

1. Classificação <i>INPE-COM.4/RPE</i> <i>C.D.U.: 681.3.01:621.385R</i>		2. Período	4. Distribuição
3. Palavras Chaves (selecionadas pelo autor) <i>CARACTERÍSTICAS DE TEXTURA</i> <i>MATRIZES DE COCORRÊNCIA</i> <i>EQUALIZAÇÃO DE HISTOGRAMA</i>			interna <input type="checkbox"/> externa <input checked="" type="checkbox"/>
5. Relatório nº <i>INPE-1734-RPE/134</i>	6. Data <i>Maio, 1980</i>	7. Revisado por <i>Flavio R.D. Velasco</i>	
8. Título e Sub-Título <i>CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS,</i> <i>ATRAVÉS DE CARACTERÍSTICAS DE TEXTURA</i>		9. Autorizado por <i>Nelson de Jesus Parada</i> Diretor	
10. Setor <i>DSE/DIN</i>	Código	11. Nº de cópias <i>10</i>	
12. Autoria <i>Enivaldo F. do Ó Filho</i> <i>Nelson D. A. Mascarenhas</i> <i>Claudio R. Sonnemburg</i>		14. Nº de páginas <i>86</i>	
13. Assinatura Responsável <i>Nelson Mascarenhas</i>		15. Preço	
16. Sumário/Notas <i>Este trabalho consiste na implementação de programas no sistema IMAGE-100, do INPE, destinados à extração de características espectrais e de textura, posterior utilização na classificação de imagens multiespectrais de recursos naturais, obtidas pelo satélite LANDSAT.</i>			
17. Observações			

INDICE

ABSTRACT	v
LISTA DE FIGURAS	vi
LISTA DE TABELAS	vii
<u>CAPÍTULO I - INTRODUÇÃO</u>	1
1.1 - Generalidades	1
1.2 - Objetivos	7
<u>CAPÍTULO II - TEXTURA</u>	9
2.1 - Textura visual	9
2.2 - Espectro de Potência de Fourier	10
2.3 - Estatísticas de diferenças de níveis de cinza	12
2.4 - Estatísticas de comprimentos de cadeias	13
<u>CAPÍTULO III - ESTATÍSTICAS DE OCORRÊNCIAS</u>	15
3.1 - Matrizes de coocorrência	15
3.2 - Equalização do histograma	19
3.3 - Características de textura	21
<u>CAPÍTULO IV - ESTUDO PRINCIPAL</u>	29
4.1 - Dados utilizados	29
4.2 - Procedimento	29
4.3 - Resultados	31
4.4 - Conclusões	51

AGRADECIMENTOS	53
BIBLIOGRAFIA	54
APENDICE A - PROCEDIMENTOS DE CLASSIFICAÇÃO	A.1
APENDICE B - LISTA DOS PROGRAMAS	B.1

ABSTRACT

This report describes programs for the IMAGE-100 system of INPE, for extraction of spectral and textural characteristics, followed by classification of LANDSAT earth resources multispectral images.

LISTA DE FIGURAS

I.1 - Respostas espectrais típicas	4
I.2 - Sistema para classificação automática de imagens	6
III.1 - Imagem simples e matrizes de coocorrência correspondentes	17
III.2 - Função de distribuição acumulada	20
IV.1 - Imagem LANDSAT do nordeste do Mato Grosso	30
IV.2 - Característica: ASM-M	33
IV.3 - Característica: XIDM-D	34
IV.4 - Característica: ENT-M	35
IV.5 - Característica: CORME-M	36
IV.6 - Característica: 7-M	37

LISTA DE TABELAS

IV.1 - Número de janelas classificadas corretamente, utilizando-se características individuais	40
IV.2 - Número de janelas classificadas corretamente, utilizando-se pares de características	41
IV.3 - Características chave: ASM-M	42
IV.4 - Características chave: VAR-M	43
IV.5 - Características chave: XIDM-M	44
IV.6 - Características chave: XIDM.D	45
IV.7 - Características chave: XIDM-F	46
IV.8 - Características chave: SUMVAR-M	46
IV.9 - Características chave: SUMENT-M	47
IV.10 - Características chave: ENT-M	47
IV.11 - Características chave: CORME-M	48
IV.12 - Conjunto de características	50

CAPÍTULO I

INTRODUÇÃO

1.1 - GENERALIDADES

O campo de processamento digital de imagens tem sido objeto de muita pesquisa nos últimos anos. Este fato está diretamente relacionado ao constante aperfeiçoamento dos computadores digitais, que a cada dia se tornam mais rápidos e com maior capacidade de memória principal. Isto tem tornado possível a realização em tempos, senão curtos, pelo menos aceitáveis de diversos tipos de operações sobre os dados de imagem. Entre os objetivos dessas operações pode-se citar:

- 1) Restauração: consiste na recuperação de uma imagem que tenha sido degradada por um processo qualquer (por exemplo, ruído).
- 2) Realce: através de diversas técnicas, procura-se melhorar a qualidade da imagem ou ressaltar determinados aspectos, a fim de facilitar a detecção de certas estruturas ou objetos, eliminando informação irrelevante.
- 3) Codificação: nesta área de atividades, procura-se desenvolver técnicas de representação de uma imagem, reduzindo o volume de dados a serem transmitidos ou armazenados.
- 4) Reconhecimento de Padrões: trata-se do problema da classificação de uma imagem ou subimagem, em uma das várias classes pré-especificadas

Talvez pelo fato de ser uma área de estudos bem recente, a maior parte das pesquisas realizadas se limitam à solução de problemas bem específicos, envolvendo certas classes particulares de imagens, e, são gradualmente, uma generalização de técnicas de processamento digital de imagens se forma (Rosenfeld, 1969).

Dentre as inúmeras aplicações do estudo de processamento de imagens, tem-se a destacar aquelas que utilizam imagens multiespectrais, obtidas através de sensores remotