

INSTITUTO DE PESQUISAS ESPACIAIS

DISSERTAÇÃO


EXTRAÇÃO DE ATRIBUTOS ESPACIAIS EM IMAGENS MULTIESPECTRAIS

SUBMETIDA POR

Luciano Vieira Dutra

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

1981

1. Publicação nº <i>INPE-2315-TDL/078</i>	2. Versão	3. Data <i>Fev., 1982</i>	5. Distribuição <input type="checkbox"/> Interna <input checked="" type="checkbox"/> Externa <input type="checkbox"/> Restrita
4. Origem <i>DRH-DSR</i>	Programa <i>FRH/CAP</i>		
6. Palavras chaves - selecionadas pelo(s) autor(es) <i>SELEÇÃO DE ATRIBUTOS CLASSIFICAÇÃO DE PADRÕES</i> <i>ATRIBUTOS ESPACIAIS IMAGENS MULTIESPECTRAIS</i>			
7. C.D.U.: <i>528.711.7:621.376.5</i>			
8. Título <i>EXTRAÇÃO DE ATRIBUTOS ESPACIAIS EM</i> <i>IMAGENS MULTIESPECTRAIS</i>		10. Páginas: <i>101</i>	
		11. Última página: <i>A.1</i>	
		12. Revisada por	
9. Autoria <i>Luciano Vieira Dutra</i>		<i>Nelson Mascarenhas</i> <i>Nelson D.D. Mascarenhas</i>	
Assinatura responsável 		13. Autorizada por <i>Parada</i> <i>Nelson de Jesus Parada</i> <i>Diretor</i>	
14. Resumo/Notas <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 imagens multiespectrais 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 de 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>			
15. Observações <i>Tese de Mestrado em Computação Aplicada, aprovada em 06 de março de 1981.</i>			

*Disse-lhe Nicodemos: como po
de um homem nascer, sendo velho?
porventura pode tornar a entrar
no ventre de sua mãe, e nascer?*

*Jesus respondeu: Na verdade,
na verdade te digo que aquele
que não nascer da água e do Es
pírito, não pode entrar no rei
no de Deus.*

*O que é nascido da carne é
carne, e o que é nascido do es
pírito é espírito.*

*Não te maravilhes de te ter
dito: Necessário vos é nascer
de novo.*

*O vento assopra onde quer, e
não sabes donde vem, nem para
onde vai; assim é todo aquele
que é nascido do Espírito.*

(Jo 3, 4-8)

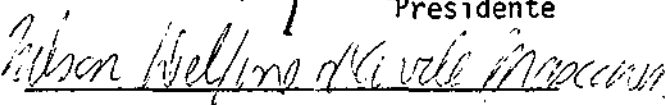
Aprovada pela Banca Examinadora
em cumprimento dos requisitos exigidos
para a obtenção do Título de Mestre em
Computação Aplicada

Dr. Celso de Renna e Souza




Presidente

Dr. Nelson Delfino D'Ávila Mascarenhas



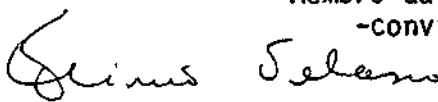
Orientador

Dr. Claudio Roland Sonnenburg



Membro da Banca
-convidado-

Dr. Flávio Roberto Dias Velasco



Membro da Banca

Luciano Vieira Dutra



candidato

São José dos Campos, 06 de março de 1981

AGRADECIMENTOS

O trabalho apresentado não seria possível sem a valiosa colaboração do meu orientador Dr. Nelson D.A. Mascarenhas. Estendo meus agradecimentos a Ricardo C.M. de Souza pela confecção da subrotina de projeção de figuras de 3 dimensões, a José C. Moreira por alterações que foram necessárias ao Sistema MAXVER; a Fernando A.M. Ii pela confecção do sistema de seleção de atributos e cálculo de autovalores e autovetores; a Edson A. Ribeiro pela confecção de diversos filtros; e finalmente a Solange B.M. de Oliveira e Cláudio C.F. Barbosa pela ajuda que me prestaram na confecção de outros programas auxiliares.

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 although the use of nonlinear filters does not guarantee the normality of the resulting features. Therefore, nonlinear 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.

SUMÁRIO

	<u>Pág.</u>
LISTA DE FIGURAS	<i>xi</i>
LISTA DE TABELAS	<i>xiii</i>
<u>CAPÍTULO 1 - INTRODUÇÃO</u>	1
1.1 - O problema de classificação de padrões	1
1.2 - Caracterização de imagens digitais	3
1.2.1 - A representação matemática da imagem	3
1.2.2 - Caracterização estatística dos dados de sensoriamento re moto	4
1.3 - Objetivo do trabalho	6
<u>CAPÍTULO 2 - EXTRAÇÃO DE ATRIBUTOS DE IMAGEM DIGITAL</u>	7
2.1 - Filtragem	7
2.1.1 - Filtragem linear	7
2.1.1.1 - Filtros derivativos	8
2.1.1.2 - Detecção de linhas e manchas	11
2.1.1.3 - Médias	12
2.1.1.4 - Filtros mistos	12
2.1.2 - Filtragem não linear	18
2.1.2.1 - Segmentação de imagens	19
2.1.2.2 - Filtragem não-linear para realce de bordas	21
2.1.3 - Discussão sobre a largura das máscaras	25
2.2 - Atributos estatísticos	26
2.2.1 - Função auto-correlação	26
2.2.2 - Detecção estatísticas de bordas	27
2.2.3 - Histograma	27
2.3 - Outros métodos	28
2.3.1 - Coeficientes de transformada digital	28
2.3.2 - Atributos estruturais	28
2.3.3 - Atributos obtidos por modelos especiais	29
2.3.4 - Operadores heurísticos	30
2.3.5 - Atributos extraídos de cenas multiespectrais	32
2.3.6 - Dados auxiliares	33

	<u>Pág.</u>
<u>CAPÍTULO 3 - OS MÉTODOS DE CLASSIFICAÇÃO</u>	35
CAPÍTULO 4 - SELEÇÃO DE ATRIBUTOS	39
4.1 - Objetivo	39
4.2 - Método	39
<u>CAPÍTULO 5 - O MÉTODO PROPOSTO E DISCUSSÕES</u>	43
5.1 - O método	43
5.2 - O método no contexto da literatura	48
5.3 - Observações teóricas sobre o método	53
5.3.1 - O teorema central do limite	53
5.3.2 - Dimensionalidade, precisão e número de amostras	54
<u>CAPÍTULO 6 - RESULTADOS</u>	57
6.1 - 1ª experiência	59
6.2 - 2ª experiência	67
6.3 - 3ª experiência	71
6.4 - 4ª experiência	74
6.5 - Comentários gerais	77
6.6 - Sugestões para futuras pesquisas	80
REFERÊNCIAS BIBLIOGRÁFICAS	83
APÊNDICE A - BIBLIOGRAFIA COMPLEMENTAR	

LISTA DE FIGURAS

	<u>Pág.</u>
1.1 - Sistema de classificação de padrões	2
2.1 - Módulo da TDF do Laplaciano (Equação 2.3a)	10
2.2 - Filtro corta faixa	13
2.3 - Módulo da TDF de um filtro corta-faixa (Equação 2.8)	14
2.4 - Caso especial do realce	15
2.5 - Módulo da TDF caso especial de realce (Equação 2.10)	16
2.6 - Filtro cascata	17
2.7 - Módulo da TDF de filtro cascata (Equação 2.12)	18
2.8 - Filtro Mediano	19
2.9 - Modelo de bordas	21
2.10 - Métodos não-lineares de realce de bordas	21
2.11 - Filtros casados a bordas	24
2.12 - Método estocástico de extração de atributos de textura ...	30
5.1 - Extração de atributos em imagens digitais	44
6.1 - Máscara para suavização (5 x 5)	58
6.2 - Curva de reescalonamento tipo raiz quadrada	68
6.3 - Máscara 3 x 3 de suavização	75
6.4 - Imagem classificada com canais originais	78
6.5 - Imagem classificada com canais da seleção 3	79

LISTA DE TABELAS

	<u>Pág.</u>
6.1 - Classes usadas	57
6.2 - Seleção 1	59
6.3 - Matriz de classificação para áreas de treinamento utilizando-se canais originais com $L = 5$	61
6.4 - Matriz de classificação para áreas teste, utilizando-se canais originais com $L = 5$	62
6.5 - Matriz de classificação para áreas de treinamento, utilizando-se os canais da seleção número 1, com $L = 5$	63
6.6 - Matriz de classificação para áreas teste, utilizando-se os canais da seleção número 1, com $L = 5$	64
6.7 - Seleção 2	65
6.8 - Índices de desempenho para os conjuntos de canais com operador variação sem reescalonamento (áreas de treinamento)	66
6.9 - Índices de desempenho para os conjuntos de canais com operador variação sem reescalonamento (áreas teste)	66
6.10 - Seleção 3	68
6.11 - Seleção 4	69
6.12 - Índices de desempenho para os conjuntos de canais com operador variação com reescalonamento (áreas de treinamento)	69
6.13 - Índices de desempenho para os conjuntos de canais com operador variação com reescalonamento (áreas teste)	70
6.14 - Matriz de classificação para áreas teste, utilizando-se os canais de seleção 3, com $L = 5$	71
6.15 - Seleção 5	72
6.16 - Seleção 6	72
6.17 - Índices de desempenho para os conjuntos de canais com operadores laplaciano reescalados e suavizados (áreas treinamento)	73
6.18 - Índices de desempenho para os conjuntos de canais com operadores laplaciano reescalados e suavizados (áreas teste)	74
6.19 - Seleção 7	75
6.20 - Seleção 8	76
6.21 - Índices de desempenho para as seleções 7 e 8 (áreas de treinamento)	76
6.22 - Índices de desempenho para as seleções 7 e 8 (áreas teste)	77

6.23 - Distribuição da informação entre canais principais para 3 classes, usando-se matriz de covariância de ordem 4 somente com canais originais e a matriz de covariância de ordem 12 com os canais da experiência 3	80
--	----

CAPÍTULO 1

INTRODUÇÃO

1.1 - O PROBLEMA DE CLASSIFICAÇÃO DE PADRÕES

Desde o advento dos computadores digitais, tem havido um constante esforço no sentido de idealizar métodos automáticos, que substituam o homem no trabalho de tomar decisões, muitas vezes monótono e repetitivo, ou que façam essa tarefa de maneira rápida e precisa.

Estudos intensivos de problemas de classificação a fim de associar um objeto físico ou evento a uma das várias categorias 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, podem-se citar: previsão numérica de tempo, diagnóstico de pacientes através da análise de eletrocardiogramas e raios X, reconhecimento de assinaturas escritas à mão, de impressões digitais etc.

Este caso específico refere-se à partição e classificação das várias áreas ou objetos que compõem uma imagem de recursos naturais.

Um sistema de classificação de padrões pode ser dividido em 2 partes: o extrator de atributos e o classificador. (Figura 1.1).

O extrator de atributos tem a função de reduzir os dados naturais medindo um certo conjunto de "atributos" ou "propriedades" que melhor caracterizem os objetivos de interesse. Esses atributos, ou mais precisamente os valores desses atributos, passam por um classificador que avalia as evidências apresentadas segundo determinado critério e associa uma categoria ao objeto.




Fig. 1.1 - Sistema de classificação de padrões.

O critério usual para a tarefa de classificação é a minimização dos erros de classificação. Existem várias técnicas, e a escolha de uma em particular depende da natureza do problema, das informações disponíveis a priori e da preferência do projetista.

Discutir-se-ão neste trabalho principalmente as questões de extração de atributos de imagens digitais adquiridas de plataformas remotas, avião ou satélite.

Considera-se que é suficiente definir um conjunto finito de M classes w_1, w_2, \dots, w_M , e que N atributos x_1, x_2, \dots, x_N podem ser extraídos para uso na classificação.

Cada conjunto de N medidas pode ser representado por um vetor N-dimensional $\vec{x} = [x_1 \ x_2 \ \dots \ x_N]$, ou por um ponto no espaço N-dimensional θ .

Normalmente o uso de um grande número de medidas aumenta o custo computacional do processo. Técnicas de seleção de atributos permitem selecionar um número menor de atributos, aumentando assim a eficiência das tarefas computacionais, sem prejudicar demasiadamente a precisão.

Pelo processo denominado treinamento, anterior ao da classificação, o sistema determina, a partir de dados de categoria conhecida, parâmetros usados no algoritmo de classificação, que é denominada "supervisionada".

1.2 - CARACTERIZAÇÃO DE IMAGENS DIGITAIS

1.2.1 - A REPRESENTAÇÃO MATEMÁTICA DA IMAGEM

Uma figura é um objeto plano cujo brilho, cor ou refletância varia de ponto para ponto. Essa variação pode ser representada por uma função escalar de 2 variáveis, no caso de figuras em preto e branco, e por uma função vetorial, no caso de figuras coloridas. Para facilidade de expressão, define-se cena como sendo uma figura colorida. O vocábulo imagem fica reservado a cada uma das componentes da cena que podem ser consideradas figuras em preto e branco.

O valor da função que representa a imagem denomina-se nível de cinza ou brilho.

Considera-se também que essas funções são analiticamente bem comportadas e tem valores não-negativos e limitados.

Em processamento digital não se usam imagens como funções contínuas. As cenas naturais são normalmente observadas e adquiridas em plataformas remotas, em faixas estreitas centradas em alguns comprimentos de onda convenientes. Em seguida, essas imagens são digitalizadas, ou seja, um processo de amostragem é levado a efeito para extrair da imagem um número discreto de números reais (amostras) a intervalos regulares. Depois um processo de quantização é aplicado às amostras para que assumam um número discreto de valores.

Cada amostra será chamada "pixel" (de "picture element") ou elemento de resolução, e a imagem pode ser considerada uma matriz de números inteiros.

Notação:

$f = [f(i, j)]$ = matriz de imagem.

$f_c(x, y)$ = brilho da imagem contínua no ponto (x, y) .

$f(i, j)$ = nível de cinza da imagem amostrada de $f_c(x, y)$ no ponto $x = i, y = j$ (na prática, $f(i, j)$ representa o nível médio do brilho em uma pequena região centrada em (i, j)).

1.2.2 - CARACTERIZAÇÃO ESTATÍSTICA DOS DADOS DE SENSORIAMENTO REMOTO

Considerando-se a hipótese que admite um caráter de aleatoriedade inerente à natureza, os dados de sensoriamento remoto exibem variações que tendem a obscurecer as diferenças entre as classes de interesse. A análise estatística leva em conta essas variações e, assim, procura reduzir os erros de classificação.

No caso de classificação supervisionada, existe também incerteza na escolha dos padrões de treinamento e superposição destes no espaço de atributos.

Para o tratamento estatístico dos dados de sensoriamento remoto, um histograma para cada classe que ocorre na imagem é obtido, para estimar a função densidade de probabilidade para essa classe.

Estes histogramas podem ser usados diretamente para estimar a probabilidade a posteriori de um dado ponto da imagem pertencer a uma classe determinada, visto que foi observada uma medida \bar{x} .

Se o número de dados for grande, será preciso muita memória de computador para guardar estes histogramas ainda mais de um caso N-dimensional. Acrescente-se também o fato de que, para estimar bem uma função densidade de probabilidade, seria necessário um grande número de padrões de treinamento.

A maneira de aliviar esse problema é adotar para cada histograma a forma de uma função densidade de probabilidade conhecida.

O modelo mais frequentemente usado é o gaussiano multivariável (Swain, 1978), que tem se ajustado adequadamente aos processos probabilísticos envolvidos em um grande número de aplicações em sensoriamento remoto.

Podem-se citar, além disso, outras quatro vantagens de utilizar o modelo gaussiano:

- a) A existência do teorema central do limite e de teoremas relacionados permite considerar a soma de um grande número de variáveis aleatórias (v.a) independentes e identicamente distribuídas como gaussianas (discussão detalhada na Seção 5.3.1).
- b) A distribuição gaussiana é bem conhecida com tratamento matemático fácil e resultados tabelados.
- c) Os classificadores projetados nesta base são robustos, levando-se em consideração que violações até um pouco severas desse modelo não alteram muito a precisão da classificação.
- d) Do ponto de vista prático, classificadores que utilizam o modelo gaussiano oferecem uma boa solução de compromisso entre desempenho e custo.

Duas precauções devem ser tomadas:

- a) É preciso ter cuidado com o número de padrões utilizados para o treinamento. Usando-se n canais para a aquisição da cena de recurso natural, o mínimo número teórico de amostras requerido para estimativa dos parâmetros necessários é $n + 1$. Na prática, esse número deverá estar entre $20n$ e $100n$ para prover boas estimativas.
- b) Os casos em que o histograma da classe se apresentar multimodal não podem ser adequadamente descritos por funções normais. Re

comenda-se subdividir a classe de maneira a associar a cada modo uma função normal.

1.3 - OBJETIVO DO TRABALHO

O objetivo do trabalho é a procura de métodos eficientes e precisos de classificação de padrões para a resolução de problemas de sensoriamento remoto.

Dois dos fatores que influenciam o poder discriminatório de um dado algoritmo de classificação são: o número de atributos que se usam, e os processos usados para a extração de atributos da imagem.

Procurar-se-á desenvolver um método de classificação que utilize atributos espaciais (locais), conjuntamente ou não com dados espectrais.

Os métodos de extração de atributos espaciais basear-se-ão em filtragens linear e não-linear. Será usado um esquema de seleção de atributos, para escolher um subconjunto, entre os atributos escolhidos, que maximize o poder discriminatório.

Supõe-se que as funções densidade de probabilidade condicionais envolvidas são gaussianas. O compromisso entre eficiência de precisão e dimensionalidade será discutido.

CAPÍTULO 2

EXTRAÇÃO DE ATRIBUTOS DE IMAGEM DIGITAL

Um atributo de imagem é uma propriedade que pode ser medida. Os atributos naturais são aqueles que derivam da aparência visual da imagem, como o nível de cinza, bordas e textura. Os artificiais são os obtidos por manipulação e medidas na imagem, como o histograma e a frequência espacial.

Podem-se listar os seguintes processos de extração de atributos em imagens. Dar-se-ã maior atenção aos de maior interesse para o trabalho.

2.1 - FILTRAGEM

Operadores locais, lineares ou não-lineares, podem ressaltar o conteúdo de alta ou baixa frequência de uma imagem, sendo utilizados também para detecção de bordas, linhas ou manchas.

2.1.1 - FILTRAGEM LINEAR

A imagem resultante é obtida a partir da original pela convolução com diversos filtros curtos denominados máscaras, ou seja:

$$[r(i, j)] = [h(i, j)] * [f(i, j)] \quad (2.1)$$

Ou de modo mais simples:

$$r = h * f$$

2.1.1.1 - FILTROS DERIVATIVOS

Existem várias máscaras digitais que aproximam operadores derivativos e que quando aplicadas em imagem, realçam o conteúdo de alta frequência e eliminam, em alguns casos, o nível médio da figura.

Os filtros derivativos são usados normalmente para detecção de bordas. Borda é o nome dado a descontinuidades locais em nível de cinza entre regiões razoavelmente planas. Descontinuidade globais são chamadas segmentos limítrofes.

Outra maneira de considerar a atuação desses filtros é a extração de medidas de microtextura, pois estas medidas procuram resaltar um ou outro aspecto da relação local entre "pixels".

As máscaras apresentadas a seguir são aproximações digitais dos operadores derivativos contínuos mencionados.

1) Derivadas de primeira ordem

$$\frac{\partial f_c}{\partial x} \equiv \Delta_x f(i, j) = f(i, j) - f(i-1, j) \quad (2.2a)$$

$$\frac{\partial f_c}{\partial y} \equiv \Delta_y f(i, j) = f(i, j) - f(i, j-1) \quad (2.2b)$$

Em forma matricial 2 x 2, e usando-se a Equação 2.1

$$h_1 = \begin{bmatrix} 1 & 0 \\ -1 & 0 \end{bmatrix} \quad \Delta_x f = h_1 * f \quad (2.2c)$$

$$h_2 = \begin{bmatrix} 1 & -1 \\ 0 & 0 \end{bmatrix} \quad \Delta_y f = h_2 * f \quad (2.2d)$$

Aproximações mais exatas podem ser utilizadas usando-se máscaras de dimensão 3 x 3, como segue:

- Aproximação de Prewit para as primeiras derivadas:

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \quad (2.2e)$$

$$h_2 = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad (2.2f)$$

- Aproximação de Sobel para a primeira derivada:

$$h_1 = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (2.2g)$$

$$h_2 = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (2.2h)$$

Essas máscaras efetuam a rotação de 180 graus para compensar a rotação inerente à convolução.

2) Derivadas de segunda ordem

É possível derivar as seguintes aproximações digitais para o operador laplaciano $\nabla^2(\cdot)$ (Prado e Cortez, 1976):

$$h_1 = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (2.3a)$$

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (2.3b)$$

O filtro laplaciano é claramente passa-alta, como se pode observar na propriedade de transformada de Fourier:

$$TF(\nabla^2 f_c) = - (2\pi)^2 (u^2 + v^2) F_c(u, v)$$

onde:

$$F_c(u, v) = TF(f_c) \quad e$$

$$TF(\nabla^2(.)) = - 2^2\pi^2(u^2 + v^2)$$

Na Figura 2.1 vê-se o módulo da Transformada Discreta de Fourier (TDF) da Equação 2.3a multiplicada por 100. O ponto mínimo da figura corresponde ao valor de nível médio 0.

O operador bi-laplaciano tem a representação

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




Fig. 2.1 - Módulo da TDF do laplaciano (Equação 2.3a).

2.1.1.2 - DETECÇÃO DE LINHAS E MANCHAS

Manchas são regiões pequenas na imagem cuja amplitude difere significativamente de sua vizinhança.

Um conjunto de pontos conectados de uma imagem é uma linha, se quando se percorre um caminho perpendicular a esse conjunto, o nível de cinza diminui e, depois, aumenta (ou vice-versa).

Tanto manchas quanto linhas em uma imagem podem ser detectadas correlacionando-se a imagem com modelos idealizados de linhas e manchas. Linhas de largura 1 podem ser detectadas por:

$$h_1 = \begin{bmatrix} -1 & 2 & -1 \\ -1 & 2 & -1 \\ -1 & 2 & -1 \end{bmatrix} \quad (2.4a)$$

$$h_2 = \begin{bmatrix} -1 & -1 & -1 \\ 2 & 2 & 2 \\ -1 & -1 & -1 \end{bmatrix} \quad (2.4b)$$

$$h_3 = \begin{bmatrix} -1 & -1 & 2 \\ -1 & 2 & -1 \\ 2 & -1 & -1 \end{bmatrix} \quad (2.4c)$$

$$h_4 = \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix} \quad (2.4d)$$

Linhas de largura 2 podem ser detectadas por:

$$h_5 = \begin{bmatrix} -1 & 1 & 1 & -1 \\ -1 & 1 & 1 & -1 \\ -1 & 1 & 1 & -1 \\ -1 & 1 & 1 & -1 \end{bmatrix} \quad (2.4e)$$

Pequenas manchas podem ser detectadas por:

$$h_1 = \begin{bmatrix} -1 & -1 & -1 & -1 \\ -1 & 3 & 3 & -1 \\ -1 & 3 & 3 & -1 \\ -1 & -1 & -1 & -1 \end{bmatrix} \quad (2.5)$$

Deve-se notar que a soma dos pesos dessas máscaras é zero.

2.1.1.3 - MÉDIAS

Médias podem ser realizadas na imagem com o objetivo de diminuir a influência do ruído. Exemplos: 1) eliminação de estrias ("stripping") produzidas nas imagens, devido a diferenças entre sensores diversos colocados a bordo de satélites, mas referentes à mesma banda espectral; 2) linhas saturadas isoladas decorrentes de falha momentânea do sensor. Como o ruído se compõe basicamente de componentes de alta frequência, uma filtragem passa-baixa tende a eliminar o efeito do ruído nas imagens.

As médias, ponderadas ou não, aproximam uma operação de integração na imagem ou filtragem passa-baixa.

Alguns exemplos:

$$h_1 = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (2.6)$$

$$h_2 = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (2.7)$$

2.1.1.4 - FILTROS MISTOS

Filtros corta-faixa podem ser projetados utilizando-se da configuração da Figura 2.2:




Fig. 2.2 - Filtro corta-faixa.

onde h_b é um filtro passa-baixa e h_a é um filtro passa-alta.

Exemplo:

$$h_a = \frac{1}{2} \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

$$h_b = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

$$h_t = h_a + h_b \Rightarrow$$

$$h_t = \frac{1}{18} \begin{bmatrix} 2 & 11 & 2 \\ 11 & -34 & 11 \\ 2 & 11 & 2 \end{bmatrix} \quad (2.8)$$

Média do filtro $(52-34)/18 = 18/18 = 1$.

Nessa configuração, quando se usa um filtro passa-alta que corte totalmente o nível médio da figura, o nível médio da figura resultante permanece igual ao ditado pelo filtro passa-baixa.

Na Figura 2.3 vê-se o módulo da TDF de h_t (filtro resultante). E o valor da cota no ponto θ é 1, ou seja, o filtro não altera o nível médio da imagem.




Fig. 2.3 - Módulo da TDF de um filtro corta-faixa (Equação 2.8).

Um caso especial de operação de realce também pode ser realizada pela configuração paralela (Figura 2.4):




Fig. 2.4 - Caso especial de realce.

Exemplo de aplicação: operação conhecida como "unsharp masking" para eliminar efeito de degradação do tipo difusão na imagem, produzindo uma imagem com bordas realçadas.

$$[g] = [f] - c \cdot \nabla^2 (f) \quad (2.9)$$

Neste caso, h_b , que não altera a imagem, é igual a:

$$h_b = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

Outros filtros mistos podem ter a aplicação que segue: As operações de diferenciação em imagem costumam ampliar consideravelmente o ruído, pois este se compõe basicamente de componentes de alta frequência.

Para contornar o problema, pode-se usar um dos seguintes métodos:

1) Utilizar o esquema da Figura 2.4 com filtro hb passa-baixa. O resultado é diminuir a influência de pontos ruidosos, por causa de realce menos acentuado. Exemplo:

$$g = \frac{1}{6} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix} - \begin{bmatrix} 1 & 1 & 1 \\ 1 & -4 & 1 \\ 1 & 1 & 1 \end{bmatrix} = \begin{bmatrix} -\frac{5}{6} & \frac{26}{6} & -\frac{5}{6} \\ -\frac{5}{6} & \frac{26}{6} & -\frac{5}{6} \\ -\frac{5}{6} & \frac{26}{6} & -\frac{5}{6} \end{bmatrix} \quad (2.10)$$

Na Figura 2.5 vê-se o resultado da TDF da resposta impulsiva g . Esse filtro não altera o nível médio da imagem, ou seja, a cota no ponto θ é 1. Compare esse resultado com o da Figura 2.1. O filtro laplaciano, além de retirar o nível médio da imagem, tem um realce mais agudo para altas frequências.




Fig. 2.5 - Módulo da TDF caso especial de realce (Equação 2.10).

- 2) Utilizar um filtro passa-faixa de maneira a não ampliar demasiadamente as frequências mais altas, através de um conjunto cascata: (Figura 2.6).




Fig. 2.6 - Filtro cascata.

Usando-se os seguintes filtros passa alta e passa baixa, respectivamente:

$$h_t = h_a * h_b = \frac{1}{9} \begin{bmatrix} & 1 & & & \\ 1 & -4 & 1 & & \\ & & & & \\ & & & & \\ & & & & \end{bmatrix} * \begin{bmatrix} 1 & 2 & 1 \\ 2 & 3 & 2 \\ 1 & 2 & 1 \end{bmatrix}$$

ou

$$h_t = \frac{1}{15} \begin{bmatrix} 0 & 1 & 2 & 1 & 0 \\ 1 & 0 & -3 & 0 & 1 \\ 2 & -3 & -4 & -3 & 2 \\ 1 & 0 & -3 & 0 & 1 \\ 0 & 1 & 2 & 1 & 0 \end{bmatrix} \quad (2.12)$$

Na Figura 2.7 pode-se observar o módulo da TDF desta máscara em uma matriz 11 x 11. Observe que o ponto 0 tem cota zero.




Fig. 2.7 - M3dulo da TDF de filtro cascata (Equa3d3o 2.12).

2.1.2 - FILTRAGEM N3o-LINEAR

A filtragem passa-baixa linear tende a borrar regi3es li m3trofes entre 3reas distintas de uma imagem. Para evitar esse efeito, 3 poss3vel usar filtros n3o-lineares convenientes.

Operadores derivativos não-lineares, em vez de operadores lineares, podem muitas vezes ser os mais indicados para resolver certos tipos de problemas.

2.1.2.1 - SEGMENTAÇÃO DE IMAGENS

São comumente usados para esse fim os filtros passa-baixa não-lineares.

1) Filtro mediano

Este tipo de filtro, introduzido por Tukey (1977), consiste em associar ao ponto central de uma janela $N \times N$ (N ímpar) o nível de cinza intermediário da lista ordenada dos níveis de cinza dos $N \times N$ pontos da vizinhança.

É útil para eliminar ruídos e rugosidade excessiva, sem espalhar o efeito do ponto ruidoso na vizinhança, como acontece em filtragem passa-baixa linear. Exemplo:

			40	
			15	
			13	
10	12	9	12	
15	40	10	11	- O ponto mediano é 11
11	8	13	10	
			10	
			9	
			8	

Fig. 2.8 - Filtro mediano.

2) Filtro de modo

O filtro de modo, introduzido por Coleman (1979), computa um histograma em uma janela $N \times N$ e tem por saída o nível de cinza mais frequente na vizinhança.

O efeito deste filtro é substituir cada "pixel" pelo valor mais frequente em uma pequena região centrada nele, removendo-se pequenas variações em brilho; portanto, tende a criar regiões de brilho único.

Este filtro quase não causa perda de resolução porque a sua saída não muda suavemente como numa média, mas abruptamente quando a maioria dos níveis de cinza de uma região passa a ser outra, o que acontece ao cruzar fronteira entre regiões. Podem ocorrer, no entanto, deformações em regiões onde não aparece um nível de cinza claramente predominante.

Para evitar essas deformações, foram introduzidas duas modificações no processo: a primeira é a inclusão de um limiar de frequência para substituição do ponto central pelo mais frequente. Esse problema é mais crítico para janelas maiores. A segunda é a introdução opcional de um processo de conformação das bordas a modelos para bordas, se o limiar de frequência não for atingido. A intenção é promover um "amacramento" das bordas extraíndo-se ruídos que promovem a caracterização da borda.

Na Figura 2.9 apresentam-se 2 das 8 bordas teóricas possíveis de acontecer numa região 3×3 .

O ponto central é substituído pela média na região hachurada, mais próxima do valor do ponto, para algum dos 8 possíveis modelos de bordas.

Esse processo pode ser repetido várias vezes, até que se alcance um estado de mínima mudança estipulada.




Fig. 2.9 - Modelos de bordas.

As regiões hachuradas e brancas representam níveis idênticos.

2.1.2.2 - FILTRAGEM NÃO-LINEAR PARA REALCE DE BORDAS

Filtragem não-linear é um dos métodos que podem ser utilizados para: 1) detecção de bordas; 2) extração de atributos especiais e 3) definição de atributos texturais de uma imagem, já que microtextura pode ser considerada como densidade local de microbordas.

Os métodos não-lineares de realce de bordas constituem-se normalmente de várias etapas (Figura 2.10).

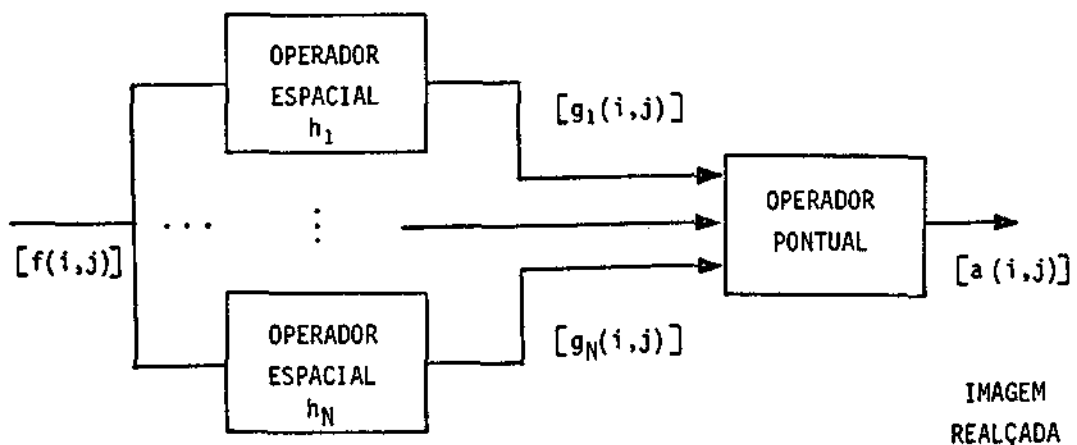


Fig. 2.10 - Métodos não-lineares de realce de bordas.

$$g_i(i,j) = f(i,j) * h_i(i,j) \quad (2.13)$$

Inicialmente a imagem é processada por N operadores lineares ou máscaras que produzem um conjunto de funções derivadas parciais ou função correlação entre a imagem e um modelo ("template").

Posteriormente, a cada ponto as funções $g_i(i,j)$ serão combinadas, normalmente de uma maneira não-linear, produzindo uma matriz gradiente.

Operações pontuais típicas são: raiz quadrada, máximo entre funções e soma de módulos. A matriz realçada $[a(i,j)]$ provê uma medida das discontinuidades no centro da máscara a cada ponto.

Costumam-se distinguir dois tipos principais de métodos: diferenciais e por correlação com modelos ideais.

1) Métodos derivativos

Utilizam na primeira fase os seguintes operadores lineares:

$$h_1 = \begin{bmatrix} -1 & 0 \\ 1 & 0 \end{bmatrix} \quad (2.14a)$$

$$h_2 = \begin{bmatrix} -1 & 1 \\ 0 & 0 \end{bmatrix} \quad (2.14b)$$

- Aproximações simples das primeiras derivadas.

$$h_1 = \begin{bmatrix} 1 & -1 \\ 1 & 0 \end{bmatrix} \quad (2.15a)$$

$$h_2 = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \quad (2.15b)$$

- Operadores de Roberts.

$$h_1 = \begin{bmatrix} 1 & 0 & -1 \\ C & 0 & -C \\ 1 & 0 & -1 \end{bmatrix} \quad (2.16a)$$

$$h_2 = \begin{bmatrix} 1 & C & 1 \\ 0 & 0 & 0 \\ -1 & -C & -1 \end{bmatrix} \quad (2.16b)$$

- Para $C = 1 \Rightarrow$ operador de Prewit

- Para $C = 2 \Rightarrow$ operador de Sobel

$$h = \begin{bmatrix} 0 & 1 & 1 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (\text{Laplaciano})$$

Esses operadores usam uma combinação não-linear, ponto a ponto, para produzir uma matriz realçada do tipo:

$$a(i,j) = ((g_1(i,j))^2 + g_2(i,j)^2)^{1/2} \quad (2.17)$$

$$a(i,j) = |g_1(i,j)| + |g_2(i,j)| \quad (2.18)$$

No caso de imagem obtida pela convolução com a máscara da Equação 2.3a, basta considerar $[a(i,j)]$:

$$a(i,j) = |g(i,j)| \quad (2.19)$$

Apresentam-se algumas observações sobre o operador $|\nabla^2 f(i,j)|$, que é obtido pela Equação 2.19, a qual é aplicada à Equação 2.13, usando-se a Equação 2.3a.

Panda (1977) prova, para o caso contínuo, que o operador $|\nabla^2(\cdot)|$ torna o campo de imagem não-correlacionado, ou seja, o campo

aleatório resultado da operação $|\nabla^2(\cdot)|$ tem função de autocorrelação impulsiva.

Essa propriedade é interessante porque indica que o campo resultante não tem informação espacial e sugere que a informação espacial contida na imagem original foi transformada em informação pontual na imagem resultante.

Além disso, é mais adequada a utilização de campos não-correlacionados em classificadores pontuais.

A orientação da borda a cada ponto é dada por:

$$\theta(i,j) = \arctg(g_2(i,j)/g_1(i,j)) \quad (2.20)$$

2) Correlação com modelos ideais

Operadores por correlação com modelos ideais são conjuntos de máscaras que representam aproximações de bordas ideais em várias direções. A Figura 2.11 apresenta as direções e diferentes aproximações propostas.

$\begin{bmatrix} 1 & 1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & -1 \end{bmatrix}$	$\begin{bmatrix} 1 & -1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & 1 \end{bmatrix}$	"Compass gradient"
$\begin{bmatrix} 3 & 3 & 5 \\ 3 & 0 & 5 \\ 3 & 3 & 5 \end{bmatrix}$	$\begin{bmatrix} 3 & -5 & -5 \\ 3 & 0 & -5 \\ 3 & 3 & 3 \end{bmatrix}$	"Kirsch"
$\begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 1 & -1 & -1 \\ 1 & 0 & -1 \\ 1 & 1 & 0 \end{bmatrix}$	"Nível 3"
$\begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 & -2 \\ 1 & 0 & -1 \\ 2 & 1 & 0 \end{bmatrix}$	"Nível 5"
Posição e1	Posição e2	

Fig. 2.11 - Filtros casados a bordas.

Os modelos denominados nível 3 e nível 5 estão relacionados com os operadores de Prewit e Sobel, respectivamente; neste caso bastam 4 orientações para achar o máximo.

A matriz realçada é obtida por:

$$a(i,j) = \max(|g(i,j)|) \quad (2.21)$$

2.1.3 - DISCUSSÃO SOBRE A LARGURA DAS MÁSCARAS

Aumentar a área da máscara significa diminuir a sensibilidade do ruído. No entanto, bordas deslocadas dentro das máscaras contribuem para o gradiente, aumentando a probabilidade de detecção de bordas falsas.

O compromisso entre redução de ruído e sensibilidade de deslocamento de bordas é discutido por Abdou e Pratt (1979). Particularmente na Seção VI.

Máscaras curtas são convenientes para detecção de microtexturas. Padrões compostos de componentes de baixa frequência não influenciam o resultado das máscaras curtas.

Desejando-se medir texturas e macrotexturas, as máscaras devem aumentar de tamanho e contar com o número de pontos compatíveis com a dimensão das estruturas que se quer detectar.

Um estudo de Gramenopoulos (1973) conclui que se podem utilizar máscaras curtas (3 x 3, 4 x 4, 5 x 5) no tratamento de imagens LANDSAT, pois as estruturas de maior interesse têm frequência maior que 1/4 ciclo por "pixel". (Seção 5.2).

2.2 - ATRIBUTOS ESTADÍSTICOS

2.2.1 - FUNÇÃO DE AUTOCORRELAÇÃO

Considere a função de autocorrelação estacionária no "ensemble":

$$k_f(m,n) = E(f(j,k) f(j+m, k+n)) \quad (2.22)$$

definida para os valores $m, n = \pm 1, \pm 2, \dots, \pm T$.

Essa função pode ser estimada pela função de autocorrelação espacial

$$A_f(m,n) = \sum_{j+W}^{j+W} \sum_{k+W}^{k+W} f(u,v) f(u-m, v-n) \quad (2.23)$$

em média sobre uma janela $(2W+1) \times (2W+1)$, centrada em (j,k) . O tamanho da janela deve ser escolhido de maneira a ter custo computacional não elevado, mas com boa margem de precisão na estimativa.

A partir dessa função de autocorrelação, podem ser definidos momentos (medidas de espalhamento) cujo valor pode ser assinalado no ponto central da janela, ou em todos os seus pontos.

$$S(u,v) = \sum_{m,n=0}^T \sum_{m,n=0}^T (m-h_m)^u (n-h_n)^v A_f(m,n)$$

onde

$$h_m = \sum_{m,n=0}^T \sum_{m,n=0}^T m A_f(m,n)$$

$$h_n = \sum_{m,n=0}^T n \tilde{A}_f(m,n)$$

$$\tilde{A}_f(m,n) = \frac{A_f(m,n)}{\sum_{m,n=0}^T A_f(m,n)} \quad (2.24)$$

2.2.2 - DETECÇÃO ESTATÍSTICA DE BORDAS

O realce de bordas pode ser feito proporcionalmente à correlação dos "pixels" para máscara estatística:

$$h = \begin{bmatrix} \rho_r \rho_c & -\rho_c (1 + \rho_r^2) & \rho_r \rho_c \\ -\rho_r (1 + \rho_c^2) & (1 + \rho_r^2)(1 + \rho_c^2) & -\rho_r (1 + \rho_c^2) \\ \rho_r \rho_c & -\rho_c (1 + \rho_r^2) & \rho_r \rho_c \end{bmatrix} \quad (2.25)$$

onde ρ_r e ρ_c são os coeficientes de correlação entre "pixels" adjacentes na linha e na coluna.

2.2.3 - HISTOGRAMA

Vários atributos podem ser definidos a partir de histograma da janela na imagem.

Para descrever a forma de histogramas de primeira ordem, são utilizadas as medidas de: média, variância, assimetria, kurtosis, energia e entropia.

Histogramas de segunda ordem são baseados na distribuição de probabilidade conjunta de pares de "pixels". São representados por uma matrix $L \times L$, chamada matriz de co-ocorrência, onde L é igual ao número de níveis de cinza possíveis.

A partir dessa matriz podem-se obter medidas tais como: autocorrelação, covariância, inércia, energia, entropia e outros.

Pratt (1976), Haralick et alii (1973) e outros têm contribuído para o desenvolvimento dos métodos que envolvem medida de histograma.

2.3 - OUTROS MÉTODOS

2.3.1 - COEFICIENTES DE TRANSFORMADA DIGITAL

Os coeficientes de transformada digital especificam a amplitude ou o grau de repetição de certos padrões de luminância na imagem ou janela que se está examinando. Dos métodos mais comuns, podem-se citar:

- 1) Transformada Discreta de Fourier (TDF)
(Pratt, 1978; Haralick, 1979)
- 2) Transformada Textural
(Haralick, 1979)
- 3) Outras transformadas: Hadamard, Haar etc.

Nestes métodos, a imagem é tipicamente subdividida em várias subimagens quadradas. Cada subimagem é transformada, e os coeficientes resultantes são associados a ela. Tais coeficientes auxiliam a discriminação desses campos, pois estão relacionados com a textura.

2.3.2 - ATRIBUTOS ESTRUTURAIIS

Normalmente se utiliza somente o nível de cinza de cada ponto da imagem em processos de classificação de padrões. As inter-relações locais (textura) ou globais (contexto) de pontos na imagem também são características importantes a serem consideradas na definição de classes ou objetos nelas contidos.

No método estrutural, a primitiva é definida como sendo um conjunto de pontos com propriedades tonais comuns. Regras de localização descrevem a inter-relação entre as primitivas.

Dessa maneira é possível separar do restante da imagem as áreas que tenham as mesmas primitivas e regras de localização.

Modelos puros de textura são baseados no fato de que texturas são compostas de primitivas que aparecem em arranjos espaciais regulares e repetitivos.

Os métodos de densidade de extremos relativos e de árvores relacionais (Haralick, 1979) são exemplos de método estrutural.

2.3.3 - ATRIBUTOS OBTIDOS POR MODELOS ESPECIAIS

Existem métodos de extração de atributos de imagem derivados de alguns modelos propostos.

O modelo de auto-regressão baseia-se no fato de que o valor do "pixel" depende do valor de seus vizinhos.

Fixada uma vizinhança de um dado ponto, pode-se associar a esse uma função dos coeficientes da função que estima esse ponto a partir dos pontos de sua vizinhança. (Haralick, 1979).

O modelo visual estocástico desenvolvido por Pratt e Faugeras (1979) considera uma região de textura como uma amostra de um processo estocástico bidimensional, descritível por seus parâmetros estatísticos, limitados porém a descrições que concordem com a percepção humana. O método se resume no diagrama de bloco da Figura 2.12.

Da função de autocorrelação da imagem e do histograma do campo descorrelacionado são extraídos atributos que a experiência mostrou serem significativos em relação aos processos de discriminação visual.

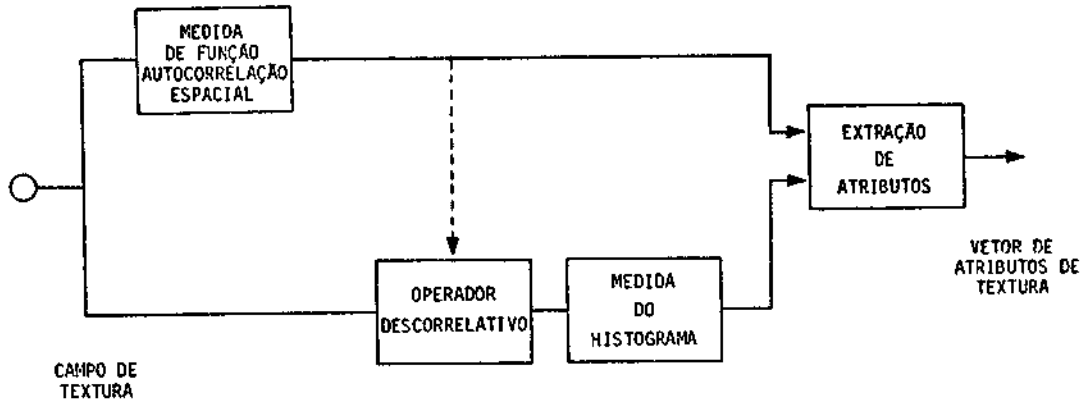


Fig. 2.12 - Método estocástico de extração de atributos de textura.

2.3.4 - OPERADORES HEURÍSTICOS

Alguns operadores heurísticos podem ser definidos para que tenham uma saída proporcional à rugosidade de uma pequena região circunvizinha de um dado ponto. São operadores projetados a partir da experiência.

Considere a seguinte disposição dos pontos em uma vizinhança 3 x 3:

a b c
d x e
g h i

A partir dela podem ser definidos os operadores:

1) Variações

- Variação horizontal

$$\begin{aligned} \text{HTV} = & |a - b| + |d - x| + |g - h| + \\ & + |b - c| + |x - e| + |h - i| \end{aligned} \quad (2.26)$$

- Variação vertical:

$$\begin{aligned} \text{VTV} = & |a - d| + |b - x| + |c - e| + \\ & + |d - g| + |x - h| + |e - i| \end{aligned} \quad (2.27)$$

- Variação total:

$$\text{TV} = \text{HTV} + \text{VTV} \quad (2.28)$$

- Variação mínima:

(menor sensibilidade de ruído)

$$\text{MTV} = \min(\text{HTV}, \text{VTV}) \quad (2.29)$$

2) Deslocamento

Uma imagem deslocada lateral ou verticalmente pode ser usada como outro canal. Nesse caso, a matriz de covariância teria elementos que medem a autocovariância no sentido horizontal e vertical das imagens.

3) Rugosidade

$$\begin{aligned} \text{rugosidade} = & |x - a| + |x - b| + |x - c| + |x - d| + \\ & |x - e| + |x - g| + |x - h| + |x - i| \end{aligned} \quad (2.30)$$

Existem outros métodos de extração de atributos baseados em estatísticas de comprimentos de segmentos de nível de cinza constante, na imagem, e em densidade de extremos relativos.

OBSERVAÇÃO: Todos os métodos até agora descritos se referem à extração de atributos, particularmente aos espaciais, realizados antes do processo de classificação. O método de Welch and Salter (1976) transfere para a fase de classificação a uti

lização de informações espaciais para auxílio no processo discriminatório (Teoria da Decisão Composta).

2.3.5 - ATRIBUTOS EXTRAÍDOS DE CENAS MULTIESPECTRAIS

Os métodos de extração de atributos apresentados aplicam-se a imagens em preto e branco. Em processos de classificação de padrões, que utilizam cenas multiespectrais, tais métodos são aplicados a cada componente da cena separadamente. Em certas aplicações, como Geologia por exemplo, podem ser extraídos certos atributos derivados de caráter espectral da cena, obtidos por operações pontuais entre os níveis de cinza do ponto de cada faixa espectral. Alguns exemplos desses atributos são definidos a seguir:

1) Razão entre canais:

$$r_{ij} = \frac{C_i}{C_j} \quad (2.31)$$

onde C_i e C_j são os níveis de cinza nos canais i e j .

2) Normalização:

$$N_i = \frac{C_i}{\sum_{j=1}^N C_j} \quad (2.32)$$

onde N é o número de canais.

3) Diferença normalizada:

$$D_{ij} = \frac{C_i - C_j}{C_i + C_j} \quad (2.33)$$

A motivação primária dessas operações é transformar os dados de imagem em outra forma menos dependente de fatores ambientais e condições de sensores, que são normalmente de caráter multiplicativo, como por exemplo: ganho dos sensores, iluminação, transmitância etc.

2.3.6 - DADOS AUXILIARES

Em adição aos atributos de imagem ou dela derivados por manipulações dos níveis de cinza dos "pixels", outros dados não diretamente extraídos, mas relacionados com a posição dos pontos na imagem, tais como dados temporais, geomorfológicos, sócio-econômicos e climáticos, podem ser utilizados em combinação com os primeiros, para auxiliar no processo de discriminação de objetos especiais na imagem.

CAPÍTULO 3

OS MÉTODOS DE CLASSIFICAÇÃO

Quanto ao modelo que descreve o comportamento dos atributos, os métodos de classificação de padrões podem ser classificados em dois tipos: estatístico e determinístico.

Um método determinístico de interpretação automática de imagens, disponível aos usuários do sistema I-100 fabricado pela G.E., é o chamado método do paralelepípedo (GE, 1975).

Um padrão ou vetor é classificado como pertencente a uma dada classe se todas as componentes desse vetor estiverem dentro de certos limites superiores e inferiores, definidos para cada dimensão ou eixo e para aquela classe. Em outras palavras, um padrão ou vetor é classificado para uma classe se ele pertence ao interior do paralelepípedo cujos vértices são dados pelos pares de limitantes superiores e inferiores, para todos os eixos do espaço de atributos em uso.

Esse método, embora rápido, conduz a aproximações grosseiras da assinatura real do objeto que está sendo classificado, gerando muitos erros de classificação.

Um método estatístico de decisão implantado no sistema I-100, e que será usado normalmente neste trabalho, é a regra de decisão por máxima verossimilhança. (Velasco et alii, 1978).

Decide-se que um padrão \vec{x} pertence a uma classe w_i se e somente se:

$$g_i(\vec{x}) = p(\vec{x}/w_i) P(w_i) \geq p(\vec{x}/w_j) P(w_j) = g_j(\vec{x}) \quad (3.1)$$

$i = 1, \dots, N$ onde $N =$ número de classes.

$g_i(\vec{x}) = p(\vec{x}/w_i) P(w_i)$ é chamado função discriminante para a classe w_i .

Para densidades gaussianas pode-se derivar:

$$g_i(\vec{x}) = \ln P(w_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (\vec{x} - \mu_i)^T \Sigma_i^{-1} (\vec{x} - \mu_i) \quad (3.2)$$

onde

Σ_i = matriz de covariância.

μ_i = vetor de média da classe w_i .

Esse esquema de categorização assinala cada um dos pa
drões apresentados a alguma das classes definidas anteriormente na fa
se de treinamento. Em problemas de sensoriamento remoto, no entanto,
hã sempre pontos que, de fato, não deveriam pertencer a nenhuma das
classes definidas, devido à incerteza na definição da área de treina
mento e na definição de um número menor de classes que as realmente
existentes.

Para evitar classificação excessiva (isto é, que pontos
que não pertencem a nenhuma classe sejam classificados) rejeita-se pa
ra a classe w_i o ponto cuja função discriminante for menor que um cer
to limiar T_i para a classe w_i . A regra passa a ser então:

$$\begin{aligned} x \in w_i \text{ se } g_i(x) \geq g_j(x) \quad i \neq j \\ \text{e } g_i(x) \geq T_i \end{aligned} \quad (3.3)$$

onde T_i é o limiar para a classe w_i .

Normalmente supõe-se que esse limiar T_i é o mesmo para
todas as classes.

O método estatístico gaussiano requer a estimativa do ve
tor média e da matriz de covariância para as classes a serem usadas na
fase de classificação. Para isso, usam-se áreas na imagem chamadas "de

treinamento", consideradas como verdade terrestre, para possibilitar o aprendizado das características da classe.

Um meio de testar a acuidade com que foram definidas as classes, permitindo também avaliar o poder discriminatório dos atributos usados na separação das classes de interesse, nesta fase de treinamento, é classificar os pontos de todas as áreas de treinamento, ou de outras áreas de classificação também conhecidas, denominadas áreas teste.

Uma alta percentagem de pontos de uma área de treinamento ou teste de uma classe w_i , classificada como pertencendo a w_j , significa que no mínimo a classe w_i está mal definida; provavelmente a classe w_j também estará mal definida. Se não for possível melhorar a definição das áreas de treinamento, os atributos usados não serão os mais adequados para separar essas classes.

Observando-se a influência da troca de atributos ou do número de atributos usados nas percentagens de classificação correta das diversas áreas de treinamento ou teste, um melhor conjunto de atributos para separar aquelas classes pode ser procurado.

O uso de áreas teste se faz necessário, pois a classificação de áreas de treinamento é um tanto otimista visto advir das próprias os parâmetros utilizados para a classificação. Um bom resultado na classificação de áreas teste significa que a aquisição de parâmetros foi feito com bom índice de generalização para aquela classe.

Os dois classificadores mencionados são chamados ponto a ponto, pois a classificação de um ponto não depende da classificação de seus vizinhos. A teoria de decisão composta (Duda et alii, 1973) introduz a utilização do contexto na classificação de um ponto, modelando melhor as ocorrências naturais, já que na maioria dos casos é grande a correlação entre "pixels" vizinhos nas imagens de recursos terres

tres. Infelizmente, o custo computacional da aplicação de algoritmos baseados nesta teoria é muito grande, limitando o número de casos possíveis de uso eficiente.

CAPÍTULO 4

SELEÇÃO DE ATRIBUTOS

4.1 - OBJETIVO

Cenas obtidas por sensores situados em plataformas remotas e utilizadas em levantamento de recursos naturais compõem-se normalmente de 4 ou mais imagens, cada qual captada em uma faixa diferente e estreita do espectro.

Processos de extração de atributos aplicados às imagens componentes de uma cena podem elevar consideravelmente a dimensionalidade dos dados, pela multiplicação das medidas que caracterizam um único ponto da imagem.

A Seleção de Atributos refere-se ao método utilizado para escolher um subconjunto de dimensão $M < N$, onde N é o número total de características do padrão, tal que a separabilidade entre certas classes de interesse é maximizada para esse subconjunto em relação aos outros subconjuntos de mesma subdimensão M .

4.2 - O MÉTODO

Utilizar-se-ão no processo de seleção de atributos a figura de mérito denominada Distância de Bhattacharyya (Distância B) e sua relacionada Distância Jeffreys-Matusita (Distância JM) (Chen, 1973).

A Distância B é função escalar das funções densidade de probabilidade de 2 classes e é definida como:

$$B = - \ln \rho \quad (4.1)$$

onde ρ = coeficiente de Bhattacharyya dado por:

$$\rho = \int_{-\infty}^{\infty} (p(\vec{x}/w_1) p(\vec{x}/w_2))^{1/2} dx \quad (4.2)$$

A Distância JM é dada por:

$$d_{JM}^2 = 2(1 - \rho) \Rightarrow d_{JM} = (2(1 - \rho))^{1/2} \quad (4.3)$$

Para o caso de 2 classes, podem ser obtidos limites superiores e inferiores para a probabilidade de erro em função de ρ . Sendo P_E probabilidade de erro; e P_1 e P_2 probabilidades a priori de w_1 e w_2 , respectivamente, tem-se:

$$\frac{1}{4} \rho^2 \leq P_1 P_2 \rho^2 \leq \frac{1}{2} (1 - \sqrt{1 - 4P_1 P_2 \rho^2}) \leq P_E \leq \sqrt{P_1 P_2} \rho \leq \frac{1}{2} \rho \quad (4.4)$$

Para densidades gaussianas a Distância B é dada por

$$B = \frac{1}{8} (\vec{\mu}_1 - \vec{\mu}_2)^T \left(\frac{\Sigma_1 + \Sigma_2}{2} \right) (\vec{\mu}_1 - \vec{\mu}_2) + \frac{1}{2} \left\{ \frac{\frac{1}{2} |\Sigma_1 + \Sigma_2|}{|\Sigma_1|^{1/2} |\Sigma_2|^{1/2}} \right\} \quad (4.5)$$

onde $\vec{\mu}_1$ e $\vec{\mu}_2$ são vetores média e Σ_i são matrizes de covariância para as classes 1 e 2.

É difícil derivar uma expressão semelhante para outros tipos de função densidade de probabilidade; sabe-se no entanto, que para a maior parte dos casos de imagens naturais, o modelo gaussiano se ajusta satisfatoriamente.

Quando temos 2 classes basta escolher o subconjunto com M atributos para o qual a distância JM é maior. Para o caso de mais de 2 classes costuma-se aplicar dois critérios para a escolha do melhor subconjunto: um subconjunto é escolhido para o qual a distância média entre as distâncias JM para todos os pares de classes, é maximizada. Ou

tra escolha é feita considerando-se o subconjunto que tenha a maior das distâncias JM mínima entre os pares de classe.

CAPÍTULO 5

O MÉTODO PROPOSTO E DISCUSSÕES

5.1 - O MÉTODO

Os classificadores ponto a ponto não utilizam toda a informação disponível em uma imagem, desprezando a informação espacial que ela contém. Por outro lado, métodos baseados na teoria de decisão composta usam a informação espacial com custo computacional elevado e, além disso, existe grande dificuldade para se estimar certos parâmetros requeridos.

Utilizando-se extratores adequados, podem-se produzir, a partir de N atributos originais, outros canais ou atributos que associem a cada ponto da imagem um vetor função do conteúdo espacial em torno do ponto. Em seguida utiliza-se o esquema de classificação ponto a ponto, agora com disponibilidade de atributos espaciais. Considere o esquema da Figura 5.1.

Da cena natural, utilizando-se sensores normalmente remotos, extraem-se os atributos espectrais que são devidamente digitalizados para uso em computadores.

Novas imagens são geradas a partir de cada imagem espectral, de maneira tal que cada ponto da nova imagem é associado a um número que mede uma certa modalidade de informação espacial na vizinhança do ponto correspondente na imagem original. Usar-se-ão as modalidades de informação espacial que são extraídas por filtragem linear (Seção 2.1.1), filtragem não-linear com ou sem reescalonamento (Seção 2.1.2), e operadores heurísticos, particularmente o operador variação. (Seção 2.3.4).




Fig. 5.1 - Extração de atributos em imagens digitais.

Normalmente são utilizados para operadores espaciais filtros passa-alta (fpa.) e filtros passa-baixa (fpb.), em combinação com os dados originais. O fpb tem a função de diminuir a variância espectral das classes, fazendo com que os vetores padrões se aproximem dos vetores médias das classes a que pertencem, já que se supõe que vetores que pertencem a uma mesma classe estão próximos tanto espectral quanto espacialmente. O fpa (linear ou não) extrai uma modalidade de informação espacial, que é proporcional a um operador derivativo, direcional ou não, aplicado à imagem espectral; não é hábil em geral para detectar estruturas bem definidas na imagem (o que caracteriza a idéia de textura), e sim para extrair um tipo de dado que informa algo sobre a rugosidade local da imagem e se essa rugosidade é direcional ou não, conforme o tipo de filtro utilizado.

Existe também a alternativa de realizar uma rotação espectral, que é uma transformação linear sobre o espaço de atributos. A transformação de componentes, principais (Karhunen Loève), além de manter a gaussianidade dos dados bem como sua representação (os agregamentos mantêm-se inalterados), permite reduzir o número de atributos espectrais, sem grande perda de informação, pela escolha dos autovetores correspondentes aos maiores autovalores da matriz de covariância global dos canais originais.

Assim, para a mesma dimensionalidade global pode-se fazer a extração de um número maior de atributos espaciais.

Como as máscaras utilizadas são curtas, as frequências predominantemente realçadas correspondem à faixa de 3,5 a 6,3 ciclos por km em imagens LANDSAT, que é a máxima frequência que pode ser observada nesta série de satélites com resolução de aproximadamente 80 m. Notar que a frequência de 6,3 ciclos por km corresponde à frequência normalizada de 0,5 ciclo por "pixel".

Estudos anteriores (Gramenopoulos, 1973) indicam que essa faixa contém a informação necessária para discriminar as classes mais comuns em levantamento de uso do solo (montanhas, deserto, campos

cultivados, estradas, rios, colinas, áreas urbanas, etc.) com o uso de imagens do MSS ("multispectral scanner") do LANDSAT.

Para diminuir a influência do ruído (que contém predominantemente componentes de alta frequência), o campo filtrado por operador derivativo é novamente filtrado por fpb, obtendo-se assim, por exemplo, um campo média do laplaciano ou do gradiente.

O aumento da dimensionalidade, apesar da eficiência relativa inerente ao classificador ponto a ponto, pode, entretanto, diminuir consideravelmente a velocidade de processamento. Dispondo-se de áreas de treinamento suficientes e de recursos computacionais adequados, pode-se realizar a classificação de padrões considerando-se todos os atributos gerados. Quando isso não for possível é necessário, então, escolher, entre os atributos gerados, um subconjunto que minimize a probabilidade de erro, $P(E)$, fixado o número de elementos que podem pertencer ao conjunto.

O número de atributos a ser fixado depende de vários fatores: custo computacional, disponibilidade de amostras de treinamento, limitações físicas, precisão requeridas, qualidade dos extratores, e classes utilizadas. O relacionamento existente entre esses fatores é discutido na Seção 5.3.2.

O método que será utilizado para a escolha dos atributos não usa diretamente a $P(E)$ como critério de escolha dos canais ou atributos mais convenientes, e sim a figura de mérito denominada distância JM (Jeffreys-Matusita) e a sua relacionada distância B (Bhattacharyya) (ver Capítulo 4). Essas figuras de mérito têm uma implementação mais conveniente, limitantes para a $P(E)$ em função da distância B, e expressões simples quando se consideram as funções densidade de probabilidade gaussianas.

A experiência indica que é razoável admitir que o comportamento das classes possa ser descrito por funções densidade gaussianas, conduzindo, além disso a expressões simples para a implementação do classificador.

O classificador utilizado será o de máxima verossimilhança, implantado no Laboratório de Interpretação Automática do INPE sob o nome de MAXVER.

Alguns dos operadores de extração de atributos são transformações lineares e como tal conservam a gaussianidade; o mesmo, porém, não acontece com as transformações não-lineares, podem-se utilizar, no entanto, outras transformações não-lineares subsequentes do tipo reescalonamento não-linear, com o objetivo de recuperar aproximadamente o caráter gaussiano dos resultados (ver Seção 5.3.1). Isto é necessário porque tanto a distância B como o algoritmo de classificação adotam a distribuição gaussiana.

Obtém-se finalmente um conjunto de canais que, considerando um determinado conjunto de classes, pode ser utilizado em classificação de padrões naturais, tendo sido diminuída a $P(E)$, ou seja, a probabilidade de confusão entre os padrões.

Com a utilização do método alguns problemas podem aparecer: 1) demora na escolha de um conjunto de canais convenientes para um dado conjunto de classes; e 2) perda de aparência visual natural.

O uso de informação espacial é uma forma adicional de extrair informação de uma cena. Para aumentar a dimensionalidade intrínseca (ver Seção 5.3.2) é necessário fornecer informação proveniente de outras fontes.

A metodologia apresentada sugere e permite a utilização, quando possível, de dados auxiliares não diretamente extraídos, mas relacionados com a cena original, tais como dados temporais (uso de ce

nas com diferentes datas), geomorfológicas (extraídos de cartas geográficas) ou sócio-econômicas (ver Seção 2.3.5).

Pode aparecer, entretanto, a necessidade de utilizar técnicas de registro de imagens para ajustar devidamente a posição relativa de cenas obtidas em datas diferentes, ou provocar uma determinada deformação em uma imagem com o fito de ajustá-la a um determinado tipo de projeção.

Dados sócio-econômicos, demográficos e outros devem estar organizados em bancos de dados e poderão auxiliar as tarefas que envolvem acompanhamento de fenômenos que variam com o tempo e com aplicações em mapeamento físico, demográfico e outros.

5.2 - O MÉTODO NO CONTEXTO DA LITERATURA

Bastante extensa, embora recente, é a literatura sobre textura e atributos espaciais. Citam-se, a seguir, 5 referências diretamente ligadas ao trabalho:

- 1) O trabalho de Ahuja et alii (1977), que descreve a aplicação de métodos supervisionados e não-supervisionados para segmentação de imagens; tais métodos usam níveis de cinza de pontos da vizinhança como atributos.

O procedimento supervisionado computa uma função discriminante linear e o algoritmo média-k é usado para o procedimento não supervisionado.

A um ponto $I(i,j)$ de uma imagem $M \times N$ é associado o vetor \vec{x} , cujas componentes são o nível de cinza de $I(i,j)$, a média 3×3 e a média 5×5 .

As componentes também podem ser os próprios pontos da vizinhança.

O autor conclui que não se ganha muito em utilizar os pontos da vizinhança em lugar de usar uma média local ou alguma propriedade derivada desses pontos. A técnica é limitada para uso em cenas simples.

O procedimento não supervisionado não deu bons resultados, pois revelou ser muito sensível aos pontos iniciais.

- 2) O trabalho de Schachter et alii (1979), que descreve algumas tentativas para segmentar imagens monocromáticas que detectam agregamentos ("clusters") de certos atributos locais.

Regiões da imagem com mesma faixa de nível de cinza, mas de diferentes texturas, poderão ser discriminadas com o uso de certos atributos locais.

O procedimento básico é plotar o histograma bidimensional (uma das dimensões é um atributo espacial) num espaço também bidimensional (diagrama de espalhamento) e procurar agregar separadamente as regiões mais densas.

Utilizar como um atributo o gradiente ou laplaciano não conduziu a resultado muito bom, pois os valores mais altos se davam nas bordas e não detectavam tanto a textura.

Foi definido o operador HTV, VTV e MTV (ver Seção 2.3.4) para a obtenção de valores uniformes para toda uma região de mesma textura.

A transformada textural introduzida por Haralick (1979) (ver Seção 2.3.1) também foi usada, pois mede a tipicidade de um certo padrão espacial em torno de um ponto.

Os melhores resultados foram obtidos utilizando-se como atributos MTV mediano x média 3 x 3 e tipicidade média x média 3 x 3, comparáveis com o resultado obtido utilizando-se 3 informações espectrais para a mesma cena.

Para melhorar o desempenho o autor sugere a utilização de técnicas de "region growing" e relaxação.

- 3) Iisaka (1979) usou atributos locais obtidos por filtragem para ajudar a classificação de tipos de florestas diferentes.

Conclui que o método é útil para o caso e que há um tamanho ótimo da janela para cada tipo de floresta.

- 4) Logan et alii (1979) sintetizaram um canal a partir do canal 5 do LANDSAT, calculando o desvio padrão em uma janela 3 x 3, e utilizaram esse canal para classificação não supervisionada de áreas florestais.

- 5) O trabalho de Gramenopoulos (1973) relata os resultados de um estudo aplicado a imagens LANDSAT. São empregados 4 atributos espaciais combinados com 3 atributos espectrais para formar um vetor de dimensão 7, que representa uma janela de 32 x 32. Os vetores são classificados usando a regra de máxima verossimilhança. Gramenopoulos usa um algoritmo de agregamento para obter os dados de treinamento para o classificador e conclui que: a utilização de atributos espaciais aumenta a precisão do classificador; as estatísticas variam bastante conforme as estações do ano, e os resultados são aplicáveis a produção de mapas de uso do solo. É feita uma análise dos erros de classificação quando os atributos não têm distribuição gaussiana. Para esse caso são desenvolvidas transformações não-lineares (raiz quadrada e logaritmo neperiano) de tal maneira que os erros são minimizados e as classes ficam com distribuição mais próxima da gaussiana.

Os atributos espaciais foram obtidos examinando-se as Transformadas Discretas de Fourier (TDF) de cada cela e identificando os padrões de cada classe. O autor usa a banda vermelha (canal 5) por que oferece mais informação espacial que as outras bandas. Conclui que somente frequências maiores que 3,5 ciclos por km (1/4 ciclo por "pixel" em imagens LANDSAT) oferecem informação necessária para distinguir diferentes tipos de terreno (conclusão > máscaras curtas) e que existe energia significativa ao longo do eixo vertical de frequência nos pontos de 2,1, 4,2 e 6,3 ciclos por km (1/6, 1/3 e 1/2 ciclos por "pixel" > essa energia aparece devido ao "stripping" - ruído que aparece na imagem devido à diferença entre os sensores do LANDSAT que detectam a radiação numa mesma frequência).

Os quatro atributos espaciais são obtidos: 1) eliminando-se as frequências maiores que 5,9 ciclos por km (ruído) e menores que 3,5 ciclos por km; 2) na restante TDF o maior pico é determinado; 3) a energia no setor com abertura de $\pi/8$ é centrada no pico encontrado e calculada e usada como primeiro atributo; 4) três outros atributos são obtidos de maneira similar em setores distantes de $\pi/4$, $\pi/2$ e $3\pi/4$.

Foi testado um algoritmo heurístico de classificação, usando-se somente os quatro atributos espaciais com resultados considerados razoáveis.

Esses atributos espaciais não são gaussianos; transformações não-lineares aplicadas ao espaço mudam a forma das funções densidade de probabilidade. Para tentar tornar os histogramas simétricos em torno da média, foram usadas funções logarítmicas e raiz quadrada. O autor comenta a classificação de imagens de uma data com estatísticas da mesma imagem observada em outra data. Apresenta também os resultados do uso combinado de atributos espaciais e espectrais. Nesse caso houve também um aumento significativo na precisão geral de classificação. Chega à conclusão também de que um algoritmo de agregamento para servir como fase de treinamento para a classificação de máxima verossimilhança aumenta a precisão do processo.

Comentário final:

Dos trabalhos discutidos, alguns se limitam a analisar um número pequeno de operadores espaciais em processos de classificação não-supervisionada e supervisionada não estatística com baixa dimensionalidade.

Outros, embora utilizem uma maior dimensionalidade e um número maior de operadores espaciais, têm o problema de perda de resolução espacial, pois esses atributos são retirados de janelas quadradas na imagem.

Este trabalho pretende reunir os operadores utilizados por esses autores e sugerir outros possíveis para extrair atributos espaciais, e utilizá-los em processos de classificação ponto a ponto, supervisionada sob hipótese gaussiana (classificação de máxima verossimilhança). A proposição deste trabalho difere basicamente da dos outros autores quando se sugere extrair atributos espaciais associados a cada ponto da imagem, em função de sua vizinhança, e quando se procura torná-los aproximadamente gaussianos, se não o forem, seguidos de um processo de seleção de atributos com a finalidade de escolher o melhor conjunto de atributos. A dimensão desse conjunto é ditada por razões físicas, de disponibilidade limitada de áreas de treinamento e tempo de processamento.

O método prevê também a aplicação conjunta, quando possível, de dados auxiliares, tais como geomorfológicos e temporais.

Normalmente se utilizarão conjuntamente diversos tipos de fpb e fpa; estes para retirar o ruído da informação espectral e tornar as assinaturas espectrais (volume mais frequentemente ocupado pelos pontos de uma dada classe) dos alvos mais bem definidas; aqueles serão utilizados, em geral, para extração de informação de rugosidade em torno do ponto a ser classificado.

5.3 - OBSERVAÇÕES TEÓRICAS SOBRE O MÉTODO

5.3.1 - O TEOREMA CENTRAL DO LIMITE

O clássico teorema central do limite diz que a soma de um grande número de variáveis aleatórias, independentes e identicamente distribuídas, com médias e variâncias finitas, normalizadas para ter média zero e variância 1, tem distribuição aproximadamente gaussiana.

Mais recentemente, Gnedenko and Kolmogorov têm feito pesquisas no sentido de estender a validade do teorema para os casos de variáveis aleatórias dependentes (Parzen, 1960).

Segundo Dubes (1968), as hipóteses de independência e distribuição idênticas são unicamente expedientes matemáticos. Conjuntos de hipóteses mais gerais podem ser estabelecidas, embora com prova mais difícil. Pode-se esperar uma distribuição limitante normal, mesmo que as hipóteses não se conformem exatamente com as condições clássicas.

Quando se usa filtragem não-linear, o resultado não é necessariamente gaussiano. Operações lineares, como médias por exemplo, tendem a gaussianizar o resultado se aplicado em seguida a operações não lineares.

No entanto, como a restrição de independência nem sempre é assegurada, deve-se observar o histograma das áreas de treinamento para checar se não apresenta forte discrepância com a hipótese gaussiana.

Porém, como mencionado na Seção 1.2, métodos de classificação baseados na hipótese gaussiana são robustos, e moderada violação dessa hipótese não vai prejudicar sensivelmente os resultados.

5.3.2 - DIMENSIONALIDADE, PRECISÃO E NÚMERO DE AMOSTRAS

Alguns resultados, já consignados na literatura sobre os fatores que afetam a precisão da classificação, são apresentados para orientar a escolha dos processos utilizados na extração de atributos. (Landgrebe, 1978).

1) A complexidade da medida

É uma medida de quão precisamente é feita uma medição. A complexidade da medida é dada por:

$$cm = k^P$$

onde

k = número de níveis de cinza;

P = número de bandas espectrais.

Espera-se que aumentando a complexidade ou precisão da medida a precisão do classificador aumente, o que nem sempre é verdade.

O uso de um número finito de amostras faz com que não se possa aumentar indefinidamente a complexidade da medida. A partir de uma certa complexidade, fixado o número de amostras, a sensibilidade no cálculo dos parâmetros começa a aumentar e com isso cai a precisão do classificador.

Para que a precisão do classificador aumente com a complexidade é preciso que o número de amostras de treinamento também aumente, o que nem sempre é possível. As curvas de precisão de classificação versus complexidade, fixado o número de amostras, apresenta portanto um máximo.

Mesmo que se dispusesse de um número crescente de amostras, a curva teria uma tendência saturante de maneira tal que os custos computacionais não autorizariam um aumento na complexidade, para alcançar uma tímida melhora na precisão de classificação.

2) O efeito do ruído

É observado que a adição de ruído à imagem afeta mais a classificação de padrões com menor poder discriminatório (classes em confusão).

3) Dimensionalidade Intrínseca

A dimensionalidade intrínseca é o menor número de dimensões que deve ser usado para representar os dados adequadamente.

As imagens LANDSAT têm dimensionalidade de aproximadamente 2, o que pode ser observado fazendo-se a transformação K-L (principais componentes). Para cenas obtidas de avião em 12 canais, demonstra-se que a dimensionalidade intrínseca é de aproximadamente 3. Neste trabalho, como será observado, a utilização dos atributos espaciais aumentará a dimensionalidade intrínseca das cenas do LANDSAT para 3.

Esse e outros experimentos permitiram levantar algumas conclusões a respeito de alguns parâmetros envolvidos em problemas de classificação de imagens.

- i) A resolução espacial, resolução espectral e relação sinal-ruído estão intrinsecamente ligadas de maneira tal que, fixados 2 parâmetros, o terceiro também fica fixado.
- ii) O uso de informação temporal e os auxiliares geomorfológicos e sócio-econômicos podem aumentar a dimensionalidade intrínseca do sistema. Normalmente, nestes casos, é preciso utilizar técnicas de registro de imagens.

- iii) O problema de extração e seleção de atributos é fortemente dependente das classes de interesse.

CAPÍTULO 6

RESULTADOS

Os experimentos foram efetuados utilizando-se uma imagem LANDSAT-C - órbita 78, ponto 27 - de abril de 1978 sobre a área de Ribeirão Preto. Obtiveram-se também imagens de avião sobre a mesma área, o que permitiu escolher as áreas teste e de treinamento com boa precisão.

As classes utilizadas e o número de pontos nas áreas teste e de treinamento são mostrados na Tabela 6.1.

TABELA 6.1

CLASSES USADAS

	CLASSE	NÚMERO DE PONTOS	
		ÁREAS DE TREINAMENTO	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

Nos experimentos 1, 2 e 3 foram utilizados 12 atributos assim distribuídos:

- os atributos de 1 a 4 são os canais originais de 4 a 7 do LANDSAT;
- os atributos de 5 a 8 são obtidos pela convolução dos canais 4 a 7 do LANDSAT pela máscara da Figura 6.1;
- os atributos de 9 a 12 informam sobre a variação ou rugosidade local dos canais originais e são obtidos por diferentes processos, conforme a experiência realizada.

$$\frac{1}{21} \begin{bmatrix} 0 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 0 \end{bmatrix}$$

Fig. 6.1 - Máscara para suavização (5 x 5)

Dos 12 atributos foram escolhidos 2 conjuntos de quatro canais, que constituem a capacidade máxima de manipulação do Imageador Automático I-100 do Laboratório de Tratamento de Imagens Digitais do INPE. Um conjunto segundo o critério de máxima distância JM média entre as distâncias das classes utilizadas, e outro conjunto de 4 atributos segundo o critério de máxima distância JM mínima entre classes estabelecidas.

Os programas elaborados para a execução do presente trabalho, os quais posteriormente servirão para uso normal no Laboratório, serão descritos em publicações posteriores e incluem:

- sistema para seleção de atributos até 12 canais;
- sistema de filtros digitais curtos lineares e não-lineares;
- sistema de composição e reescalamento de imagens;

- programa para o cálculo e "display" do módulo da TDF de filtros digitais curtos;
- nova versão (3) do sistema MAXVER de classificação que permite aquisição e manipulação de áreas teste;
- programa para cálculo de autovalores e autovalores de matrizes de covariância em formatos MAXVER e COV (Seleção de atributos).

6.1 - 1ª EXPERIÊNCIA

Para a primeira experiência os atributos de 9 a 12 foram obtidos a partir dos canais originais, utilizando-se o operador variação total (Equação 2.28). Os canais resultantes desta operação foram suavizados pela convolução com a máscara da Figura 6.1.

Os canais selecionados pelos 2 critérios mencionados, considerando-se todas as 6 classes, coincidiram e são os seguintes (Tabela 6.2).

TABELA 6.2

SELEÇÃO 1

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
5	Média (5 x 5) do canal 4 do LANDSAT
8	Média (5 x 5) do canal 7 do LANDSAT
9	Variação suavizada do canal 4 do LANDSAT
10	Variação suavizada do canal 5 do LANDSAT

Limite superior para $P(\epsilon) = 2.82\%$ (Lainiotis, 1979).

Para comprovar a eficiência do método, foram obtidas as matrizes de classificação para as áreas de treinamento e teste. Essas matrizes apresentam de forma sucinta o resultado da classificação de áreas de classificação conhecida. Os erros cometidos ao classificar incorretamente pontos de identidade conhecida permitem estimar os erros envolvidos.

A partir dessas matrizes foi possível obter o "desempenho médio" (D_m), definido como a média da percentagem de classificação correta de cada área de treinamento ou teste, ponderada pelo número de pontos de cada uma. A "abstenção média" (A_m) foi definida como sendo a percentagem média de abstenção das áreas, ponderada pelo número de pontos das áreas. A "confusão média" (C_m) foi definida como sendo o erro médio ponderado pelo número de pontos das áreas.

As Tabelas 6.3 e 6.4 apresentam as matrizes de classificação para as áreas de treinamento e teste, com a utilização dos canais originais para o limiar de classificação = 5 ($L=5$) (Velasco et alii, 1978).

As tabelas 6.5 e 6.6 apresentam as matrizes de classificação para as áreas de treinamento e teste para os canais selecionados nesta experiência (Seleção 1).

TABELA 6.3

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS DE TREINAMENTO
UTILIZANDO-SE CANAIS ORIGINAIS COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N*	1	2	3	4	5	6
1. Cana	0,8	97,6	0,0	1,6	0,0	0,0	0,0
2. Cananova	0,5	0,0	92,1	0,0	0,0	7,4	0,0
3. Pasto	0,0	0,0	0,0	100,0	0,0	0,0	0,0
4. Água	0,0	0,0	0,0	4,2	95,8	0,0	0,0
5. Infraestrutura	0,0	0,0	8,3	0,0	9,7	81,9	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0
Desempenho Médio Dm = 95,1%							
Abstenção Média Am = 0,4%							
Confusão Média Cm = 4,5%							

* N = não-classificado

TABELA 6.4

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS TESTE, UTILIZANDO-SE
CANAIS ORIGINAIS COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N*	1	2	3	4	5	6
1. Cana	0,9	97,2	0,0	1,9	0,0	0,0	0,0
2. Cananova	0,0	0,0	79,6	0,0	0,0	20,4	0,0
3. Pasto	13,9	22,2	0,0	50,0	0,0	0,0	13,9
4. Água	2,8	0,0	0,0	11,1	86,1	0,0	0,0
5. Infraestrutura	16,7	0,0	22,2	16,7	5,6	38,9	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0

Desempenho médio $D_m = 77,8\%$
Abstenção média $A_m = 4,5\%$
Confusão média $C_m = 17,7\%$

* N = não-classificado

TABELA 6.5

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS DE TREINAMENTO, UTILIZANDO-SE OS CANAIS DA SELEÇÃO NÚMERO 1, COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N*	1	2	3	4	5	6
1. Cana	0,0	100,0	0,0	0,0	0,0	0,0	0,0
2. Cana nova	0,0	0,0	99,1	0,0	0,0	0,9	0,0
3. Pasto	0,9	0,0	0,0	99,1	0,0	0,0	0,0
4. Água	1,4	0,0	0,0	0,0	98,6	0,0	0,0
5. Infraestrutura	0,0	0,0	0,0	0,0	0,0	100,0	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0
Desempenho médio $D_m = 99,5\%$ Abstenção média $A_m = 0,3\%$ Confusão média $C_m = 0,3\%$							

* N = não-classificado

TABELA 6.6

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS TESTE, UTILIZANDO-SE OS CANAIS DA SELEÇÃO NÚMERO 1, COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N	1	2	3	4	5	6
1. Cana	0,0	100,0	0,0	0,0	0,0	0,0	0,0
2. Cana nova	0,0	0,0	100,0	0,0	0,0	0,0	0,0
3. Pasto	29,2	20,8	0,0	48,6	1,4	0,0	0,0
4. Água	5,6	0,0	0,0	2,8	86,1	5,6	0,0
5. Infraestrutura	80,6	0,0	11,1	0,0	0,0	8,3	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0

Desempenho médio $D_m = 81,1\%$
Abstenção média $A_m = 13,1\%$
Confusão média $C_m = 5,8\%$

Por esses resultados, pode-se notar uma melhoria no desempenho médio e uma diminuição na confusão média tanto para áreas teste quanto para as de treinamento.

Convém notar que o limite teórico para a P(E) não foi ultrapassado.

Nota-se, no entanto, que houve uma maior abstenção e diminuição da porcentagem de classificação correta para as classes pasto e infraestrutura, nas matrizes de classificação para áreas teste, embora o desempenho médio seja melhor. Isso ocorreu porque tais áreas teste estavam muito próximas de regiões de transição entre classes diferentes, o que fez com que os operadores médias tendessem a misturar as classes dos "pixels" e os operadores detetores de rugosidade tendessem a dar valores atipicamente altos nas regiões de transição, levando esses "pixels" a não serem classificados.

Selecionando-se desses doze canais, outros, não considerando a classe 5 por ter sido muito prejudicada pela localização difícil das áreas de teste e treinamento (essa classe não é muito extensa) obteve-se a seleção 2 (Tabela 6.7).

TABELA 6.7

SELEÇÃO 2

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
6	Média (5 x 5) do canal 5 do LANDSAT
7	Média (5 x 5) do canal 6 do LANDSAT
8	Média (5 x 5) do canal 7 do LANDSAT
11	Varição amaciada do canal 6 do LANDSAT

Os resultados das seleções 1 e 2 para os limiares de classificação 5 e 6 são sumarizados nas Tabelas 6.8 (áreas de treinamento) e 6.9 (áreas teste).

TABELA 6.8

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM
OPERADOR VARIAÇÃO SEM REESCALONAMENTO
(ÁREAS DE TREINAMENTO)

	CANAIS ORIGINAIS		SELEÇÃO 1		SELEÇÃO 2	
	5,0	6,0	5,0	6,0	5,0	6,0
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	95,1	95,2	99,5	98,4	99,2	99,6
Am (%)	0,4	0,3	0,3	0,8	0,5	0,1
Cm (%)	4,5	4,5	0,3	0,9	0,3	0,3

TABELA 6.9

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM
OPERADOR VARIAÇÃO SEM REESCALOCAMENTO
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 1		SELEÇÃO 2	
	5,0	6,0	5,0	6,0	5,0	6,0
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	81,1	83,8	75,0	79,5
Am (%)	4,5	0,3	13,1	6,6	16,9	7,3
Cm (%)	17,7	19,2	5,8	9,6	7,3	13,1

Observando-se a Tabela 6.8 deduz-se que houve boa diminuição da confusão média, não havendo diferença significativa entre as 2 seleções. Nota-se também que, na 1ª seleção, houve ligeiro aumento da confusão média, passando-se do limiar 5 para 6, devido à classificação de alguns pontos de pasto como cana para a classificação com limiar 6.

A Tabela 6.9 apresenta um resultado que indica que para a seleção 1 (Tabela 6.2) a confusão média caiu para metade, e que a confusão média também diminuiu para a seleção 2 (Tabela 6.7).

6.2 - 2ª EXPERIÊNCIA

Para a 2ª experiência os atributos de 9 a 12 foram obtidos a partir dos originais 4 a 7 do LANDSAT, utilizando-se operador variação total (Equação 2.28).

Nessa experiência procurar-se-á recuperar, pelo menos aproximadamente, o caráter gaussiano dos atributos espaciais gerados.

Para o resultado das operações não-lineares poderia ser aplicado o processo de gaussianização de histograma.

Esse processo, no entanto, é dependente da classe e a gaussianização simultânea não é garantida.

Optou-se por aplicar um reescalonamento por curva do tipo raiz quadrada ajustado aos limites 0-255 (Figura 6.2). Em seguida suaviza-se esse campo pela convolução com a máscara da Figura 6.1.

O reescalonamento por raiz quadrada tem bases empíricas e visa basicamente saturar os valores altos que os operadores de rugosidade têm nas bordas entre regiões e aumentar os níveis de cinza dos pontos com nível de cinza mais baixo que são os mais frequentes.

Sua aplicação é bem mais simples que a gaussianização do histograma.

A aplicação posterior de um fpb. linear preenche os vazios resultantes no histograma, diminui a influência do ruído nesse tipo de operação e o torna mais próximo do modelo gaussiano de histograma, conforme sugere o teorema central do limite.




Fig. 6.2 - Curva de reescalonamento do tipo raiz quadrada.

Os 4 canais selecionados pelo critério de máxima distância JM média são apresentados na Tabela 6.10.

TABELA 6.10

SELEÇÃO 3

NÚMERO DOS CANAIS	DENOMINAÇÃO DAS CLASSES
6	Média (5 x 5) do canal 5 do LANDSAT
7	Média (5 x 5) do canal 6 do LANDSAT
10	Variação total do canal 5 do LANDSAT reescalonado e suavizado
12	Variação total do canal 7 do LANDSAT reescalonado e suavizado

Os 4 canais seleccionados pelo critério de máxima distância JM mínima entre canais estão na Tabela 6.11.

TABELA 6.11

SELEÇÃO 4

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
5	Média (5 x 5) do canal 4 do LANDSAT
8	Média (5 x 5) do canal 7 do LANDSAT
9	Variação total do canal 4 do LANDSAT reescalonado e suavizado
10	Variação total do canal 5 do LANDSAT reescalonado e suavizado

Os índices de desempenho extraídos das matrizes de classificação para as áreas de treinamento e teste, para limiares 5 e 6, seleções 3 e 4, estão nas Tabelas 6.12 e 6.13.

TABELA 6.12

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM
OPERADOR VARIAÇÃO COM REESCALONAMENTO
(ÁREAS DE TREINAMENTO)

	CANAIS ORIGINAIS		SELEÇÃO 3		SELEÇÃO 4	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	95,1	95,2	98,6	99,6	99,6	99,6
Am (%)	0,4	0,3	0,9	0,1	0,0	0,0
Cm (%)	4,5	4,5	0,3	0,3	0,4	0,4

TABELA 6.13

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM
OPERADORES VARIAÇÃO COM REESCALONAMENTO
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 3		SELEÇÃO 4	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	80,8	88,6	82,3	85,1
Am (%)	4,5	0,3	18,4	6,6	12,6	5,8
Cm (%)	17,7	19,2	0,8	4,8	5,1	9,1

Comparando-se as Tabelas 6.8 e 6.12 observa-se que se obtêm menores erros e abstenções quando se usa reescalonamento; o fato de os pontos não-classificados passarem a ser classificados corretamente quando se aumenta o limiar de classificação sugere uma separabilidade mais aguda no caso de reescalonamento, por causa da melhor aproximação à hipótese gaussiana.

Esta hipótese é reforçada comparando-se as Tabelas 6.9 e 6.13 nas quais nota-se que, para o caso de reescalonamento, há sensível redução na confusão média para a terceira seleção de canais.

A observação direta das matrizes de classificação para o caso de reescalonamento permitiu também chegar à conclusão de que o reescalonamento ajuda a evitar não-classificação demasiada para a classificação de áreas próximas a fronteira entre regiões, pois tendem a saturar os valores altos desses operadores quando atuam na vizinhança entre classes diferentes. Basta observar, por exemplo, a matriz de classificação para as áreas teste da seleção 3 (Tabela 6.14) e compará-la com o resultado da classificação de infraestrutura da Tabela 6.6.

TABELA 6.14

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS TESTE, UTILIZANDO-SE
OS CANAIS DE SELEÇÃO 3, COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N*	1	2	3	4	5	6
1. Cana	0,0	98,1	0,0	1,9	0,0	0,0	0,0
2. Cananova	0,0	0,0	100,0	0,0	0,0	0,0	0,0
3. Pasto	51,4	0,0	0,0	48,6	0,0	0,0	0,0
4. Água	33,3	0,0	0,0	2,8	63,9	0,0	0,0
5. Infraestrutura	66,7	0,0	0,0	0,0	0,0	33,3	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0
Desempenho Médio DM = 80,8%							
Abstenção Média AM = 18,4%							
Confusão Média CM = 0,8%							

* N = não-classificado

6.3 - 3ª EXPERIÊNCIA

Para a 3ª experiência os atributos de 9 a 12 foram obtidos a partir dos originais 4 a 7 do LANDSAT, utilizando-se o operador laplaciano (Equação 2.36).

Faz-se o reescalonamento do campo laplaciano por uma curva do tipo raiz quadrática (Figura 6.2) e, em seguida, esse campo foi suavizado pela convolução com a máscara da Figura 6.1.

Os 4 canais selecionados pelo critério de máxima distância JM média são apresentados na Tabela 6.15.

TABELA 6.15

SELEÇÃO 5

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
4	Média (5 x 5) do canal 4 do LANDSAT
5	Média (5 x 5) do canal 5 do LANDSAT
6	Média (5 x 5) do canal 6 do LANDSAT
10	Laplaciano do canal 5 do LANDSAT reescalonado e suavizado

Limite superior para $P(\epsilon) = 4,5\%$.

Os 4 canais selecionados pelo critério de máxima distância JM mínima entre pares de canais estão na Tabela 6.16.

TABELA 6.16

SELEÇÃO 6

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
5	Média (5 x 5) do canal 4 do LANDSAT
7	Média (5 x 5) do canal 6 do LANDSAT
9	Laplaciano do canal 4 do LANDSAT reescalonado e suavizado
10	Laplaciano do canal 5 do LANDSAT reescalonado e suavizado

Os índices de desempenho médio extraídos das matrizes de classificação para as áreas de treinamento e teste, para limiares 5 e 6, seleções 5 e 6, estão nas Tabelas 6.17 e 6.18.

TABELA 6.17

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM OPERADORES
LAPLACIANO REESCALONADOS E SUAVIZADOS
(ÁREAS DE TREINAMENTO)

	CANAIS ORIGINAIS		SELEÇÃO 5		SELEÇÃO 6	
Límiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	95,1	95,2	99,4	99,5	99,0	99,2
Am (%)	0,4	0,3	0,4	0,0	0,3	0,0
Cm (%)	4,5	4,5	0,3	0,5	0,8	0,8

O resultado da Tabela 6.17 demonstra haver sensível diminuição da confusão média. Se se compararem as Tabelas 6.17 com as Tabelas 6.12 e 6.8 observar-se-á pouca mudança entre elas, todas com boa melhora com relação aos resultados obtidos com os canais originais.

Maiores diferenças são encontradas quando se analisam as Tabelas 6.9, 6.13 e 6.18, referentes às áreas teste, onde se observa certa vantagem para a terceira seleção sobre as outras, o que significa que para essa seleção conseguiu-se maior acuidade na definição das classes utilizadas.

TABELA 6.18

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM OPERADORES
LAPLACIANO REESCALONADOS E SUAVIZADOS
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 5		SELEÇÃO 6	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	82,8	85,9	82,1	85,6
Am (%)	4,5	0,3	13,1	5,1	9,6	1,0
Cm (%)	17,7	19,2	4,0	9,1	8,3	13,4

6.4 - 4ª EXPERIÊNCIA

Observando-se as experiências anteriores, nota-se que os canais originais não são escolhidos em nenhuma ocasião. Isto sugere que não é necessário considerar esses canais, sendo possível substituí-los por outros canais filtrados.

Coletando-se os canais mais frequentemente escolhidos nas experiências anteriores e usando-se outros três canais filtrados pela máscara da Figura 6.3 (suavizados), obtêm-se os seguintes atributos a partir dos canais originais.

- os atributos de 1 a 3 são os canais 4 a 6 do LANDSAT, suavizados pela máscara da Figura 6.3;
- os atributos de 4 a 6 são os canais 4 a 6 do LANDSAT, suavizados pela máscara da Figura 6.1 (média em região 5 x 5);

- os atributos de 7 a 9 são os canais de variação total dos canais 4 a 6 do LANDSAT, reescalados e suavizados pela máscara da Figura 6.1;
- os atributos de 10 a 12 são os canais módulo do laplaciano dos canais 4, 5 e 7 do LANDSAT, reescalados e suavizados pela máscara da Figura 6.1.

$$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Fig. 6.3 - Máscara 3 x 3 de suavização.

Selecionando-se também para esse caso 4 canais, obtiveram-se as seguintes seleções segundo os critérios de máxima distância JM média (Tabela 6.19) e máxima distância JM mínima (Tabela 6.20).

TABELA 6.19

SELEÇÃO 7

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
2	Média (5 x 5) do canal 5 do LANDSAT
3	Média (5 x 5) do canal 6 do LANDSAT
11	Variação total do canal 5 do LANDSAT reescalado e suavizado
12	Variação total do canal 7 do LANDSAT reescalado e suavizado

TABELA 6.20

SELEÇÃO 8

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
2	Média (3 x 3) do canal 5 do LANDSAT
4	Média (5 x 5) do canal 4 do LANDSAT
6	Média (5 x 5) do canal 6 do LANDSAT
11	Variação total do canal 5 do LANDSAT reescalonado e suavizado

Nota-se que a seleção 7 é a mesma que a seleção 3 da 2ª experiência. Houve diferença somente com relação aos canais escolhidos segundo o critério de máxima distância JM mínima (seleção 8).

Os índices de desempenho médio extraídos das matrizes de classificação para as áreas de treinamento e teste estão nas Tabelas 6.21 e 6.22.

TABELA 6.21

ÍNDICES DE DESEMPENHO PARA AS SELEÇÕES 7 E 8
(ÁREAS DE TREINAMENTO)

	CANAIS ORIGINAIS		SELEÇÃO 7		SELEÇÃO 8	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	95,1	95,2	98,6	99,6	96,6	96,7
Am (%)	0,4	0,3	0,9	0,1	0,1	0,0
Cm (%)	4,5	4,5	0,3	0,3	3,3	3,3

TABELA 6.22

ÍNDICES DE DESEMPENHO PARA AS SELEÇÕES 7 E 8
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 7		SELEÇÃO 8	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	80,8	88,6	84,3	84,3
Am (%)	4,5	0,3	18,4	6,6	2,0	0,0
Cm (%)	17,7	19,2	0,8	4,8	13,6	15,7

Observou-se que os canais módulo do laplaciano não foram escolhidos, o que indica que o operador variação é mais eficiente em extrair informação espacial, conclusão essa reforçada quando se compararam os índices de desempenho da 2ª e 3ª experiência.

A seleção 8 inclui um canal média em região 3 x 3, mas os índices de desempenho não foram bons, sugerindo que os operadores médias em região 5 x 5 são mais eficientes.

Conclui-se portanto que não se ganha nada, neste caso, em incluir as médias em região 3 x 3, bem como canais laplacianos, confirmando-se a conclusão de que a melhor seleção que deve ser usada é a 3ª (ou 7ª).

6.5 - COMENTÁRIOS GERAIS

Os resultados demonstram 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.

O campo classificado mostrou-se mais homogêneo (compare a Figura 6.4 com a Figura 6.5), havendo uma região de não classificação na fronteira entre campos diferentes. Isso ocorre devido ao fato de os detetores de rugosidade darem valores atipicamente altos nas regiões de transição, já que estes também podem ser utilizados como detetores de bordas. O método desenvolvido permitiu então detectar regiões de classificação normalmente confusas e não classificá-las, em vez de classificá-las erradamente.



Fig. 6.4 - Imagem classificada com canais originais.




Fig. 6.5 - Imagem classificada com canais da seleção 3.

A utilização do reescalonamento mostrou-se benéfica, pois permitiu aproximar mais o comportamento das classes da hipótese gaussiana.

Observou-se também um aumento na dimensionalidade intrínseca para 3 ou mais canais, bastando observar como exemplo os autovalores normalizados que indicam a distribuição da informação entre os 4 canais principais, (Tabela 6.23) conseguidos pela transformação K-L, baseada nas matrizes de covariância das classes utilizando-se os 12 atributos da 3ª experiência (Tabela 6.11). Esse aumento da dimensionalidade intrínseca se deve ao uso da informação espacial.

TABELA 6.23

DISTRIBUIÇÃO DA INFORMAÇÃO ENTRE CANAIS PRINCIPAIS PARA 3 CLASSES,
USANDO-SE MATRIZ DE COVARIÂNCIA DE ORDEM 4 SOMENTE COM CANAIS
ORIGINAIS E A MATRIZ DE COVARIÂNCIA DE ORDEM 12
COM OS CANAIS DA EXPERIÊNCIA 3

CLASSE	DIMENSÃO	AUTOVALOTES NORMALIZADOS (%)				TOTAL
Cana	4	75,95	13,42	7,73	2,8	100,00
	12	39,87	22,76	13,50	11,51	87,64
Cana nova	4	81,77	11,48	5,88	4,41	100,00
	12	36,80	31,47	15,07	7,93	91,27
Pasto	4	71,92	15,17	9,81	3,09	100,00
	12	47,15	19,92	16,98	6,69	90,74

Um resultado que deve ser notado é a não-seleção de canais originais em nenhuma das experiências, inclusive nas escolhas seguintes em ordem decrescente de prioridade, conforme o critério de seleção utilizado. Isto sugere que não é necessário utilizar em nenhum caso os canais originais, colocando nos seus lugares outros canais especiais, ou utilizar somente oito atributos para obter maior rapidez na obtenção dos 4 melhores canais.

Os resultados apresentados demonstram que o método pode ser útil na resolução de diversos problemas de classificação de tipos de terreno em sensoriamento remoto.

6.6 - SUGESTÕES PARA FUTURAS PESQUISAS

Estudos de outros operadores para extração de atributos de rugosidade.

Estudo de operadores de suavização não-lineares para tentar diminuir o efeito de "borramento" na fronteira entre classes.

Estudo da influência da dimensão das máscaras na eficiência do método.

Estudos para analisar mais profundamente o erro de classificação nas fronteiras.

Possibilidade de uso de detectores de linha para utilização em Geologia.

Investigação para determinar a ótima curva de reescalonamento para um dado conjunto de classes e operadores.

Utilização conjugada com informação temporal e outros dados auxiliares.

Estudos da utilização de rotação espectral antes da extração de atributos espaciais.

Utilização do método com outros tipos de classificadores supervisionados e não-supervisionados. Um método supervisionado determinístico possível de ser utilizado é o método multicélula disponível no sistema I-100 de classificação de padrões. Esse método permite adquirir uma assinatura espectral para o objeto que se aproxima melhor da sua assinatura real, desde que se tenha um grande número de amostras de treinamento.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDOU, I.E.; PRATT, W.K. Quantitative design and evaluation of enhancement thresholding edge detectors. *Proceedings of the IEEE*, 67(5):753-763, May 1979.
- AHUJA, N.; DAVIS, L.S.; HARALICK, R.M.; PANDA, D.P. *Image segmentation based on local gray level patterns*. Maryland Md., University of Maryland, 1977. (TR 551).
- CHEN, C. H. *Statistical pattern recognition*, Rochele Park, NJ, Hayden, 1973.
- COLEMAN, G.B.; ANDREWS, H.C. Image segmentation by clustering. *Proceedings of the IEEE*, 67(5) May 1979.
- DUBES, R.C. *The theory of applied probability*. Englewood Cliffs, NJ, Prentice Hall, 1968.
- DUDA, R.O.; HART, P.E. *Pattern classification and scene analysis*. New York, NY, John Wiley, 1973.
- GENERAL ELECTRIC (GE). *User manual*. Daytona Beach, FL, 1975.
- GNEDENKO, B.V.; KOLMOGOROV, A.N. *Limit distribution for sums of independent random variables*. Reading MA, Addison-Wesley, 1954.
- GRAMENOPOULOS, N. Automatic thematic mapping and change detection of ERTS-1 images. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3. Washington, DC, 1973. *Proceedings*. Washington, NASA, 1974. v. 1B, p. 1845-1875.
- HARALICK, R.M. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5):786-804, May 1979. Survey.
- HARALICK, R.M.; SHAMMUGAN, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMS-3(6):610-621, Nov. 1973.
- IISAKA, J. Texture analysis by space filter and applications to forestype classification. In: ANNUAL SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA, 5., West Lafayette, IN, 1979. *Proceedings*. New York, IEEE, c 1977. p. 392-393.

- LAINIOTIS, D.G. A class of upper bounds on probability for multihypotheses pattern recognition. *IEEE transactions on Information Theory*. IT-15:(6):730-731, Nov. 1979. Correspondence.
- LANDGREBE, D.A. Useful information from multispectral image data: another look. In: SWAIN, P.H.; DAVIS, S.H., eds. *Remote sensing the quantitative approach*. New York, NY, MacGraw Hill, 1978.
- LOGAN, T.L.; STRABLER, A.H. Use of a standart deviation based texture channel for LANDSAT classification of forest strata. In: ANNUAL SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA, 5., West Lafayette, IN, 1979. Proceedings. New York, IEEE, c 1979.
- PANDA, D.P. *Statistical analysis of some edge operators*. Maryland, MD, University of Maryland, 1977. (Tech. rep. 558).
- PARZEN, E. *Modern probability theory and its aplications*. New York, NY, John Wiley, 1960.
- PRADO, L.O.C.; CORTEZ, I.R. *Computação digital de operadores gradiente e laplaciano de imagens do sistema I-100*. São José dos Campos, INPE, fev. 1976. (INPE-806-NTI/043).
- PRATT, W.K. *Digital Image Processing*. New York, NY, Wiley-Interscience, 1978.
- PRATT, W.K.; FAUGERAS, O.D. Decorrelation methods of texture feature extration. In: ADREWS, H.C.; PRATT, W.K. *Image understanding research*; semiannual technical report. Los Angeles, CA, Univ. of Southern California, IPI, 1979. p. 3-17. (USCIPI Report 860)
- 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, Jan. 1979.
- SWAIN, P.H. Fundamentals of pattern recognition in remote sensing. In: SWAIN, P.H.; DAVIS, S.H., eds. *Remote sensing - The quantitative approach*. New York, NY, McGraw-Hill, 1978.
- TUKEY, J.W. *Exploratory data analysis*. New York, NY, Addison Wesley, 1977.

VELASCO, F.R.D.; PRADO, L.O.C.; SOUZA, R.C.M. *Sistema Maxver: manual do usuário*. São José dos Campos, INPE, julho 1979. (INPE-1315-NTI/110).

WELCH, J.R.; SALTER, K.G. A context algorithm for pattern recognition and image interpretation, *IEEE Transactions on Systems Man and Cybernetics*, SMC-6(1):24-30, Jan. 1976.

APÊNDICE A

BIBLIOGRAFIA COMPLEMENTAR

- FUKUNAGA, K. *Introduction to statistical pattern recognition*. New York, NY, Academic, 1972.
- GREEN, J.R.; MARGERISON, D. *Statistical treatment of experimental data*. Amsterdam, Elsevier, 1978.
- GONZALEZ, R.C.; WINTZ, P. *Digital Image Processing*. Reading MA, Addison-Wesley, 1977.
- O'FILHO, E.F.; MASCARENHAS, N.D.A.; SONNENBURG, C.R. *Classificação de Imagens Multiespectrais através de características de textura*. São José dos Campos, INPE, maio, 1980. (INPE-1734-RPE/134).
- ROSENFELD, A.; KAK, A.C. *Digital picture processing*. New York, NY, Academic, 1976.
- WESZKA, J.; DYER, C.; ROSENFELD, A. A comparative study of texture measures of terrain classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMS-6(4):269-285, Ap. 1976.

TABELA 6.22

ÍNDICES DE DESEMPENHO PARA AS SELEÇÕES 7 E 8
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 7		SELEÇÃO 8	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	80,8	88,6	84,3	84,3
Am (%)	4,5	0,3	18,4	6,6	2,0	0,0
Cm (%)	17,7	19,2	0,8	4,8	13,6	15,7

Observou-se que os canais módulo do laplaciano não foram escolhidos, o que indica que o operador variação é mais eficiente em extrair informação espacial, conclusão essa reforçada quando se compararam os índices de desempenho da 2ª e 3ª experiência.

A seleção 8 inclui um canal média em região 3 x 3, mas os índices de desempenho não foram bons, sugerindo que os operadores médias em região 5 x 5 são mais eficientes.

Conclui-se portanto que não se ganha nada, neste caso, em incluir as médias em região 3 x 3, bem como canais laplacianos, confirmando-se a conclusão de que a melhor seleção que deve ser usada é a 3ª (ou 7ª).

6.5 - COMENTÁRIOS GERAIS

Os resultados demonstram 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.

O campo classificado mostrou-se mais homogêneo (compare a Figura 6.4 com a Figura 6.5), havendo uma região de não classificação na fronteira entre campos diferentes. Isso ocorre devido ao fato de os detetores de rugosidade darem valores atipicamente altos nas regiões de transição, já que estes também podem ser utilizados como detetores de bordas. O método desenvolvido permitiu então detectar regiões de classificação normalmente confusas e não classificá-las, em vez de classificá-las erradamente.




Fig. 6.4 - Imagem classificada com canais originais.

TABELA 6.23

DISTRIBUIÇÃO DA INFORMAÇÃO ENTRE CANAIS PRINCIPAIS PARA 3 CLASSES,
USANDO-SE MATRIZ DE COVARIÂNCIA DE ORDEM 4 SOMENTE COM CANAIS
ORIGINAIS E A MATRIZ DE COVARIÂNCIA DE ORDEM 12
COM OS CANAIS DA EXPERIÊNCIA 3

CLASSE	DIMENSÃO	AUTOVALOTES NORMALIZADOS (%)				TOTAL
Cana	4	75,95	13,42	7,73	2,8	100,00
	12	39,87	22,76	13,50	11,51	87,64
Cana nova	4	81,77	11,48	5,88	4,41	100,00
	12	36,80	31,47	15,07	7,93	91,27
Pasto	4	71,92	15,17	9,81	3,09	100,00
	12	47,15	19,92	16,98	6,69	90,74

Um resultado que deve ser notado é a não-seleção de canais originais em nenhuma das experiências, inclusive nas escolhas seguintes em ordem decrescente de prioridade, conforme o critério de seleção utilizado. Isto sugere que não é necessário utilizar em nenhum caso os canais originais, colocando nos seus lugares outros canais especiais, ou utilizar somente oito atributos para obter maior rapidez na obtenção dos 4 melhores canais.

Os resultados apresentados demonstram que o método pode ser útil na resolução de diversos problemas de classificação de tipos de terreno em sensoriamento remoto.

6.6 - SUGESTÕES PARA FUTURAS PESQUISAS

Estudos de outros operadores para extração de atributos de rugosidade.





Fig. 6.5 - Imagem classificada com canais da seleção 3.

A utilização do reescalonamento mostrou-se benéfica, pois permitiu aproximar mais o comportamento das classes da hipótese gaussiana.

Observou-se também um aumento na dimensionalidade intrínseca para 3 ou mais canais, bastando observar como exemplo os autovalores normalizados que indicam a distribuição da informação entre os 4 canais principais, (Tabela 6.23) conseguidos pela transformação K-L, baseada nas matrizes de covariância das classes utilizando-se os 12 atributos da 3ª experiência (Tabela 6.11). Esse aumento da dimensionalidade intrínseca se deve ao uso da informação espacial.

1. Publicação nº <i>INPE-2315-TDL/078</i>	2. Versão	3. Data <i>Fev., 1982</i>	5. Distribuição <input type="checkbox"/> Interna <input checked="" type="checkbox"/> Externa <input type="checkbox"/> Restrita
4. Origem <i>DRH-DSR</i>	Programa <i>FRH/CAP</i>		
6. Palavras chaves - selecionadas pelo(s) autor(es) <i>SELEÇÃO DE ATRIBUTOS</i> <i>CLASSIFICAÇÃO DE PADRÕES</i> <i>ATRIBUTOS ESPACIAIS</i> <i>IMAGENS MULTIESPECTRAIS</i>			
7. C.D.U.: <i>528.711.7:621.376.5</i>			
8. Título <i>EXTRAÇÃO DE ATRIBUTOS ESPACIAIS EM</i> <i>IMAGENS MULTIESPECTRAIS</i>		10. Páginas: <i>101</i>	
		11. Última página: <i>A.1</i>	
		12. Revisada por	
9. Autoria <i>Luciano Vieira Dutra</i>		<i>Nelson Mascarenhas</i> <i>Nelson D.D. Mascarenhas</i>	
Assinatura responsável 		13. Autorizada por <i>Parada</i> <i>Nelson de Jesus Parada</i> <i>Diretor</i>	
14. Resumo/Notas <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 imagens multiespectrais 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 de 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>			
15. Observações <i>Tese de Mestrado em Computação Aplicada, aprovada em 06 de março de 1981.</i>			

*Disse-lhe Nicodemos: como po
de um homem nascer, sendo velho?
porventura pode tornar a entrar
no ventre de sua mãe, e nascer?*

*Jesus respondeu: Na verdade,
na verdade te digo que aquele
que não nascer da água e do Es
pírito, não pode entrar no rei
no de Deus.*

*O que é nascido da carne é
carne, e o que é nascido do es
pírito é espírito.*

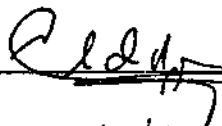
*Não te maravilhes de te ter
dito: Necessário vos é nascer
de novo.*

*O vento assopra onde quer, e
não sabes donde vem, nem para
onde vai; assim é todo aquele
que é nascido do Espírito.*

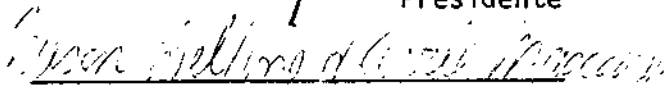
(Jo 3, 4-8)

Aprovada pela Banca Examinadora
em cumprimento dos requisitos exigidos
para a obtenção do Título de Mestre em
Computação Aplicada


Dr. Celso de Renna e Souza


Presidente

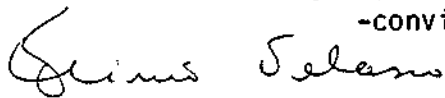
Dr. Nelson Delfino D'Ávila Mascarenhas


Orientador

Dr. Claudio Roland Sonnenburg


Membro da Banca
-convidado-

Dr. Flávio Roberto Dias Velasco


Membro da Banca

Luciano Vieira Dutra


candidato

São José dos Campos, 06 de março de 1981

AGRADECIMENTOS

O trabalho apresentado não seria possível sem a valiosa colaboração do meu orientador Dr. Nelson D.A. Mascarenhas. Estendo meus agradecimentos a Ricardo C.M. de Souza pela confecção da subrotina de projeção de figuras de 3 dimensões, a José C. Moreira por alterações que foram necessárias ao Sistema MAXVER; a Fernando A.M. Ii pela confecção do sistema de seleção de atributos e cálculo de autovalores e autovetores; a Edson A. Ribeiro pela confecção de diversos filtros; e finalmente a Solange B.M. de Oliveira e Cláudio C.F. Barbosa pela ajuda que me prestaram na confecção de outros programas auxiliares.

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 although the use of nonlinear filters does not guarantee the normality of the resulting features. Therefore, nonlinear 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.

SUMÁRIO

	<u>Pág.</u>
LISTA DE FIGURAS	<i>xi</i>
LISTA DE TABELAS	<i>xiii</i>
<u>CAPÍTULO 1 - INTRODUÇÃO</u>	1
1.1 - O problema de classificação de padrões	1
1.2 - Caracterização de imagens digitais	3
1.2.1 - A representação matemática da imagem	3
1.2.2 - Caracterização estatística dos dados de sensoriamento re- moto	4
1.3 - Objetivo do trabalho	6
<u>CAPÍTULO 2 - EXTRAÇÃO DE ATRIBUTOS DE IMAGEM DIGITAL</u>	7
2.1 - Filtragem	7
2.1.1 - Filtragem linear	7
2.1.1.1 - Filtros derivativos	8
2.1.1.2 - Detecção de linhas e manchas	11
2.1.1.3 - Médias	12
2.1.1.4 - Filtros mistos	12
2.1.2 - Filtragem não linear	18
2.1.2.1 - Segmentação de imagens	19
2.1.2.2 - Filtragem não-linear para realce de bordas	21
2.1.3 - Discussão sobre a largura das máscaras	25
2.2 - Atributos estatísticos	26
2.2.1 - Função auto-correlação	26
2.2.2 - Detecção estatísticas de bordas	27
2.2.3 - Histograma	27
2.3 - Outros métodos	28
2.3.1 - Coeficientes de transformada digital	28
2.3.2 - Atributos estruturais	28
2.3.3 - Atributos obtidos por modelos especiais	29
2.3.4 - Operadores heurísticos	30
2.3.5 - Atributos extraídos de cenas multiespectrais	32
2.3.6 - Dados auxiliares	33

	<u>Pág.</u>
<u>CAPÍTULO 3 - OS MÉTODOS DE CLASSIFICAÇÃO</u>	35
<u>CAPÍTULO 4 - SELEÇÃO DE ATRIBUTOS</u>	39
4.1 - Objetivo	39
4.2 - Método	39
<u>CAPÍTULO 5 - O MÉTODO PROPOSTO E DISCUSSÕES</u>	43
5.1 - O método	43
5.2 - O método no contexto da literatura	48
5.3 - Observações teóricas sobre o método	53
5.3.1 - O teorema central do limite	53
5.3.2 - Dimensionalidade, precisão e número de amostras	54
<u>CAPÍTULO 6 - RESULTADOS</u>	57
6.1 - 1ª experiência	59
6.2 - 2ª experiência	67
6.3 - 3ª experiência	71
6.4 - 4ª experiência	74
6.5 - Comentários gerais	77
6.6 - Sugestões para futuras pesquisas	80
REFERÊNCIAS BIBLIOGRÁFICAS	83
APÊNDICE A - BIBLIOGRAFIA COMPLEMENTAR	

LISTA DE FIGURAS

	<u>Pág.</u>
1.1 - Sistema de classificação de padrões	2
2.1 - Módulo da TDF do Laplaciano (Equação 2.3a)	10
2.2 - Filtro corta faixa	13
2.3 - Módulo da TDF de um filtro corta-faixa (Equação 2.8)	14
2.4 - Caso especial do realce	15
2.5 - Módulo da TDF caso especial de realce (Equação 2.10)	16
2.6 - Filtro cascata	17
2.7 - Módulo da TDF de filtro cascata (Equação 2.12)	18
2.8 - Filtro Mediano	19
2.9 - Modelo de bordas	21
2.10 - Métodos não-lineares de realce de bordas	21
2.11 - Filtros casados a bordas	24
2.12 - Método estocástico de extração de atributos de textura ...	30
5.1 - Extração de atributos em imagens digitais	44
6.1 - Máscara para suavização (5 x 5)	58
6.2 - Curva de reescalonamento tipo raiz quadrada	68
6.3 - Máscara 3 x 3 de suavização	75
6.4 - Imagem classificada com canais originais	78
6.5 - Imagem classificada com canais da seleção 3	79

LISTA DE TABELAS

	<u>Pág.</u>
6.1 - Classes usadas	57
6.2 - Seleção 1	59
6.3 - Matriz de classificação para áreas de treinamento utilizando-se canais originais com $L = 5$	61
6.4 - Matriz de classificação para áreas teste, utilizando-se canais originais com $L = 5$	62
6.5 - Matriz de classificação para áreas de treinamento, utilizando-se os canais da seleção número 1, com $L = 5$	63
6.6 - Matriz de classificação para áreas teste, utilizando-se os canais da seleção número 1, com $L = 5$	64
6.7 - Seleção 2	65
6.8 - Índices de desempenho para os conjuntos de canais com operador variação sem reescalonamento (áreas de treinamento)	66
6.9 - Índices de desempenho para os conjuntos de canais com operador variação sem reescalonamento (áreas teste)	66
6.10 - Seleção 3	68
6.11 - Seleção 4	69
6.12 - Índices de desempenho para os conjuntos de canais com operador variação com reescalonamento (áreas de treinamento)	69
6.13 - Índices de desempenho para os conjuntos de canais com operador variação com reescalonamento (áreas teste)	70
6.14 - Matriz de classificação para áreas teste, utilizando-se os canais de seleção 3, com $L = 5$	71
6.15 - Seleção 5	72
6.16 - Seleção 6	72
6.17 - Índices de desempenho para os conjuntos de canais com operadores laplaciano reescalados e suavizados (áreas treinamento)	73
6.18 - Índices de desempenho para os conjuntos de canais com operadores laplaciano reescalados e suavizados (áreas teste)	74
6.19 - Seleção 7	75
6.20 - Seleção 8	76
6.21 - Índices de desempenho para as seleções 7 e 8 (áreas de treinamento)	76
6.22 - Índices de desempenho para as seleções 7 e 8 (áreas teste)	77

6.23 - Distribuição da informação entre canais principais para 3 classes, usando-se matriz de covariância de ordem 4 somente com canais originais e a matriz de covariância de ordem 12 com os canais da experiência 3	80
--	----

CAPÍTULO 1

INTRODUÇÃO

1.1 - O PROBLEMA DE CLASSIFICAÇÃO DE PADRÕES

Desde o advento dos computadores digitais, tem havido um constante esforço no sentido de idealizar métodos automáticos, que substituam o homem no trabalho de tomar decisões, muitas vezes monótono e repetitivo, ou que façam essa tarefa de maneira rápida e precisa.

Estudos intensivos de problemas de classificação - ato de associar um objeto físico ou evento a uma das várias categorias 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, podem-se citar: previsão numérica de tempo, diagnóstico de pacientes através da análise de eletrocardiogramas e raios X, reconhecimento de assinaturas escritas à mão, de impressões digitais etc.

Este caso específico refere-se à partição e classificação das várias áreas ou objetos que compõem uma imagem de recursos naturais.

Um sistema de classificação de padrões pode ser dividido em 2 partes: o extrator de atributos e o classificador (Figura 1.1).

O extrator de atributos tem a função de reduzir os dados naturais medindo um certo conjunto de "atributos" ou "propriedades" que melhor caracterizem os objetivos de interesse. Esses atributos, ou mais precisamente os valores desses atributos, passam por um classificador que avalia as evidências apresentadas segundo determinado critério e associa uma categoria ao objeto.

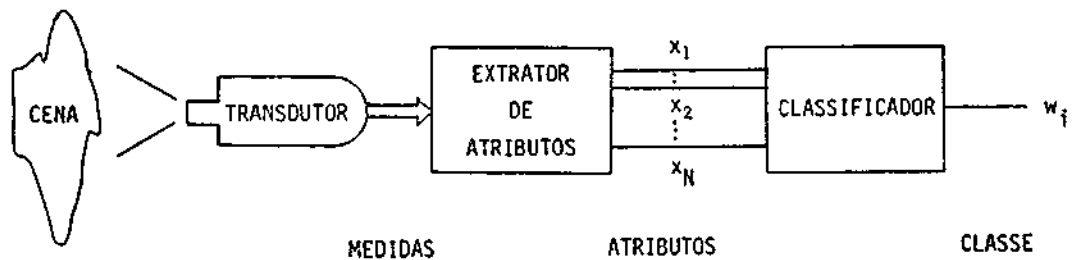


Fig. 1.1 - Sistema de classificação de padrões.

O critério usual para a tarefa de classificação é a minimização dos erros de classificação. Existem várias técnicas, e a escolha de uma em particular depende da natureza do problema, das informações disponíveis a priori e da preferência do projetista.

Discutir-se-ão neste trabalho principalmente as questões de extração de atributos de imagens digitais adquiridas de plataformas remotas, avião ou satélite.

Considera-se que é suficiente definir um conjunto finito de M classes w_1, w_2, \dots, w_M , e que N atributos x_1, x_2, \dots, x_N podem ser extraídos para uso na classificação.

Cada conjunto de N medidas pode ser representado por um vetor N -dimensional $\vec{x} = [x_1 \ x_2 \ \dots \ x_N]$, ou por um ponto no espaço N -dimensional θ .

Normalmente o uso de um grande número de medidas aumenta o custo computacional do processo. Técnicas de seleção de atributos permitem selecionar um número menor de atributos, aumentando assim a eficiência das tarefas computacionais, sem prejudicar demasiadamente a precisão.

Pelo processo denominado treinamento, anterior ao da classificação, o sistema determina, a partir de dados de categoria conhecida, parâmetros usados no algoritmo de classificação, que é denominada "supervisionada".

1.2 - CARACTERIZAÇÃO DE IMAGENS DIGITAIS

1.2.1 - A REPRESENTAÇÃO MATEMÁTICA DA IMAGEM

Uma figura é um objeto plano cujo brilho, cor ou reflexão varia de ponto para ponto. Essa variação pode ser representada por uma função escalar de 2 variáveis, no caso de figuras em preto e branco, e por uma função vetorial, no caso de figuras coloridas. Para facilidade de expressão, define-se cena como sendo uma figura colorida. O vocábulo imagem fica reservado a cada uma das componentes da cena que podem ser consideradas figuras em preto e branco.

O valor da função que representa a imagem denomina-se nível de cinza ou brilho.

Considera-se também que essas funções são analiticamente bem comportadas e tem valores não-negativos e limitados.

Em processamento digital não se usam imagens como funções contínuas. As cenas naturais são normalmente observadas e adquiridas em plataformas remotas, em faixas estreitas centradas em alguns comprimentos de onda convenientes. Em seguida, essas imagens são digitalizadas, ou seja, um processo de amostragem é levado a efeito para extrair da imagem um número discreto de números reais (amostras) a intervalos regulares. Depois um processo de quantização é aplicado às amostras para que assumam um número discreto de valores.

Cada amostra será chamada "pixel" (de "picture element") ou elemento de resolução, e a imagem pode ser considerada uma matriz de números inteiros.

Notação:

$f = [f(i, j)]$ = matriz de imagem.

$f_c(x, y)$ = brilho da imagem contínua no ponto (x, y) .

$f(i, j)$ = nível de cinza da imagem amostrada de $f_c(x, y)$ no ponto $x = i, y = j$ (na prática, $f(i, j)$ representa o nível médio do brilho em uma pequena região centrada em (i, j)).

1.2.2 - CARACTERIZAÇÃO ESTATÍSTICA DOS DADOS DE SENSORIAMENTO REMOTO

Considerando-se a hipótese que admite um caráter de aleatoriedade inerente à natureza, os dados de sensoriamento remoto exibem variações que tendem a obscurecer as diferenças entre as classes de interesse. A análise estatística leva em conta essas variações e, assim, procura reduzir os erros de classificação.

No caso de classificação supervisionada, existe também incerteza na escolha dos padrões de treinamento e superposição destes no espaço de atributos.

Para o tratamento estatístico dos dados de sensoriamento remoto, um histograma para cada classe que ocorre na imagem é obtido, para estimar a função densidade de probabilidade para essa classe.

Estes histogramas podem ser usados diretamente para estimar a probabilidade a posteriori de um dado ponto da imagem pertencer a uma classe determinada, visto que foi observada uma medida \bar{x} .

Se o número de dados for grande, será preciso muita memória de computador para guardar estes histogramas ainda mais de um caso N-dimensional. Acrescente-se também o fato de que, para estimar bem uma função densidade de probabilidade, seria necessário um grande número de padrões de treinamento.

A maneira de aliviar esse problema é adotar para cada histograma a forma de uma função densidade de probabilidade conhecida.

O modelo mais frequentemente usado é o gaussiano multivariável (Swain, 1978), que tem se ajustado adequadamente aos processos probabilísticos envolvidos em um grande número de aplicações em sensoriamento remoto.

Podem-se citar, além disso, outras quatro vantagens de utilizar o modelo gaussiano:

- a) A existência do teorema central do limite e de teoremas relacionados permite considerar a soma de um grande número de variáveis aleatórias (v.a) independentes e identicamente distribuídas como gaussianas (discussão detalhada na Seção 5.3.1).
- b) A distribuição gaussiana é bem conhecida com tratamento matemático fácil e resultados tabelados.
- c) Os classificadores projetados nesta base são robustos, levando-se em consideração que violações até um pouco severas desse modelo não alteram muito a precisão da classificação.
- d) Do ponto de vista prático, classificadores que utilizam o modelo gaussiano oferecem uma boa solução de compromisso entre desempenho e custo.

Duas precauções devem ser tomadas:

- a) É preciso ter cuidado com o número de padrões utilizados para o treinamento. Usando-se n canais para a aquisição da cena de recurso natural, o mínimo número teórico de amostras requerido para estimativa dos parâmetros necessários é $n + 1$. Na prática, esse número deverá estar entre $20n$ e $100n$ para prover boas estimativas.
- b) Os casos em que o histograma da classe se apresentar multimodal não podem ser adequadamente descritos por funções normais. Re

comenda-se subdividir a classe de maneira a associar a cada modo uma função normal.

1.3 - OBJETIVO DO TRABALHO

O objetivo do trabalho é a procura de métodos eficientes e precisos de classificação de padrões para a resolução de problemas de sensoriamento remoto.

Dois dos fatores que influenciam o poder discriminatório de um dado algoritmo de classificação são: o número de atributos que se usam, e os processos usados para a extração de atributos da imagem.

Procurar-se-á desenvolver um método de classificação que utilize atributos espaciais (locais), conjuntamente ou não com dados espectrais.

Os métodos de extração de atributos espaciais basear-se-ão em filtragens linear e não-linear. Será usado um esquema de seleção de atributos, para escolher um subconjunto, entre os atributos escolhidos, que maximize o poder discriminatório.

Supõe-se que as funções densidade de probabilidade condicionais envolvidas são gaussianas. O compromisso entre eficiência de precisão e dimensionalidade será discutido.

CAPÍTULO 2

EXTRAÇÃO DE ATRIBUTOS DE IMAGEM DIGITAL

Um atributo de imagem é uma propriedade que pode ser medida. Os atributos naturais são aqueles que derivam da aparência visual da imagem, como o nível de cinza, bordas e textura. Os artificiais são os obtidos por manipulação e medidas na imagem, como o histograma e a frequência espacial.

Podem-se listar os seguintes processos de extração de atributos em imagens. Dar-se-ã maior atenção aos de maior interesse para o trabalho.

2.1 - FILTRAGEM

Operadores locais, lineares ou não-lineares, podem ressaltar o conteúdo de alta ou baixa frequência de uma imagem, sendo utilizados também para detecção de bordas, linhas ou manchas.

2.1.1 - FILTRAGEM LINEAR

A imagem resultante é obtida a partir da original pela convolução com diversos filtros curtos denominados máscaras, ou seja:

$$[r(i, j)] = [h(i, j)] * [f(i, j)] \quad (2.1)$$

Ou de modo mais simples:

$$r = h * f$$

2.1.1.1 - FILTROS DERIVATIVOS

Existem várias máscaras digitais que aproximam operadores derivativos e que quando aplicadas em imagem, realçam o conteúdo de alta frequência e eliminam, em alguns casos, o nível médio da figura.

Os filtros derivativos são usados normalmente para detecção de bordas. Borda é o nome dado a descontinuidades locais em nível de cinza entre regiões razoavelmente planas. Descontinuidades globais são chamadas segmentos limítrofes.

Outra maneira de considerar a atuação desses filtros é a extração de medidas de microtextura, pois estas medidas procuram ressaltar um ou outro aspecto da relação local entre "pixels".

As máscaras apresentadas a seguir são aproximações digitais dos operadores derivativos contínuos mencionados.

1) Derivadas de primeira ordem

$$\frac{\partial f_c}{\partial x} \cong \Delta_x f(i, j) = f(i, j) - f(i-1, j) \quad (2.2a)$$

$$\frac{\partial f_c}{\partial y} \cong \Delta_y f(i, j) = f(i, j) - f(i, j-1) \quad (2.2b)$$

Em forma matricial 2 x 2, e usando-se a Equação 2.1

$$h_1 = \begin{bmatrix} 1 & 0 \\ -1 & 0 \end{bmatrix} \quad \Delta_x f = h_1 * f \quad (2.2c)$$

$$h_2 = \begin{bmatrix} 1 & -1 \\ 0 & 0 \end{bmatrix} \quad \Delta_y f = h_2 * f \quad (2.2d)$$

Aproximações mais exatas podem ser utilizadas usando-se máscaras de dimensão 3 x 3, como segue:

- Aproximação de Prewit para as primeiras derivadas:

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \quad (2.2e)$$

$$h_2 = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad (2.2f)$$

- Aproximação de Sobel para a primeira derivada:

$$h_1 = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (2.2g)$$

$$h_2 = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (2.2h)$$

Essas máscaras efetuam a rotação de 180 graus para compensar a rotação inerente à convolução.

2) Derivadas de segunda ordem

É possível derivar as seguintes aproximações digitais para o operador laplaciano $\nabla^2(\cdot)$ (Prado e Cortez, 1976):

$$h_1 = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (2.3a)$$

$$h_1 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (2.3b)$$

O filtro laplaciano é claramente passa-alta, como se pode observar na propriedade de transformada de Fourier:

$$TF\{\nabla^2 fc\} = - (2\pi)^2 (u^2 + v^2) Fc(u, v)$$

onde:

$$Fc(u, v) = TF(fc) \quad e$$

$$TF(\nabla^2(.)) = - 2^2\pi^2(u^2 + v^2)$$

Na Figura 2.1 vê-se o módulo da Transformada Discreta de Fourier (TDF) da Equação 2.3a multiplicada por 100. O ponto mínimo da figura corresponde ao valor de nível médio 0.

O operador bi-laplaciano tem a representação

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




Fig. 2.1 - Módulo da TDF do laplaciano (Equação 2.3a).

2.1.1.2 - DETECÇÃO DE LINHAS E MANCHAS

Manchas são regiões pequenas na imagem cuja amplitude difere significativamente de sua vizinhança.

Um conjunto de pontos conectados de uma imagem é uma linha, se quando se percorre um caminho perpendicular a esse conjunto, o nível de cinza diminui e, depois, aumenta (ou vice-versa).

Tanto manchas quanto linhas em uma imagem podem ser detectadas correlacionando-se a imagem com modelos idealizados de linhas e manchas. Linhas de largura 1 podem ser detectadas por:

$$h_1 = \begin{bmatrix} -1 & 2 & -1 \\ -1 & 2 & -1 \\ -1 & 2 & -1 \end{bmatrix} \quad (2.4a)$$

$$h_2 = \begin{bmatrix} -1 & -1 & -1 \\ 2 & 2 & 2 \\ -1 & -1 & -1 \end{bmatrix} \quad (2.4b)$$

$$h_3 = \begin{bmatrix} -1 & -1 & 2 \\ -1 & 2 & -1 \\ 2 & -1 & -1 \end{bmatrix} \quad (2.4c)$$

$$h_4 = \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix} \quad (2.4d)$$

Linhas de largura 2 podem ser detectadas por:

$$h_5 = \begin{bmatrix} -1 & 1 & 1 & -1 \\ -1 & 1 & 1 & -1 \\ -1 & 1 & 1 & -1 \\ -1 & 1 & 1 & -1 \end{bmatrix} \quad (2.4e)$$

Pequenas manchas podem ser detectadas por:

$$h_1 = \begin{bmatrix} -1 & -1 & -1 & -1 \\ -1 & 3 & 3 & -1 \\ -1 & 3 & 3 & -1 \\ -1 & -1 & -1 & -1 \end{bmatrix} \quad (2.5)$$

Deve-se notar que a soma dos pesos dessas máscaras é zero.

2.1.1.3 - MÉDIAS

Médias podem ser realizadas na imagem com o objetivo de diminuir a influência do ruído. Exemplos: 1) eliminação de estrias ("stripping") produzidas nas imagens, devido a diferenças entre sensores diversos colocados a bordo de satélites, mas referentes à mesma banda espectral; 2) linhas saturadas isoladas decorrentes de falha momentânea do sensor. Como o ruído se compõe basicamente de componentes de alta frequência, uma filtragem passa-baixa tende a eliminar o efeito do ruído nas imagens.

As médias, ponderadas ou não, aproximam uma operação de integração na imagem ou filtragem passa-baixa.

Alguns exemplos:

$$h_1 = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (2.6)$$

$$h_2 = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (2.7)$$

2.1.1.4 - FILTROS MISTOS

Filtros corta-faixa podem ser projetados utilizando-se da configuração da Figura 2.2:




Fig. 2.2 - Filtro corta-faixa.

onde h_b é um filtro passa-baixa e h_a é um filtro passa-alta.

Exemplo:

$$h_a = \frac{1}{2} \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

$$h_b = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

$$h_t = h_a + h_b \Rightarrow$$

$$h_t = \frac{1}{18} \begin{bmatrix} 2 & 11 & 2 \\ 11 & -34 & 11 \\ 2 & 11 & 2 \end{bmatrix} \quad (2.8)$$

Média do filtro $(52-34)/18 = 18/18 = 1$.

Nessa configuração, quando se usa um filtro passa-alta que corte totalmente o nível médio da figura, o nível médio da figura resultante permanece igual ao ditado pelo filtro passa-baixa.

Na Figura 2.3 vê-se o módulo da TDF de h_t (filtro resultante). E o valor da cota no ponto θ é 1, ou seja, o filtro não altera o nível médio da imagem.




Fig. 2.3 - Módulo da TDF de um filtro corta-faixa (Equação 2.8).

Um caso especial de operação de realce também pode ser realizada pela configuração paralela (Figura 2.4):




Fig. 2.4 - Caso especial de realce.

Exemplo de aplicação: operação conhecida como "unsharp masking" para eliminar efeito de degradação do tipo difusão na imagem, produzindo uma imagem com bordas realçadas.

$$[g] = [f] - c \cdot \nabla^2 (f) \quad (2.9)$$

Neste caso, h_b , que não altera a imagem, é igual a:

$$h_b = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

Outros filtros mistos podem ter a aplicação que segue: As operações de diferenciação em imagem costumam ampliar consideravelmente o ruído, pois este se compõe basicamente de componentes de alta frequência.

Para contornar o problema, pode-se usar um dos seguintes métodos:

1) Utilizar o esquema da Figura 2.4 com filtro hb passa-baixa. O resultado é diminuir a influência de pontos ruidosos, por causa de realce menos acentuado. Exemplo:

$$g = \frac{1}{6} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix} - \begin{bmatrix} 1 & 1 & 1 \\ 1 & -4 & 1 \\ 1 & 1 & 1 \end{bmatrix} = \begin{bmatrix} -\frac{5}{6} & \frac{26}{6} & -\frac{5}{6} \\ -\frac{5}{6} & \frac{26}{6} & -\frac{5}{6} \\ -\frac{5}{6} & \frac{26}{6} & -\frac{5}{6} \end{bmatrix} \quad (2.10)$$

Na Figura 2.5 vê-se o resultado da TDF da resposta impulsiva g . Esse filtro não altera o nível médio da imagem, ou seja, a cota no ponto θ é 1. Compare esse resultado com o da Figura 2.1. O filtro laplaciano, além de retirar o nível médio da imagem, tem um realce mais agudo para altas frequências.




Fig. 2.5 - Módulo da TDF caso especial de realce (Equação 2.10).

- 2) Utilizar um filtro passa-faixa de maneira a não ampliar demasiadamente as frequências mais altas, através de um conjunto cascata: (Figura 2.6).




Fig. 2.6 - Filtro cascata.

Usando-se os seguintes filtros passa alta e passa baixa, respectivamente:

$$ht = ha * hb = \frac{1}{9} \begin{bmatrix} & 1 & & & \\ 1 & -4 & 1 & & \\ & & & & \\ & & & & \\ & & & & \end{bmatrix} * \begin{bmatrix} 1 & 2 & 1 \\ 2 & 3 & 2 \\ 1 & 2 & 1 \end{bmatrix}$$

ou

$$ht = \frac{1}{15} \begin{bmatrix} 0 & 1 & 2 & 1 & 0 \\ 1 & 0 & -3 & 0 & 1 \\ 2 & -3 & -4 & -3 & 2 \\ 1 & 0 & -3 & 0 & 1 \\ 0 & 1 & 2 & 1 & 0 \end{bmatrix} \quad (2.12)$$

Na Figura 2.7 pode-se observar o módulo da TDF desta máscara em uma matriz 11 x 11. Observe que o ponto 0 tem cota zero.




Fig. 2.7 - Módulo da TDF de filtro cascata (Equação 2.12).

2.1.2 - FILTRAGEM NÃO-LINEAR

A filtragem passa-baixa linear tende a borrar regiões l_i m̃itrofes entre áreas distintas de uma imagem. Para evitar esse efeito, \bar{e} possıvel usar filtros ño-lineares convenientes.

Operadores derivativos não-lineares, em vez de operadores lineares, podem muitas vezes ser os mais indicados para resolver certos tipos de problemas.

2.1.2.1 - SEGMENTAÇÃO DE IMAGENS

São comumente usados para esse fim os filtros passa-baixa não-lineares.

1) Filtro mediano

Este tipo de filtro, introduzido por Tukey (1977), consiste em associar ao ponto central de uma janela $N \times N$ (N ímpar) o nível de cinza intermediário da lista ordenada dos níveis de cinza dos $N \times 2$ pontos da vizinhança.

É útil para eliminar ruídos e rugosidade excessiva, sem espalhar o efeito do ponto ruidoso na vizinhança, como acontece em filtragem passa-baixa linear. Exemplo:




Fig. 2.8 - Filtro mediano.

2) Filtro de modo

O filtro de modo, introduzido por Coleman (1979), computa um histograma em uma janela $N \times N$ e tem por saída o nível de cinza mais frequente na vizinhança.

O efeito deste filtro é substituir cada "pixel" pelo valor mais frequente em uma pequena região centrada nele, removendo-se pequenas variações em brilho; portanto, tende a criar regiões de brilho único.

Este filtro quase não causa perda de resolução porque a sua saída não muda suavemente como numa média, mas abruptamente quando a maioria dos níveis de cinza de uma região passa a ser outra, o que acontece ao cruzar fronteira entre regiões. Podem ocorrer, no entanto, deformações em regiões onde não aparece um nível de cinza claramente predominante.

Para evitar essas deformações, foram introduzidas duas modificações no processo: a primeira é a inclusão de um limiar de frequência para substituição do ponto central pelo mais frequente. Esse problema é mais crítico para janelas maiores. A segunda é a introdução opcional de um processo de conformação das bordas a modelos para bordas, se o limiar de frequência não for atingido. A intenção é promover um "amaciamento" das bordas extraíndo-se ruídos que promovem a descaracterização da borda.

Na Figura 2.9 apresentam-se 2 das 8 bordas teóricas possíveis de acontecer numa região 3×3 .

O ponto central é substituído pela média na região hachurada, mais próxima do valor do ponto, para algum dos 8 possíveis modelos de bordas.

Esse processo pode ser repetido várias vezes, até que se alcance um estado de mínima mudança estipulada.




Fig. 2.9 - Modelos de bordas.

As regiões hachuradas e brancas representam níveis idênticos.

2.1.2.2 - FILTRAGEM NÃO-LINEAR PARA REALCE DE BORDAS

Filtragem não-linear é um dos métodos que podem ser utilizados para: 1) detecção de bordas; 2) extração de atributos especiais e 3) definição de atributos texturais de uma imagem, já que microtextura pode ser considerada como densidade local de microbordas.

Os métodos não-lineares de realce de bordas constituem-se normalmente de várias etapas (Figura 2.10).




Fig. 2.10 - Métodos não-lineares de realce de bordas.

$$g_i(i,j) = f(i,j) * h_i(i,j) \quad (2.13)$$

Inicialmente a imagem \tilde{e} é processada por N operadores li neares ou máscaras que produzem um conjunto de funções derivadas par ciais ou função correlação entre a imagem e um modelo ("template").

Posteriormente, a cada ponto as funções $g_i(i,j)$ serão com binadas, normalmente de uma maneira não-linear, produzindo uma matriz gradiente.

Operações pontuais típicas são: raiz quadrada, máximo en tre funções e soma de módulos. A matriz realçada $[a(i,j)]$ provê uma me dida das discontinuidades no centro da máscara a cada ponto.

Costumam-se distinguir dois tipos principais de métodos: diferenciais e por correlação com modelos ideais.

1) Métodos derivativos

Utilizam na primeira fase os seguintes operadores linea res:

$$h_1 = \begin{bmatrix} -1 & 0 \\ 1 & 0 \end{bmatrix} \quad (2.14a)$$

$$h_2 = \begin{bmatrix} -1 & 1 \\ 0 & 0 \end{bmatrix} \quad (2.14b)$$

- Aproximações simples das primeiras derivadas.

$$h_1 = \begin{bmatrix} 1 & -1 \\ 1 & 0 \end{bmatrix} \quad (2.15a)$$

$$h_2 = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \quad (2.15b)$$

- Operadores de Roberts.

$$h_1 = \begin{bmatrix} 1 & 0 & -1 \\ C & 0 & -C \\ 1 & 0 & -1 \end{bmatrix} \quad (2.16a)$$

$$h_2 = \begin{bmatrix} 1 & C & 1 \\ 0 & 0 & 0 \\ -1 & -C & -1 \end{bmatrix} \quad (2.16b)$$

- Para $C = 1 \Rightarrow$ operador de Prewit

- Para $C = 2 \Rightarrow$ operador de Sobel

$$h = \begin{bmatrix} 0 & 1 & 1 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (\text{Laplaciano})$$

Esses operadores usam uma combinação não-linear, ponto a ponto, para produzir uma matriz realçada do tipo:

$$a(i,j) = ((g_1(i,j))^2 + g_2(i,j)^2)^{1/2} \quad (2.17)$$

$$a(i,j) = |g_1(i,j)| + |g_2(i,j)| \quad (2.18)$$

No caso de imagem obtida pela convolução com a máscara da Equação 2.3a, basta considerar $[a(i,j)]$:

$$a(i,j) = |g(i,j)| \quad (2.19)$$

Apresentam-se algumas observações sobre o operador $| \nabla^2 f(i,j) |$, que é obtido pela Equação 2.19, a qual é aplicada à Equação 2.13, usando-se a Equação 2.3a.

Panda (1977) prova, para o caso contínuo, que o operador $| \nabla^2(.) |$ torna o campo de imagem não-correlacionado, ou seja, o campo

aleatório resultado da operação $|\nabla^2(\cdot)|$ tem função de autocorrelação impulsiva.

Essa propriedade é interessante porque indica que o campo resultante não tem informação espacial e sugere que a informação espacial contida na imagem original foi transformada em informação pontual na imagem resultante.

Além disso, é mais adequada a utilização de campos não-correlacionados em classificadores pontuais.

A orientação da borda a cada ponto é dada por:

$$\theta(i,j) = \arctg(g_2(i,j)/g_1(i,j)) \quad (2.20)$$

2) Correlação com modelos ideais

Operadores por correlação com modelos ideais são conjuntos de máscaras que representam aproximações de bordas ideais em várias direções. A Figura 2.11 apresenta as direções e diferentes aproximações propostas.

$\begin{bmatrix} 1 & 1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & -1 \end{bmatrix}$	$\begin{bmatrix} 1 & -1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & 1 \end{bmatrix}$	"Compass gradient"
$\begin{bmatrix} 3 & 3 & 5 \\ 3 & 0 & 5 \\ 3 & 3 & 5 \end{bmatrix}$	$\begin{bmatrix} 3 & -5 & -5 \\ 3 & 0 & -5 \\ 3 & 3 & 3 \end{bmatrix}$	"Kirsh"
$\begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 1 & -1 & -1 \\ 1 & 0 & -1 \\ 1 & 1 & 0 \end{bmatrix}$	"Nível 3"
$\begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 & -2 \\ 1 & 0 & -1 \\ 2 & 1 & 0 \end{bmatrix}$	"Nível 5"
Posição e1	Posição e2	

Fig. 2.11 - Filtros casados a bordas.

Os modelos denominados nível 3 e nível 5 estão relacionados com os operadores de Prewit e Sobel, respectivamente; neste caso bastam 4 orientações para achar o máximo.

A matriz realçada \bar{e} obtida por:

$$a(i,j) = \max(|g(i,j)|) \quad (2.21)$$

2.1.3 - DISCUSSÃO SOBRE A LARGURA DAS MÁSCARAS

Aumentar a área da máscara significa diminuir a sensibilidade do ruído. No entanto, bordas deslocadas dentro das máscaras contribuem para o gradiente, aumentando a probabilidade de detecção de bordas falsas.

O compromisso entre redução de ruído e sensibilidade de deslocamento de bordas é discutido por Abdou e Pratt (1979). Particularmente na Seção VI.

Máscaras curtas são convenientes para detecção de microtexturas. Padrões compostos de componentes de baixa frequência não influenciam o resultado das máscaras curtas.

Desejando-se medir texturas e macrotexturas, as máscaras devem aumentar de tamanho e contar com o número de pontos compatíveis com a dimensão das estruturas que se quer detectar.

Um estudo de Gramenopoulos (1973) conclui que se podem utilizar máscaras curtas (3 x 3, 4 x 4, 5 x 5) no tratamento de imagens LANDSAT, pois as estruturas de maior interesse têm frequência maior que 1/4 ciclo por "pixel". (Seção 5.2).

2.2 - ATRIBUTOS ESTATÍSTICOS

2.2.1 - FUNÇÃO DE AUTOCORRELAÇÃO

Considere a função de autocorrelação estacionária no "ensemble":

$$K_f(m,n) = E(f(j,k) f(j+m, k+n)) \quad (2.22)$$

definida para os valores $m, n = \pm 1, \pm 2, \dots \pm T$.

Essa função pode ser estimada pela função de autocorrelação espacial

$$A_f(m,n) = \sum_{u=j-W}^{j+W} \sum_{v=k-W}^{k+W} f(u,v) f(u-m, v-n) \quad (2.23)$$

em média sobre uma janela $(2W+1) \times (2W+1)$, centrada em (j,k) . O tamanho da janela deve ser escolhido de maneira a ter custo computacional não elevado, mas com boa margem de precisão na estimativa.

A partir dessa função de autocorrelação, podem ser definidos momentos (medidas de espalhamento) cujo valor pode ser assinalado no ponto central da janela, ou em todos os seus pontos.

$$S(u,v) = \sum_{m,n=0}^T (m-h_m)^u (n-h_n)^v \tilde{A}_f(m,n)$$

onde

$$h_m = \sum_{m,n=0}^T m \tilde{A}_f(m,n)$$

$$h_n = \sum_{m,n=0}^T n \tilde{A}_f(m,n)$$
$$\tilde{A}_f(m,n) = \frac{A_f(m,n)}{\sum_{m,n=0}^T A_f(m,n)} \quad (2.24)$$

2.2.2 - DETECÇÃO ESTATÍSTICA DE BORDAS

O realce de bordas pode ser feito proporcionalmente à correlação dos "pixels" para máscara estatística:

$$h = \begin{bmatrix} \rho_r \rho_c & -\rho_c(1 + \rho_r^2) & \rho_r \rho_c \\ -\rho_r(1 + \rho_c^2) & (1 + \rho_r^2)(1 + \rho_c^2) & -\rho_r(1 + \rho_c^2) \\ \rho_r \rho_c & -\rho_c(1 + \rho_r^2) & \rho_r \rho_c \end{bmatrix} \quad (2.25)$$

onde ρ_r e ρ_c são os coeficientes de correlação entre "pixels" adjacentes na linha e na coluna.

2.2.3 - HISTOGRAMA

Vários atributos podem ser definidos a partir de histograma da janela na imagem.

Para descrever a forma de histogramas de primeira ordem, são utilizadas as medidas de: média, variância, assimetria, kurtosis, energia e entropia.

Histogramas de segunda ordem são baseados na distribuição de probabilidade conjunta de pares de "pixels". São representados por uma matrix $L \times L$, chamada matriz de co-ocorrência, onde L é igual ao número de níveis de cinza possíveis.

A partir dessa matriz podem-se obter medidas tais como: autocorrelação, covariância, inércia, energia, entropia e outros.

Pratt (1976), Haralick et alii (1973) e outros têm contribuído para o desenvolvimento dos métodos que envolvem medida de histograma.

2.3 - OUTROS MÉTODOS

2.3.1 - COEFICIENTES DE TRANSFORMADA DIGITAL

Os coeficientes de transformada digital especificam a amplitude ou o grau de repetição de certos padrões de luminância na imagem ou janela que se está examinando. Dos métodos mais comuns, podem-se citar:

- 1) Transformada Discreta de Fourier (TDF)
(Pratt, 1978; Haralick, 1979)
- 2) Transformada Textural
(Haralick, 1979)
- 3) Outras transformadas: Hadamard, Haar etc.

Nestes métodos, a imagem é tipicamente subdividida em várias subimagens quadradas. Cada subimagem é transformada, e os coeficientes resultantes são associados a ela. Tais coeficientes auxiliam a discriminação desses campos, pois estão relacionados com a textura.

2.3.2 - ATRIBUTOS ESTRUTURAIS

Normalmente se utiliza somente o nível de cinza de cada ponto da imagem em processos de classificação de padrões. As inter-relações locais (textura) ou globais (contexto) de pontos na imagem também são características importantes a serem consideradas na definição de classes ou objetos nelas contidos.

No método estrutural, a primitiva é definida como sendo um conjunto de pontos com propriedades tonais comuns. Regras de localização descrevem a inter-relação entre as primitivas.

Dessa maneira é possível separar do restante da imagem as áreas que tenham as mesmas primitivas e regras de localização.

Modelos puros de textura são baseados no fato de que texturas são compostas de primitivas que aparecem em arranjos espaciais regulares e repetitivos.

Os métodos de densidade de extremos relativos e de árvores relacionais (Haralick, 1979) são exemplos de método estrutural.

2.3.3 - ATRIBUTOS OBTIDOS POR MODELOS ESPECIAIS

Existem métodos de extração de atributos de imagem derivados de alguns modelos propostos.

O modelo de auto-regressão baseia-se no fato de que o valor do "pixel" depende do valor de seus vizinhos.

Fixada uma vizinhança de um dado ponto, pode-se associar a esse uma função dos coeficientes da função que estima esse ponto a partir dos pontos de sua vizinhança. (Haralick, 1979).

O modelo visual estocástico desenvolvido por Pratt e Faugeras (1979) considera uma região de textura como uma amostra de um processo estocástico bidimensional, descritível por seus parâmetros estatísticos, limitados porém a descrições que concordem com a percepção humana. O método se resume no diagrama de bloco da Figura 2.12.

Da função de autocorrelação da imagem e do histograma do campo descorrelacionado são extraídos atributos que a experiência mostrou serem significativos em relação aos processos de discriminação visual.

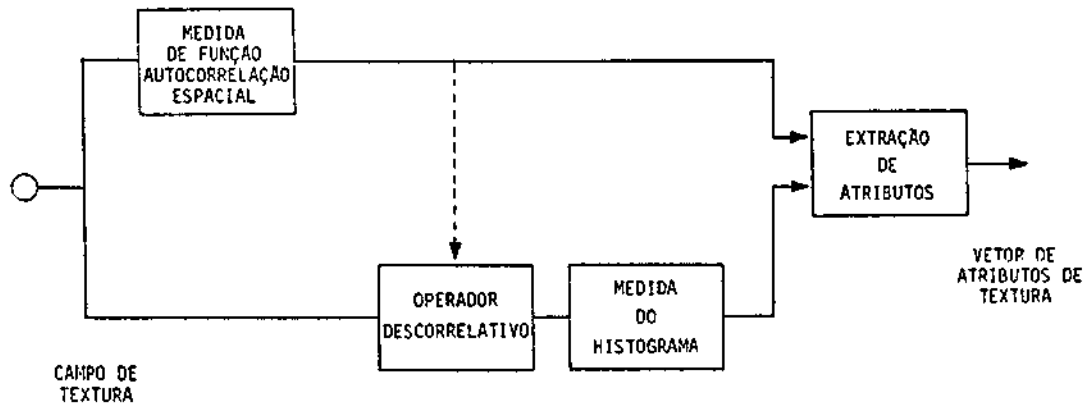


Fig. 2.12 - Método estocástico de extração de atributos de textura.

2.3.4 - OPERADORES HEURÍSTICOS

Alguns operadores heurísticos podem ser definidos para que tenham uma saída proporcional à rugosidade de uma pequena região circunvizinha de um dado ponto. São operadores projetados a partir da experiência.

Considere a seguinte disposição dos pontos em uma vizinhança 3 x 3:

a b c
d x e
g h i

A partir dela podem ser definidos os operadores:

1) Variações

- Variação horizontal

$$\begin{aligned} \text{HTV} = & |a - b| + |d - x| + |g - h| + \\ & + |b - c| + |x - e| + |h - i| \end{aligned} \quad (2.26)$$

- Variação vertical:

$$\begin{aligned} VTV = & |a - d| + |t - x| + |c - e| + \\ & + |d - g| + |x - h| + |e - i| \end{aligned} \quad (2.27)$$

- Variação total:

$$TV = HTV + VTV \quad (2.28)$$

- Variação mínima:

(menor sensibilidade de ruído)

$$MTV = \min(HTV, VTV) \quad (2.29)$$

2) Deslocamento

Uma imagem deslocada lateral ou verticalmente pode ser usada como outro canal. Nesse caso, a matriz de covariância teria elementos que medem a autocovariância no sentido horizontal e vertical das imagens.

3) Rugosidade

$$\begin{aligned} \text{rugosidade} = & |x - a| + |x - b| + |x - c| + |x - d| + \\ & |x - e| + |x - g| + |x - h| + |x - i| \end{aligned} \quad (2.30)$$

Existem outros métodos de extração de atributos baseados em estatísticas de comprimentos de segmentos de nível de cinza constante, na imagem, e em densidade de extremos relativos.

OBSERVAÇÃO: Todos os métodos até agora descritos se referem à extração de atributos, particularmente aos espaciais, realizados antes do processo de classificação. O método de Welch and Salter (1976) transfere para a fase de classificação a uti

lização de informações espaciais para auxílio no processo discriminatório (Teoria da Decisão Composta).

2.3.5 - ATRIBUTOS EXTRAÍDOS DE CENAS MULTIESPECTRAIS

Os métodos de extração de atributos apresentados aplicam-se a imagens em preto e branco. Em processos de classificação de padrões, que utilizam cenas multiespectrais, tais métodos são aplicados a cada componente da cena separadamente. Em certas aplicações, como Geologia por exemplo, podem ser extraídos certos atributos derivados de caráter espectral da cena, obtidos por operações pontuais entre os níveis de cinza do ponto de cada faixa espectral. Alguns exemplos desses atributos são definidos a seguir:

1) Razão entre canais:

$$r_{ij} = \frac{C_i}{C_j} \quad (2.31)$$

onde C_i e C_j são os níveis de cinza nos canais i e j .

2) Normalização:

$$N_i = \frac{C_i}{\sum_{j=1}^N C_j} \quad (2.32)$$

onde N é o número de canais.

3) Diferença normalizada:

$$D_{ij} = \frac{C_i - C_j}{C_i + C_j} \quad (2.33)$$

A motivação primária dessas operações é transformar os dados de imagem em outra forma menos dependente de fatores ambientais e condições de sensores, que são normalmente de caráter multiplicativo, como por exemplo: ganho dos sensores, iluminação, transmitância etc.

2.3.6 - DADOS AUXILIARES

Em adição aos atributos de imagem ou dela derivados por manipulações dos níveis de cinza dos "pixels", outros dados não diretamente extraídos, mas relacionados com a posição dos pontos na imagem, tais como dados temporais, geomorfológicos, sócio-econômicos e climáticos, podem ser utilizados em combinação com os primeiros, para auxiliar no processo de discriminação de objetos especiais na imagem.

CAPÍTULO 3

OS MÉTODOS DE CLASSIFICAÇÃO

Quanto ao modelo que descreve o comportamento dos atributos, os métodos de classificação de padrões podem ser classificados em dois tipos: estatístico e determinístico.

Um método determinístico de interpretação automática de imagens, disponível aos usuários do sistema I-100 fabricado pela G.E., é o chamado método do paralelepípedo (GE, 1975).

Um padrão ou vetor é classificado como pertencente a uma dada classe se todas as componentes desse vetor estiverem dentro de certos limites superiores e inferiores, definidos para cada dimensão ou eixo e para aquela classe. Em outras palavras, um padrão ou vetor é classificado para uma classe se ele pertence ao interior do paralelepípedo cujos vértices são dados pelos pares de limitantes superiores e inferiores, para todos os eixos do espaço de atributos em uso.

Esse método, embora rápido, conduz a aproximações grosseiras da assinatura real do objeto que está sendo classificado, gerando muitos erros de classificação.

Um método estatístico de decisão implantado no sistema I-100, e que será usado normalmente neste trabalho, é a regra de decisão por máxima verossimilhança. (Velasco et alii, 1978).

Decide-se que um padrão \vec{x} pertence a uma classe w_i se e somente se:

$$g_i(\vec{x}) = p(\vec{x}/w_i) P(w_i) \geq p(\vec{x}/w_j) P(w_j) = g_j(\vec{x}) \quad (3.1)$$

$i = 1, \dots, N$ onde $N =$ número de classes.

$g_i(\vec{x}) = p(\vec{x}/w_i) P(w_i)$ é chamado função discriminante para a classe w_i .

Para densidades gaussianas pode-se derivar:

$$g_i(\vec{x}) = \ln P(w_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (\vec{x} - \mu_i)^T \Sigma_i^{-1} (\vec{x} - \mu_i) \quad (3.2)$$

onde

Σ_i = matriz de covariância.

μ_i = vetor de média da classe w_i .

Esse esquema de categorização assinala cada um dos padrões apresentados a alguma das classes definidas anteriormente na fase de treinamento. Em problemas de sensoriamento remoto, no entanto, há sempre pontos que, de fato, não deveriam pertencer a nenhuma das classes definidas, devido à incerteza na definição da área de treinamento e na definição de um número menor de classes que as realmente existentes.

Para evitar classificação excessiva (isto é, que pontos que não pertencem a nenhuma classe sejam classificados) rejeita-se para a classe w_i o ponto cuja função discriminante for menor que um certo limiar T_i para a classe w_i . A regra passa a ser então:

$$\begin{aligned} x \in w_i \text{ se } & g_i(x) \geq g_j(x) \quad i \neq j \\ & \text{e } g_i(x) \geq T_i. \end{aligned} \quad (3.3)$$

onde T_i é o limiar para a classe w_i .

Normalmente supõe-se que esse limiar T_i é o mesmo para todas as classes.

O método estatístico gaussiano requer a estimativa do vetor média e da matriz de covariância para as classes a serem usadas na fase de classificação. Para isso, usam-se áreas na imagem chamadas "de

treinamento", consideradas como verdade terrestre, para possibilitar o aprendizado das características da classe.

Um meio de testar a acuidade com que foram definidas as classes, permitindo também avaliar o poder discriminatório dos atributos usados na separação das classes de interesse, nesta fase de treinamento, é classificar os pontos de todas as áreas de treinamento, ou de outras áreas de classificação também conhecidas, denominadas áreas teste.

Uma alta percentagem de pontos de uma área de treinamento ou teste de uma classe w_i , classificada como pertencendo à w_j , significa que no mínimo a classe w_i está mal definida; provavelmente a classe w_j também estará mal definida. Se não for possível melhorar a definição das áreas de treinamento, os atributos usados não serão os mais adequados para separar essas classes.

Observando-se a influência da troca de atributos ou do número de atributos usados nas percentagens de classificação correta das diversas áreas de treinamento ou teste, um melhor conjunto de atributos para separar aquelas classes pode ser procurado.

O uso de áreas teste se faz necessário, pois a classificação de áreas de treinamento é um tanto otimista visto advir das próprias os parâmetros utilizados para a classificação. Um bom resultado na classificação de áreas teste significa que a aquisição de parâmetros foi feito com bom índice de generalização para aquela classe.

Os dois classificadores mencionados são chamados ponto a ponto, pois a classificação de um ponto não depende da classificação de seus vizinhos. A teoria de decisão composta (Duda et alii, 1973) introduz a utilização do contexto na classificação de um ponto, modelando melhor as ocorrências naturais, já que na maioria dos casos é grande a correlação entre "pixels" vizinhos nas imagens de recursos terres

tres. Infelizmente, o custo computacional da aplicação de algoritmos baseados nesta teoria é muito grande, limitando o número de casos possíveis de uso eficiente.

CAPÍTULO 4

SELEÇÃO DE ATRIBUTOS

4.1 - OBJETIVO

Cenas obtidas por sensores situados em plataformas remotas e utilizadas em levantamento de recursos naturais compõem-se normalmente de 4 ou mais imagens, cada qual captada em uma faixa diferente e estreita do espectro.

Processos de extração de atributos aplicados às imagens componentes de uma cena podem elevar consideravelmente a dimensionalidade dos dados, pela multiplicação das medidas que caracterizam um único ponto da imagem.

A Seleção de Atributos refere-se ao método utilizado para escolher um subconjunto de dimensão $M < N$, onde N é o número total de características do padrão, tal que a separabilidade entre certas classes de interesse é maximizada para esse subconjunto em relação aos outros subconjuntos de mesma subdimensão M .

4.2 - O MÉTODO

Utilizar-se-ão no processo de seleção de atributos a figura de mérito denominada Distância de Bhattacharyya (Distância B) e sua relacionada Distância Jeffreys-Matusita (Distância JM) (Chen, 1973).

A Distância B é função escalar das funções densidade de probabilidade de 2 classes e é definida como:

$$B = - \ln \rho \quad (4.1)$$

onde ρ = coeficiente de Bhattacharyya dado por:

$$\rho = \int_{-\infty}^{\infty} (p(\vec{x}/w_1) p(\vec{x}/w_2))^{1/2} dx \quad (4.2)$$

A Distância JM é dada por:

$$d_{JM}^2 = 2(1 - \rho) \Rightarrow d_{JM} = (2(1 - \rho))^{1/2} \quad (4.3)$$

Para o caso de 2 classes, podem ser obtidos limites superiores e inferiores para a probabilidade de erro em função de ρ . Sendo P_E probabilidade de erro; e P_1 e P_2 probabilidades a priori de w_1 e w_2 , respectivamente, tem-se:

$$\frac{1}{4} \rho^2 \leq P_1 P_2 \rho^2 \leq \frac{1}{2} (1 - \sqrt{1 - 4P_1 P_2 \rho^2}) \leq P_E \leq \sqrt{P_1 P_2} \rho \leq \frac{1}{2} \rho \quad (4.4)$$

Para densidades gaussianas a Distância B é dada por

$$B = \frac{1}{8} (\vec{\mu}_1 - \vec{\mu}_2)^T \left(\frac{\Sigma_1 + \Sigma_2}{2} \right) (\vec{\mu}_1 - \vec{\mu}_2) + \frac{1}{2} \left\{ \frac{\frac{1}{2} |\Sigma_1 + \Sigma_2|}{|\Sigma_1|^{1/2} |\Sigma_2|^{1/2}} \right\} \quad (4.5)$$

onde $\vec{\mu}_1$ e $\vec{\mu}_2$ são vetores média e Σ_i são matrizes de covariância para as classes 1 e 2.

É difícil derivar uma expressão semelhante para outros tipos de função densidade de probabilidade; sabe-se no entanto, que para a maior parte dos casos de imagens naturais, o modelo gaussiano se ajusta satisfatoriamente.

Quando temos 2 classes basta escolher o subconjunto com M atributos para o qual a distância JM é maior. Para o caso de mais de 2 classes costuma-se aplicar dois critérios para a escolha do melhor subconjunto: um subconjunto é escolhido para o qual a distância média entre as distâncias JM para todos os pares de classes, é maximizada. Ou

tra escolha é feita considerando-se o subconjunto que tenha a maior das distâncias JM mínima entre os pares de classe.

CAPÍTULO 5

O MÉTODO PROPOSTO E DISCUSSÕES

5.1 - O MÉTODO

Os classificadores ponto a ponto não utilizam toda a informação disponível em uma imagem, desprezando a informação espacial que ela contém. Por outro lado, métodos baseados na teoria de decisão composta usam a informação espacial com custo computacional elevado e, além disso, existe grande dificuldade para se estimar certos parâmetros requeridos.

Utilizando-se extratores adequados, podem-se produzir, a partir de N atributos originais, outros canais ou atributos que associem a cada ponto da imagem um vetor função do conteúdo espacial em torno do ponto. Em seguida utiliza-se o esquema de classificação ponto a ponto, agora com disponibilidade de atributos espaciais. Considere o esquema da Figura 5.1.

Da cena natural, utilizando-se sensores normalmente remotos, extraem-se os atributos espectrais que são devidamente digitalizados para uso em computadores.

Novas imagens são geradas a partir de cada imagem espectral, de maneira tal que cada ponto da nova imagem é associado a um número que mede uma certa modalidade de informação espacial na vizinhança do ponto correspondente na imagem original. Usar-se-ão as modalidades de informação espacial que são extraídas por filtragem linear (Seção 2.1.1), filtragem não-linear com ou sem reescalonamento (Seção 2.1.2), e operadores heurísticos, particularmente o operador variação. (Seção 2.3.4).




Fig. 5.1 - Extração de atributos em imagens digitais.

Normalmente são utilizados para operadores espaciais filtros passa-alta (fpa.) e filtros passa-baixa (fpb.), em combinação com os dados originais. O fpb tem a função de diminuir a variância espectral das classes, fazendo com que os vetores padrões se aproximem dos vetores médias das classes a que pertencem, já que se supõe que vetores que pertencem a uma mesma classe estão próximos tanto espectral quanto espacialmente. O fpa (linear ou não) extrai uma modalidade de informação espacial, que é proporcional a um operador derivativo, direcional ou não, aplicado à imagem espectral; não é hábil em geral para detectar estruturas bem definidas na imagem (o que caracteriza a idéia de textura), e sim para extrair um tipo de dado que informa algo sobre a rugosidade local da imagem e se essa rugosidade é direcional ou não, conforme o tipo de filtro utilizado.

Existe também a alternativa de realizar uma rotação espectral, que é uma transformação linear sobre o espaço de atributos. A transformação de componentes, principais (Karhunen Loève), além de manter a gaussianidade dos dados bem como sua representação (os agregamentos mantêm-se inalterados), permite reduzir o número de atributos espectrais, sem grande perda de informação, pela escolha dos autovetores correspondentes aos maiores autovalores da matriz de covariância global dos canais originais.

Assim, para a mesma dimensionalidade global pode-se fazer a extração de um número maior de atributos espaciais.

Como as máscaras utilizadas são curtas, as frequências predominantemente realçadas correspondem à faixa de 3,5 a 6,3 ciclos por km em imagens LANDSAT, que é a máxima frequência que pode ser observada nesta série de satélites com resolução de aproximadamente 80 m. Notar que a frequência de 6,3 ciclos por km corresponde à frequência normalizada de 0,5 ciclo por "pixel".

Estudos anteriores (Gramenopoulos, 1973) indicam que essa faixa contém a informação necessária para discriminar as classes mais comuns em levantamento de uso do solo (montanhas, deserto, campos

cultivados, estradas, rios, colinas, áreas urbanas, etc.) com o uso de imagens do MSS ("multispectral scanner") do LANDSAT.

Para diminuir a influência do ruído (que contém predominantemente componentes de alta frequência), o campo filtrado por operador derivativo é novamente filtrado por fpb, obtendo-se assim, por exemplo, um campo média do laplaciano ou do gradiente.

O aumento da dimensionalidade, apesar da eficiência relativa inerente ao classificador ponto a ponto, pode, entretanto, diminuir consideravelmente a velocidade de processamento. Dispondo-se de áreas de treinamento suficientes e de recursos computacionais adequados, pode-se realizar a classificação de padrões considerando-se todos os atributos gerados. Quando isso não for possível é necessário, então, escolher, entre os atributos gerados, um subconjunto que minimize a probabilidade de erro, $(P(E))$, fixado o número de elementos que podem pertencer ao conjunto.

O número de atributos a ser fixado depende de vários fatores: custo computacional, disponibilidade de amostras de treinamento, limitações físicas, precisão requeridas, qualidade dos extratores, e classes utilizadas. O relacionamento existente entre esses fatores é discutido na Seção 5.3.2.

O método que será utilizado para a escolha dos atributos não usa diretamente a $P(E)$ como critério de escolha dos canais ou atributos mais convenientes, e sim a figura de mérito denominada distância JM (Jeffreys-Matusita) e a sua relacionada distância B (Bhattacharyya) (ver Capítulo 4). Essas figuras de mérito têm uma implementação mais conveniente, limitantes para a $P(E)$ em função da distância B, e expressões simples quando se consideram as funções densidade de probabilidade gaussianas.

A experiência indica que é razoável admitir que o comportamento das classes possa ser descrito por funções densidade gaussianas, conduzindo, além disso a expressões simples para a implementação do classificador.

O classificador utilizado será o de máxima verossimilhança, implantado no Laboratório de Interpretação Automática do INPE sob o nome de MAXVER.

Alguns dos operadores de extração de atributos são transformações lineares e como tal conservam a gaussianidade; o mesmo, porém, não acontece com as transformações não-lineares, podem-se utilizar, no entanto, outras transformações não-lineares subsequentes do tipo reescalonamento não-linear, com o objetivo de recuperar aproximadamente o caráter gaussiano dos resultados (ver Seção 5.3.1). Isto é necessário porque tanto a distância B como o algoritmo de classificação adotam a distribuição gaussiana.

Obtêm-se finalmente um conjunto de canais que, considerando um determinado conjunto de classes, pode ser utilizado em classificação de padrões naturais, tendo sido diminuída a $P(E)$, ou seja, a probabilidade de confusão entre os padrões.

Com a utilização do método alguns problemas podem aparecer: 1) demora na escolha de um conjunto de canais convenientes para um dado conjunto de classes; e 2) perda de aparência visual natural.

O uso de informação espacial é uma forma adicional de extrair informação de uma cena. Para aumentar a dimensionalidade intrínseca (ver Seção 5.3.2) é necessário fornecer informação proveniente de outras fontes.

A metodologia apresentada sugere e permite a utilização, quando possível, de dados auxiliares não diretamente extraídos, mas relacionados com a cena original, tais como dados temporais (uso de ce

nas com diferentes datas), geomorfológicas (extraídos de cartas geográficas) ou sócio-econômicas (ver Seção 2.3.5).

Pode aparecer, entretanto, a necessidade de utilizar técnicas de registro de imagens para ajustar devidamente a posição relativa de cenas obtidas em datas diferentes, ou provocar uma determinada deformação em uma imagem com o fito de ajustá-la a um determinado tipo de projeção.

Dados sócio-econômicos, demográficos e outros devem estar organizados em bancos de dados e poderão auxiliar as tarefas que envolvem acompanhamento de fenômenos que variam com o tempo e com aplicações em mapeamento físico, demográfico e outros

5.2 - O MÉTODO NO CONTEXTO DA LITERATURA

Bastante extensa, embora recente, é a literatura sobre textura e atributos espaciais. Citam-se, a seguir, 5 referências diretamente ligadas ao trabalho:

- 1) O trabalho de Ahuja et alii (1977), que descreve a aplicação de métodos supervisionados e não-supervisionados para segmentação de imagens; tais métodos usam níveis de cinza de pontos da vizinhança como atributos.

O procedimento supervisionado computa uma função discriminante linear e o algoritmo média-k é usado para o procedimento não supervisionado.

A um ponto $I(i,j)$ de uma imagem $M \times N$ é associado o vetor \vec{x} , cujas componentes são o nível de cinza de $I(i,j)$, a média 3×3 e a média 5×5 .

As componentes também podem ser os próprios pontos da vizinhança.

O autor conclui que não se ganha muito em utilizar os pontos da vizinhança em lugar de usar uma média local ou alguma propriedade derivada desses pontos. A técnica é limitada para uso em cenas simples.

O procedimento não supervisionado não deu bons resultados, pois revelou ser muito sensível aos pontos iniciais.

- 2) O trabalho de Schachter et alii (1979), que descreve algumas tentativas para segmentar imagens monocromáticas que detectam agregamentos ("clusters") de certos atributos locais.

Regiões da imagem com mesma faixa de nível de cinza, mas de diferentes texturas, poderão ser discriminadas com o uso de certos atributos locais.

O procedimento básico é plotar o histograma bidimensional (uma das dimensões é um atributo espacial) num espaço também bidimensional (diagrama de espalhamento) e procurar agregar separadamente as regiões mais densas.

Utilizar como um atributo o gradiente ou laplaciano não conduziu a resultado muito bom, pois os valores mais altos se davam nas bordas e não detectavam tanto a textura.

Foi definido o operador HTV, VTV e MTV (ver Seção 2.3.4) para a obtenção de valores uniformes para toda uma região de mesma textura.

A transformada textural introduzida por Haralick (1979) (ver Seção 2.3.1) também foi usada, pois mede a tipicidade de um certo padrão espacial em torno de um ponto.

Os melhores resultados foram obtidos utilizando-se como atributos MTV mediano x média 3 x 3 e tipicidade média x média 3 x 3, comparáveis com o resultado obtido utilizando-se 3 informações espectrais para a mesma cena.

Para melhorar o desempenho o autor sugere a utilização de técnicas de "region growing" e relaxação.

- 3) Iisaka (1979) usou atributos locais obtidos por filtragem para ajudar a classificação de tipos de florestas diferentes.

Conclui que o método é útil para o caso e que há um tamanho ótimo da janela para cada tipo de floresta.

- 4) Logan et alii (1979) sintetizaram um canal a partir do canal 5 do LANDSAT, calculando o desvio padrão em uma janela 3 x 3, e utilizaram esse canal para classificação não supervisionada de áreas florestais.

- 5) O trabalho de Gramenopoulos (1973) relata os resultados de um estudo aplicado a imagens LANDSAT. São empregados 4 atributos espaciais combinados com 3 atributos espectrais para formar um vetor de dimensão 7, que representa uma janela de 32 x 32. Os vetores são classificados usando a regra de máxima verossimilhança. Gramenopoulos usa um algoritmo de agregamento para obter os dados de treinamento para o classificador e conclui que: a utilização de atributos espaciais aumenta a precisão do classificador; as estatísticas variam bastante conforme as estações do ano, e os resultados são aplicáveis a produção de mapas de uso do solo. É feita uma análise dos erros de classificação quando os atributos não têm distribuição gaussiana. Para esse caso são desenvolvidas transformações não-lineares (raiz quadrada e logaritmo neperiano) de tal maneira que os erros são minimizados e as classes ficam com distribuição mais próxima da gaussiana.

Os atributos espaciais foram obtidos examinando-se as Transformadas Discretas de Fourier (TDF) de cada cela e identificando os padrões de cada classe. O autor usa a banda vermelha (canal 5) porque oferece mais informação espacial que as outras bandas. Conclui que somente frequências maiores que 3,5 ciclos por km (1/4 ciclo por "pixel" em imagens LANDSAT) oferecem informação necessária para distinguir diferentes tipos de terreno (conclusão > máscaras curtas) e que existe energia significativa ao longo do eixo vertical de frequência nos pontos de 2,1, 4,2 e 6,3 ciclos por km (1/6, 1/3 e 1/2 ciclos por "pixel" > essa energia aparece devido ao "stripping" - ruído que aparece na imagem devido à diferença entre os sensores do LANDSAT que detectam a radiação numa mesma frequência).

Os quatro atributos espaciais são obtidos: 1) eliminando-se as frequências maiores que 5,9 ciclos por km (ruído) e menores que 3,5 ciclos por km; 2) na restante TDF o maior pico é determinado; 3) a energia no setor com abertura de $\pi/8$ é centrada no pico encontrado e calculada e usada como primeiro atributo; 4) três outros atributos são obtidos de maneira similar em setores distantes de $\pi/4$, $\pi/2$ e $3\pi/4$.

Foi testado um algoritmo heurístico de classificação, usando-se somente os quatro atributos espaciais com resultados considerados razoáveis.

Esses atributos espaciais não são gaussianos; transformações não-lineares aplicadas ao espaço mudam a forma das funções densidade de probabilidade. Para tentar tornar os histogramas simétricos em torno da média, foram usadas funções logarítmicas e raiz quadrada. O autor comenta a classificação de imagens de uma data com estatísticas da mesma imagem observada em outra data. Apresenta também os resultados do uso combinado de atributos espaciais e espectrais. Nesse caso houve também um aumento significativo na precisão geral de classificação. Chega à conclusão também de que um algoritmo de agregamento para servir como fase de treinamento para a classificação de máxima verossimilhança aumenta a precisão do processo.

Comentário final:

Dos trabalhos discutidos, alguns se limitam a analisar um número pequeno de operadores espaciais em processos de classificação não-supervisionada e supervisionada não estatística com baixa dimensionalidade.

Outros, embora utilizem uma maior dimensionalidade e um número maior de operadores espaciais, têm o problema de perda de resolução espacial, pois esses atributos são retirados de janelas quadradas na imagem.

Este trabalho pretende reunir os operadores utilizados por esses autores e sugerir outros possíveis para extrair atributos espaciais, e utilizá-los em processos de classificação ponto a ponto, supervisionada sob hipótese gaussiana (classificação de máxima verossimilhança). A proposição deste trabalho difere basicamente da dos outros autores quando se sugere extrair atributos espaciais associados a cada ponto da imagem, em função de sua vizinhança, e quando se procura torná-los aproximadamente gaussianos, se não o forem, seguidos de um processo de seleção de atributos com a finalidade de escolher o melhor conjunto de atributos. A dimensão desse conjunto é ditada por razões físicas, de disponibilidade limitada de áreas de treinamento e tempo de processamento.

O método prevê também a aplicação conjunta, quando possível, de dados auxiliares, tais como geomorfológicos e temporais.

Normalmente se utilizarão conjuntamente diversos tipos de fpb e fpa; estes para retirar o ruído da informação espectral e tornar as assinaturas espectrais (volume mais frequentemente ocupado pelos pontos de uma dada classe) dos alvos mais bem definidas; aqueles serão utilizados, em geral, para extração de informação de rugosidade em torno do ponto a ser classificado.

5.3 - OBSERVAÇÕES TEÓRICAS SOBRE O MÉTODO

5.3.1 - O TEOREMA CENTRAL DO LIMITE

O clássico teorema central do limite diz que a soma de um grande número de variáveis aleatórias, independentes e identicamente distribuídas, com médias e variâncias finitas, normalizadas para ter média zero e variância 1, tem distribuição aproximadamente gaussiana.

Mais recentemente, Gnedenko and Kolmogorov têm feito pesquisas no sentido de estender a validade do teorema para os casos de variáveis aleatórias dependentes (Parzen, 1960).

Segundo Dubes (1968), as hipóteses de independência e distribuição idênticas são unicamente expedientes matemáticos. Conjuntos de hipóteses mais gerais podem ser estabelecidas, embora com prova mais difícil. Pode-se esperar uma distribuição limitante normal, mesmo que as hipóteses não se conformem exatamente com as condições clássicas.

Quando se usa filtragem não-linear, o resultado não é necessariamente gaussiano. Operações lineares, como médias por exemplo, tendem a gaussianizar o resultado se aplicado em seguida a operações não lineares.

No entanto, como a restrição de independência nem sempre é assegurada, deve-se observar o histograma das áreas de treinamento para checar se não apresenta forte discrepância com a hipótese gaussiana.

Porém, como mencionado na Seção 1.2, métodos de classificação baseados na hipótese gaussiana são robustos, e moderada violação dessa hipótese não vai prejudicar sensivelmente os resultados.

5.3.2 - DIMENSIONALIDADE, PRECISÃO E NÚMERO DE AMOSTRAS

Alguns resultados, já consignados na literatura sobre os fatores que afetam a precisão da classificação, são apresentados para orientar a escolha dos processos utilizados na extração de atributos. (Landgrebe, 1978).

1) A complexidade da medida

É uma medida de quão precisamente é feita uma medição. A complexidade da medida é dada por:

$$cm = k^P$$

onde

k = número de níveis de cinza;

P = número de bandas espectrais.

Espera-se que aumentando a complexidade ou precisão da medida a precisão do classificador aumente, o que nem sempre é verdade.

O uso de um número finito de amostras faz com que não se possa aumentar indefinidamente a complexidade da medida. A partir de uma certa complexidade, fixado o número de amostras, a sensibilidade no cálculo dos parâmetros começa a aumentar e com isso cai a precisão do classificador.

Para que a precisão do classificador aumente com a complexidade é preciso que o número de amostras de treinamento também aumente, o que nem sempre é possível. As curvas de precisão de classificação versus complexidade, fixado o número de amostras, apresenta portanto um máximo.

Mesmo que se dispusesse de um número crescente de amostras, a curva teria uma tendência saturante de maneira tal que os custos computacionais não autorizariam um aumento na complexidade, para alcançar uma tímida melhora na precisão de classificação.

2) O efeito do ruído

É observado que a adição de ruído à imagem afeta mais a classificação de padrões com menor poder discriminatório (classes em confusão).

3) Dimensionalidade Intrínseca

A dimensionalidade intrínseca é o menor número de dimensões que deve ser usado para representar os dados adequadamente.

As imagens LANDSAT têm dimensionalidade de aproximadamente 2, o que pode ser observado fazendo-se a transformação K-L (principais componentes). Para cenas obtidas de avião em 12 canais, demonstra-se que a dimensionalidade intrínseca é de aproximadamente 3. Neste trabalho, como será observado, a utilização dos atributos espaciais aumentará a dimensionalidade intrínseca das cenas do LANDSAT para 3.

Esse e outros experimentos permitiram levantar algumas conclusões a respeito de alguns parâmetros envolvidos em problemas de classificação de imagens.

- i) A resolução espacial, resolução espectral e relação sinal-ruído estão intrinsecamente ligadas de maneira tal que, fixados 2 parâmetros, o terceiro também fica fixado.
- ii) O uso de informação temporal e os auxiliares geomorfológicos e sócio-econômicos podem aumentar a dimensionalidade intrínseca do sistema. Normalmente, nestes casos, é preciso utilizar técnicas de registro de imagens.

iii) O problema de extração e seleção de atributos é fortemente dependente das classes de interesse.

CAPÍTULO 6

RESULTADOS

Os experimentos foram efetuados utilizando-se uma imagem LANDSAT-C - órbita 78, ponto 27 - de abril de 1978 sobre a área de Ribeirão Preto. Obtiveram-se também imagens de avião sobre a mesma área, o que permitiu escolher as áreas teste e de treinamento com boa precição.

As classes utilizadas e o número de pontos nas áreas teste e de treinamento são mostrados na Tabela 6.1.

TABELA 6.1

CLASSES USADAS

	CLASSE	NÚMERO DE PONTOS	
		ÁREAS DE TREINAMENTO	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

Nos experimentos 1, 2 e 3 foram utilizados 12 atributos assim distribuídos:

- os atributos de 1 a 4 são os canais originais de 4 a 7 do LANDSAT;
- os atributos de 5 a 8 são obtidos pela convolução dos canais 4 a 7 do LANDSAT pela máscara da Figura 6.1;
- os atributos de 9 a 12 informam sobre a variação ou rugosidade local dos canais originais e são obtidos por diferentes processos, conforme a experiência realizada.

$$\frac{1}{21} \begin{bmatrix} 0 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 0 \end{bmatrix}$$

Fig. 6.1 - Máscara para suavização (5 x 5)

Dos 12 atributos foram escolhidos 2 conjuntos de quatro canais, que constituem a capacidade máxima de manipulação do Imageador Automático I-100 do Laboratório de Tratamento de Imagens Digitais do INPE. Um conjunto segundo o critério de máxima distância JM média entre as distâncias das classes utilizadas, e outro conjunto de 4 atributos segundo o critério de máxima distância JM mínima entre classes estabelecidas.

Os programas elaborados para a execução do presente trabalho, os quais posteriormente servirão para uso normal no Laboratório, serão descritos em publicações posteriores e incluem:

- sistema para seleção de atributos até 12 canais;
- sistema de filtros digitais curtos lineares e não-lineares;
- sistema de composição e reescalonamento de imagens;

- programa para o cálculo e "display" do módulo da TDF de filtros digitais curtos;
- nova versão (3) do sistema MAXVER de classificação que permite aquisição e manipulação de áreas teste;
- programa para cálculo de autovalores e autovalores de matrizes de covariância em formatos MAXVER e COV (Seleção de atributos).

6.1 - 1ª EXPERIÊNCIA

Para a primeira experiência os atributos de 9 a 12 foram obtidos a partir dos canais originais, utilizando-se o operador variação total (Equação 2.28). Os canais resultantes desta operação foram suavizados pela convolução com a máscara da Figura 6.1.

Os canais selecionados pelos 2 critérios mencionados, considerando-se todas as 6 classes, coincidiram e são os seguintes (Tabela 6.2).

TABELA 6.2

SELEÇÃO 1

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
5	Média (5 x 5) do canal 4 do LANDSAT
8	Média (5 x 5) do canal 7 do LANDSAT
9	Variação suavizada do canal 4 do LANDSAT
10	Variação suavizada do canal 5 do LANDSAT

Limite superior para $P(\epsilon) = 2.82\%$ (Lainiotis, 1979).

Para comprovar a eficiência do método, foram obtidas as matrizes de classificação para as áreas de treinamento e teste. Essas matrizes apresentam de forma sucinta o resultado da classificação de áreas de classificação conhecida. Os erros cometidos ao classificar incorretamente pontos de identidade conhecida permitem estimar os erros envolvidos.

A partir dessas matrizes foi possível obter o "desempenho médio" (D_m), definido como a média da percentagem de classificação correta de cada área de treinamento ou teste, ponderada pelo número de pontos de cada uma. A "abstenção média" (A_m) foi definida como sendo a percentagem média de abstenção das áreas, ponderada pelo número de pontos das áreas. A "confusão média" (C_m) foi definida como sendo o erro médio ponderado pelo número de pontos das áreas.

As Tabelas 6.3 e 6.4 apresentam as matrizes de classificação para as áreas de treinamento e teste, com a utilização dos canais originais para o limiar de classificação = 5 ($L=5$) (Velasco et alii, 1978).

As tabelas 6.5 e 6.6 apresentam as matrizes de classificação para as áreas de treinamento e teste para os canais selecionados nesta experiência (Seleção 1).

TABELA 6.3

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS DE TREINAMENTO
UTILIZANDO-SE CANAIS ORIGINAIS COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N*	1	2	3	4	5	6
1. Cana	0,8	97,6	0,0	1,6	0,0	0,0	0,0
2. Cananova	0,5	0,0	92,1	0,0	0,0	7,4	0,0
3. Pasto	0,0	0,0	0,0	100,0	0,0	0,0	0,0
4. Água	0,0	0,0	0,0	4,2	95,8	0,0	0,0
5. Infraestrutura	0,0	0,0	8,3	0,0	9,7	81,9	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0
Desempenho Médio Dm = 95,1%							
Abstenção Média Am = 0,4%							
Confusão Média Cm = 4,5%							

* N = não-classificado

TABELA 6.4

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS TESTE, UTILIZANDO-SE
CANAIS ORIGINAIS COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N*	1	2	3	4	5	6
1. Cana	0,9	97,2	0,0	1,9	0,0	0,0	0,0
2. Cananova	0,0	0,0	79,6	0,0	0,0	20,4	0,0
3. Pasto	13,9	22,2	0,0	50,0	0,0	0,0	13,9
4. Água	2,8	0,0	0,0	11,1	86,1	0,0	0,0
5. Infraestrutura	16,7	0,0	22,2	16,7	5,6	38,9	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0

Desempenho médio $D_m = 77,8\%$
Abstenção média $A_m = 4,5\%$
Confusão média $C_m = 17,7\%$

* N = não-classificado

TABELA 6.5

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS DE TREINAMENTO, UTILIZANDO-SE
OS CANAIS DA SELEÇÃO NÚMERO 1, COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N*	1	2	3	4	5	6
1. Cana	0,0	100,0	0,0	0,0	0,0	0,0	0,0
2. Cana nova	0,0	0,0	99,1	0,0	0,0	0,9	0,0
3. Pasto	0,9	0,0	0,0	99,1	0,0	0,0	0,0
4. Água	1,4	0,0	0,0	0,0	98,6	0,0	0,0
5. Infraestrutura	0,0	0,0	0,0	0,0	0,0	100,0	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0

Desempenho médio $D_m = 99,5\%$
Abstenção média $A_m = 0,3\%$
Confusão média $C_m = 0,3\%$

* N = não-classificado

TABELA 6.6

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS TESTE, UTILIZANDO-SE
OS CANAIS DA SELEÇÃO NÚMERO 1, COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N	1	2	3	4	5	6
1. Cana	0,0	100,0	0,0	0,0	0,0	0,0	0,0
2. Cana nova	0,0	0,0	100,0	0,0	0,0	0,0	0,0
3. Pasto	29,2	20,8	0,0	48,6	1,4	0,0	0,0
4. Água	5,6	0,0	0,0	2,8	86,1	5,6	0,0
5. Infraestrutura	80,6	0,0	11,1	0,0	0,0	8,3	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0

Desempenho médio $D_m = 81,1\%$
Abstenção média $A_m = 13,1\%$
Confusão média $C_m = 5,8\%$

Por esses resultados, pode-se notar uma melhoria no desempenho médio e uma diminuição na confusão média tanto para áreas teste quanto para as de treinamento.

Convém notar que o limite teórico para a P(E) não foi ultrapassado.

Nota-se, no entanto, que houve uma maior abstenção e diminuição da percentagem de classificação correta para as classes pasto e infraestrutura, nas matrizes de classificação para áreas teste, embora o desempenho médio seja melhor. Isso ocorreu porque tais áreas teste estavam muito próximas de regiões de transição entre classes diferentes, o que fez com que os operadores médias tendessem a misturar as classes dos "pixels" e os operadores detetores de rugosidade tendessem a dar valores atipicamente altos nas regiões de transição, levando esses "pixels" a não serem classificados.

Selecionando-se desses doze canais, outros, não considerando a classe 5 por ter sido muito prejudicada pela localização difícil das áreas de teste e treinamento (essa classe não é muito extensa) obteve-se a seleção 2 (Tabela 6.7).

TABELA 6.7

SELEÇÃO 2

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
6	Média (5 x 5) do canal 5 do LANDSAT
7	Média (5 x 5) do canal 6 do LANDSAT
8	Média (5 x 5) do canal 7 do LANDSAT
11	Variação amaciada do canal 6 do LANDSAT

Os resultados das seleções 1 e 2 para os limiares de classificação 5 e 6 são sumarizados nas Tabelas 6.8 (áreas de treinamento) e 6.9 (áreas teste).

TABELA 6.8

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM
OPERADOR VARIAÇÃO SEM REESCALONAMENTO
(ÁREAS DE TREINAMENTO)

	CANAIS ORIGINAIS		SELEÇÃO 1		SELEÇÃO 2	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	95,1	95,2	99,5	98,4	99,2	99,6
Am (%)	0,4	0,3	0,3	0,8	0,5	0,1
Cm (%)	4,5	4,5	0,3	0,9	0,3	0,3

TABELA 6.9

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM
OPERADOR VARIAÇÃO SEM REESCALOCAMENTO
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 1		SELEÇÃO 2	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	81,1	83,8	75,0	79,5
Am (%)	4,5	0,3	13,1	6,6	16,9	7,3
Cm (%)	17,7	19,2	5,8	9,6	7,3	13,1

Observando-se a Tabela 6.8 deduz-se que houve boa diminuição da confusão média, não havendo diferença significativa entre as 2 seleções. Nota-se também que, na 1ª seleção, houve ligeiro aumento da confusão média, passando-se do limiar 5 para 6, devido à classificação de alguns pontos de pasto como cana para a classificação com limiar 6.

A Tabela 6.9 apresenta um resultado que indica que para a seleção 1 (Tabela 6.2) a confusão média caiu para metade, e que a confusão média também diminuiu para a seleção 2 (Tabela 6.7).

6.2 - 2ª EXPERIÊNCIA

Para a 2ª experiência os atributos de 9 a 12 foram obtidos a partir dos originais 4 a 7 do LANDSAT, utilizando-se operador variação total (Equação 2.28).

Nessa experiência procurar-se-á recuperar, pelo menos aproximadamente, o caráter gaussiano dos atributos espaciais gerados.

Para o resultado das operações não-lineares poderia ser aplicado o processo de gaussianização de histograma.

Esse processo, no entanto, é dependente da classe e a gaussianização simultânea não é garantida.

Optou-se por aplicar um reescalonamento por curva do tipo raiz quadrada ajustado aos limites 0-255 (Figura 6.2). Em seguida suaviza-se esse campo pela convolução com a máscara da Figura 6.1.

O reescalonamento por raiz quadrada tem bases empíricas e visa basicamente saturar os valores altos que os operadores de rugidade têm nas bordas entre regiões e aumentar os níveis de cinza dos pontos com nível de cinza mais baixo que são os mais frequentes.

Sua aplicação é bem mais simples que a gaussianização do histograma.

A aplicação posterior de um fpb. linear preenche os vazios resultantes no histograma, diminui a influência do ruído nesse tipo de operação e o torna mais próximo do modelo gaussiano de histograma, conforme sugere o teorema central do limite.




Fig. 6.2 - Curva de reescalonamento do tipo raiz quadrada.

Os 4 canais selecionados pelo critério de máxima distância JM média são apresentados na Tabela 6.10.

TABELA 6.10

SELEÇÃO 3

NÚMERO DOS CANAIS	DENOMINAÇÃO DAS CLASSES
6	Média (5 x 5) do canal 5 do LANDSAT
7	Média (5 x 5) do canal 6 do LANDSAT
10	Variação total do canal 5 do LANDSAT reescalonado e suavizado
12	Variação total do canal 7 do LANDSAT reescalonado e suavizado

Os 4 canais selecionados pelo critério de máxima distância JM mínima entre canais estão na Tabela 6.11.

TABELA 6.11

SELEÇÃO 4

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
5	Média (5 x 5) do canal 4 do LANDSAT
8	Média (5 x 5) do canal 7 do LANDSAT
9	Variação total do canal 4 do LANDSAT reescalonado e suavizado
10	Variação total do canal 5 do LANDSAT reescalonado e suavizado

Os índices de desempenho extraídos das matrizes de classificação para as áreas de treinamento e teste, para limiares 5 e 6, seleções 3 e 4, estão nas Tabelas 6.12 e 6.13.

TABELA 6.12

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM
OPERADOR VARIAÇÃO COM REESCALONAMENTO
(ÁREAS DE TREINAMENTO)

	CANAIS ORIGINAIS		SELEÇÃO 3		SELEÇÃO 4	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	95,1	95,2	98,6	99,6	99,6	99,6
Am (%)	0,4	0,3	0,9	0,1	0,0	0,0
Cm (%)	4,5	4,5	0,3	0,3	0,4	0,4

TABELA 6.13

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM
OPERADORES VARIAÇÃO COM REESCALONAMENTO
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 3		SELEÇÃO 4	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	80,8	88,6	82,3	85,1
Am (%)	4,5	0,3	18,4	6,6	12,6	5,8
Cm (%)	17,7	19,2	0,8	4,8	5,1	9,1

Comparando-se as Tabelas 6.8 e 6.12 observa-se que se obtêm menores erros e abstenções quando se usa reescalonamento; o fato de os pontos não-classificados passarem a ser classificados corretamente quando se aumenta o limiar de classificação sugere uma separabilidade mais aguda no caso de reescalonamento, por causa da melhor aproximação à hipótese gaussiana.

Esta hipótese é reforçada comparando-se as Tabelas 6.9 e 6.13 nas quais nota-se que, para o caso de reescalonamento, há sensível redução na confusão média para a terceira seleção de canais.

A observação direta das matrizes de classificação para o caso de reescalonamento permitiu também chegar à conclusão de que o reescalonamento ajuda a evitar não-classificação demasiada para a classificação de áreas próximas a fronteira entre regiões, pois tendem a saturar os valores altos desses operadores quando atuam na vizinhança entre classes diferentes. Basta observar, por exemplo, a matriz de classificação para as áreas teste da seleção 3 (Tabela 6.14) e compará-la com o resultado da classificação de infraestrutura da Tabela 6.6.

TABELA 6.14

MATRIZ DE CLASSIFICAÇÃO PARA ÁREAS TESTE, UTILIZANDO-SE
OS CANAIS DE SELEÇÃO 3, COM L = 5

MATRIZ DE CLASSIFICAÇÃO							
	N*	1	2	3	4	5	6
1. Cana	0,0	98,1	0,0	1,9	0,0	0,0	0,0
2. Cananova	0,0	0,0	100,0	0,0	0,0	0,0	0,0
3. Pasto	51,4	0,0	0,0	48,6	0,0	0,0	0,0
4. Água	33,3	0,0	0,0	2,8	63,9	0,0	0,0
5. Infraestrutura	66,7	0,0	0,0	0,0	0,0	33,3	0,0
6. Mata	0,0	0,0	0,0	0,0	0,0	0,0	100,0
Desempenho Médio DM = 80,8%							
Abstenção Média AM = 18,4%							
Confusão Média CM = 0,8%							

* N = não-classificado

6.3 - 3ª EXPERIÊNCIA

Para a 3ª experiência os atributos de 9 a 12 foram obtidos a partir dos originais 4 a 7 do LANDSAT, utilizando-se o operador laplaciano (Equação 2.36).

Faz-se o reescalonamento do campo laplaciano por uma curva do tipo raiz quadrática (Figura 6.2) e, em seguida, esse campo foi suavizado pela convolução com a máscara da Figura 6.1.

Os 4 canais selecionados pelo critério de máxima distância JM média são apresentados na Tabela 6.15.

TABELA 6.15

SELEÇÃO 5

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
4	Média (5 x 5) do canal 4 do LANDSAT
5	Média (5 x 5) do canal 5 do LANDSAT
6	Média (5 x 5) do canal 6 do LANDSAT
10	Laplaciano do canal 5 do LANDSAT reescalado e suavizado

Limite superior para $P(\epsilon) = 4,5\%$.

Os 4 canais selecionados pelo critério de máxima distância JM mínima entre pares de canais estão na Tabela 6.16.

TABELA 6.16

SELEÇÃO 6

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
5	Média (5 x 5) do canal 4 do LANDSAT
7	Média (5 x 5) do canal 6 do LANDSAT
9	Laplaciano do canal 4 do LANDSAT reescalado e suavizado
10	Laplaciano do canal 5 do LANDSAT reescalado e suavizado

Os índices de desempenho médio extraídos das matrizes de classificação para as áreas de treinamento e teste, para limiares 5 e 6, seleções 5 e 6, estão nas Tabelas 6.17 e 6.18.

TABELA 6.17

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM OPERADORES
LAPLACIANO REESCALONADOS E SUAVIZADOS
(ÁREAS DE TREINAMENTO)

	CANAIS ORIGINAIS		SELEÇÃO 5		SELEÇÃO 6	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	95,1	95,2	99,4	99,5	99,0	99,2
Am (%)	0,4	0,3	0,4	0,0	0,3	0,0
Cm (%)	4,5	4,5	0,3	0,5	0,8	0,8

O resultado da Tabela 6.17 demonstra haver sensível diminuição da confusão média. Se se compararem as Tabelas 6.17 com as Tabelas 6.12 e 6.8 observar-se-á pouca mudança entre elas, todas com boa melhora com relação aos resultados obtidos com os canais originais.

Maiores diferenças são encontradas quando se analisam as Tabelas 6.9, 6.13 e 6.18, referentes às áreas teste, onde se observa certa vantagem para a terceira seleção sobre as outras, o que significa que para essa seleção conseguiu-se maior acuidade na definição das classes utilizadas.

TABELA 6.18

ÍNDICES DE DESEMPENHO PARA OS CONJUNTOS DE CANAIS COM OPERADORES
LAPLACIANO REESCALONADOS E SUAVIZADOS
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 5		SELEÇÃO 6	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	82,8	85,9	82,1	85,6
Am (%)	4,5	0,3	13,1	5,1	9,6	1,0
Cm (%)	17,7	19,2	4,0	9,1	8,3	13,4

6.4 - 4ª EXPERIÊNCIA

Observando-se as experiências anteriores, nota-se que os canais originais não são escolhidos em nenhuma ocasião. Isto sugere que não é necessário considerar esses canais, sendo possível substituí-los por outros canais filtrados.

Coletando-se os canais mais frequentemente escolhidos nas experiências anteriores e usando-se outros três canais filtrados pela máscara da Figura 6.3 (suavizados), obtêm-se os seguintes atributos a partir dos canais originais.

- os atributos de 1 a 3 são os canais 4 a 6 do LANDSAT, suavizados pela máscara da Figura 6.3;
- os atributos de 4 a 6 são os canais 4 a 6 do LANDSAT, suavizados pela máscara da Figura 6.1 (média em região 5 x 5);

- os atributos de 7 a 9 são os canais de variação total dos canais 4 a 6 do LANDSAT, reescalados e suavizados pela máscara da Figura 6.1;
- os atributos de 10 a 12 são os canais módulo do laplaciano dos canais 4, 5 e 7 do LANDSAT, reescalados e suavizados pela máscara da Figura 6.1.

$$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Fig. 6.3 - Máscara 3 x 3 de suavização.

Selecionando-se também para esse caso 4 canais, obtiveram-se as seguintes seleções segundo os critérios de máxima distância JM média (Tabela 6.19) e máxima distância JM mínima (Tabela 6.20).

TABELA 6.19

SELEÇÃO 7

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
2	Média (5 x 5) do canal 5 do LANDSAT
3	Média (5 x 5) do canal 6 do LANDSAT
11	Variação total do canal 5 do LANDSAT reescalado e suavizado
12	Variação total do canal 7 do LANDSAT reescalado e suavizado

TABELA 6.20

SELEÇÃO 8

NÚMERO DOS CANAIS	DENOMINAÇÃO DOS CANAIS
2	Média (3 x 3) do canal 5 do LANDSAT
4	Média (5 x 5) do canal 4 do LANDSAT
6	Média (5 x 5) do canal 6 do LANDSAT
11	Variação total do canal 5 do LANDSAT reescalonado e suavizado

Nota-se que a seleção 7 é a mesma que a seleção 3 da 2ª experiência. Houve diferença somente com relação aos canais escolhidos segundo o critério de máxima distância JM mínima (seleção 8).

Os índices de desempenho médio extraídos das matrizes de classificação para as áreas de treinamento e teste estão nas Tabelas 6.21 e 6.22.

TABELA 6.21

ÍNDICES DE DESEMPENHO PARA AS SELEÇÕES 7 E 8
(ÁREAS DE TREINAMENTO)

	CANAIS ORIGINAIS		SELEÇÃO 7		SELEÇÃO 8	
Límiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	95,1	95,2	98,6	99,6	96,6	96,7
Am (%)	0,4	0,3	0,9	0,1	0,1	0,0
Cm (%)	4,5	4,5	0,3	0,3	3,3	3,3

TABELA 6.22

ÍNDICES DE DESEMPENHO PARA AS SELECÇÕES 7 E 8
(ÁREAS TESTE)

	CANAIS ORIGINAIS		SELEÇÃO 7		SELEÇÃO 8	
Limiar	5,0	6,0	5,0	6,0	5,0	6,0
Dm (%)	77,8	80,6	80,8	88,6	84,3	84,3
Am (%)	4,5	0,3	18,4	6,6	2,0	0,0
Cm (%)	17,7	19,2	0,8	4,8	13,6	15,7

Observou-se que os canais módulo do laplaciano não foram escolhidos, o que indica que o operador variação é mais eficiente em extrair informação espacial, conclusão essa reforçada quando se comparam os índices de desempenho da 2ª e 3ª experiência.

A seleção 8 inclui um canal média em região 3x3, mas os índices de desempenho não foram bons, sugerindo que os operadores médios em região 5x5 são mais eficientes.

Conclui-se portanto que não se ganha nada, neste caso, em incluir as médias em região 3x3, bem como canais laplacianos, confirmando-se a conclusão de que a melhor seleção que deve ser usada é a 3ª (ou 7ª)

6.5 - COMENTÁRIOS GERAIS

Os resultados demonstram 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.

O campo classificado mostrou-se mais homogêneo (compare a Figura 6.4 com a Figura 6.5), havendo uma região de não classificação na fronteira entre campos diferentes. Isso ocorre devido ao fato de os detetores de rugosidade darem valores atipicamente altos nas regiões de transição, já que estes também podem ser utilizados como detetores de bordas. O método desenvolvido permitiu então detectar regiões de classificação normalmente confusas e não classificá-las, em vez de classificá-las erradamente.



Fig. 6.4 - Imagem classificada com canais originais.




Fig. 6.5 - Imagem classificada com canais da seleção 3.

A utilização do reescalonamento mostrou-se benéfica, pois permitiu aproximar mais o comportamento das classes da hipótese gaussiana.

Observou-se também um aumento na dimensionalidade intrínseca para 3 ou mais canais, bastando observar como exemplo os autovalores normalizados que indicam a distribuição da informação entre os 4 canais principais, (Tabela 6.23) conseguidos pela transformação K-L, baseada nas matrizes de covariância das classes utilizando-se os 12 atributos da 3ª experiência (Tabela 6.11). Esse aumento da dimensionalidade intrínseca se deve ao uso da informação espacial.

TABELA 6.23

DISTRIBUIÇÃO DA INFORMAÇÃO ENTRE CANAIS PRINCIPAIS PARA 3 CLASSES,
USANDO-SE MATRIZ DE COVARIÂNCIA DE ORDEM 4 SOMENTE COM CANAIS
ORIGINAIS E A MATRIZ DE COVARIÂNCIA DE ORDEM 12
COM OS CANAIS DA EXPERIÊNCIA 3

CLASSE	DIMENSÃO	AUTOVALOTES NORMALIZADOS (%)				TOTAL
Cana	4	75,95	13,42	7,73	2,8	100,00
	12	39,87	22,76	13,50	11,51	87,64
Cana nova	4	81,77	11,48	5,88	4,41	100,00
	12	36,80	31,47	15,07	7,93	91,27
Pasto	4	71,92	15,17	9,81	3,09	100,00
	12	47,15	19,92	16,98	6,69	90,74

Um resultado que deve ser notado é a não-seleção de canais originais em nenhuma das experiências, inclusive nas escolhas seguintes em ordem decrescente de prioridade, conforme o critério de seleção utilizado. Isto sugere que não é necessário utilizar em nenhum caso os canais originais, colocando nos seus lugares outros canais especiais, ou utilizar somente oito atributos para obter maior rapidez na obtenção dos 4 melhores canais.

Os resultados apresentados demonstram que o método pode ser útil na resolução de diversos problemas de classificação de tipos de terreno em sensoriamento remoto.

6.6 - SUGESTÕES PARA FUTURAS PESQUISAS

Estudos de outros operadores para extração de atributos de rugosidade.

Estudo de operadores de suavização não-lineares para ten
tar diminuir o efeito de "borramento" na fronteira entre classes.

Estudo da influência da dimensão das máscaras na eficiência
do método.

Estudos para analisar mais profundamente o erro de classificação
nas fronteiras.

Possibilidade de uso de detectores de linha para utilização
em Geologia.

Investigação para determinar a ótima curva de reescalonamento
para um dado conjunto de classes e operadores.

Utilização conjugada com informação temporal e outros dados
auxiliares.

Estudos da utilização de rotação espectral antes da ex
tração de atributos espaciais.

Utilização do método com outros tipos de classificadores supervisionados e não-supervisionados. Um método supervisionado deter
minístico possível de ser utilizado é o método multicélula disponível no sistema I-100 de classificação de padrões. Esse método permite ad
quirir uma assinatura espectral para o objeto que se aproxima melhor
da sua assinatura real, desde que se tenha um grande número de amos
tras de treinamento.

REFERENCIAS BIBLIOGRÁFICAS

- ABDOU, I.E.; PRATT, W.K. Quantitative design and evaluation of enhancement thresholding edge detectors. *Proceedings of the IEEE*, 67(5):753-763, May 1979.
- AHUJA, N.; DAVIS, L.S.; HARALICK, R.M.; PANDA, D.P. *Image segmentation based on local gray level patterns*. Maryland Md., University of Maryland, 1977. (TR 551).
- CHEN, C. H. *Statistical pattern recognition*, Rochele Park, NJ, Hayden, 1973.
- COLEMAN, G.B.; ANDREWS, H.C. Image segmentation by clustering. *Proceedings of the IEEE*, 67(5) May 1979.
- DUBES, R.C. *The theory of applied probability*. Englewood Cliffs, NJ, Prentice Hall, 1968.
- DUDA, R.O.; HART, P.E. *Pattern classification and scene analysis*. New York, NY, John Wiley, 1973.
- GENERAL ELECTRIC (GE). *User manual*. Daytona Beach, FL, 1975.
- GNEDENKO, B.V.; KOLMOGOROV, A.N. *Limit distribution for sums of independent random variables*. Reading MA, Addison-Wesley, 1954.
- GRAMENOPOULOS, N. Automatic thematic mapping and change detection of ERTS-1 images. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3. Washington, DC, 1973. Proceedings. Washington, NASA, 1974. v. 1B, p. 1845-1875.
- HARALICK, R.M. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5):786-804, May 1979. Survey.
- HARALICK, R.M.; SHAMMUGAN, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMS-3(6):610-621, Nov. 1973.
- IISAKA, J. Texture analysis by space filter and applications to forestype classification. In: ANNUAL SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA, 5., West Lafayette, IN, 1979. Proceedings. New York, IEEE, c 1977. p. 392-393.

- LAINIOTIS, D.G. A class of upper bounds on probability for multihypotheses pattern recognition. *IEEE transactions on Information Theory*. IT-15:(6):730-731, Nov. 1979. Correspondence.
- LANDGREBE, D.A. Useful information from multispectral image data: another look. In: SWAIN, P.H.; DAVIS, S.H., eds. *Remote sensing the quantitative approach*. New York, NY, MacGraw Hill, 1978.
- LOGAN, T.L.; STRABLER, A.H. Use of a standart deviation based texture channel for LANDSAT classification of forest strata. In: ANNUAL SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA, 5., West Lafayette, IN, 1979. Proceedings. New York, IEEE, c 1979.
- PANDA, D.P. *Statistical analysis of some edge operators*. Maryland, MD, University of Maryland, 1977. (Tech.rep. 558).
- PARZEN, E. *Modern probability theory and its applications*. New York, NY, John Wiley, 1960.
- PRADO, L.O.C.; CORTEZ, I.R. *Computação digital de operadores gradiente e laplaciano de imagens do sistema I-100*. São José dos Campos, INPE, fev. 1976. (INPE-806-NTI/043).
- PRATT, W.K. *Digital Image Processing*. New York, NY, Wiley-Interscience, 1978.
- PRATT, W.K.; FAUGERAS, O.D. Decorrelation methods of texture feature extration. In: ADREWS, H.C.; PRATT, W.K. *Image understanding research*; semiannual technical report. Los Angeles, CA, Univ. of Southern California, IPI, 1979. p. 3-17. (USCIPI Report 860).
- 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, Jan. 1979.
- SWAIN, P.H. Fundamentals of pattern recognition in remote sensing. In: SWAIN, P.H.; DAVIS, S.H., eds. *Remote sensing - The quantitative approach*. New York, NY, McGraw-Hill, 1978.
- TUKEY, J.W. *Exploratory data analysis*. New York, NY, Addison Wesley, 1977.

VELASCO, F.R.D.; PRADO, L.O.C.; SOUZA, R.C.M. *Sistema Maxver: manual do usuário*. São José dos Campos, INPE, julho 1979. (INPE-1315-NTI/110).

WELCH, J.R.; SALTER, K.G. A context algorithm for pattern recognition and image interpretation. *IEEE Transactions on Systems Man and Cybernetics*, SMC-6(1):24-30, Jan. 1976.

APÊNDICE A

BIBLIOGRAFIA COMPLEMENTAR

- FUKUNAGA, K. *Introduction to statistical pattern recognition*. New York, NY, Academic, 1972.
- GREEN, J.R.; MARGERISON, D. *Statistical treatment of experimental data*. Amsterdam, Elsevier, 1978.
- GONZALEZ, R.C.; WINTZ, P. *Digital Image Processing*. Reading MA, Addison-Wesley, 1977.
- O'FILHO, E.F.; MASCARENHAS, N.D.A.; SONNENBURG, C.R. *Classificação de Imagens Multiespectrais através de características de textura*. São José dos Campos, INPE, maio, 1980. (INPE-1734-RPE/134).
- ROSENFELD, A.; KAK, A.C. *Digital picture processing*. New York, NY, Academic, 1976.
- WESZKA, J.; DYER, C.; ROSENFELD, A. A comparative study of texture measures of terrain classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMS-6(4):269-285, Ap. 1976.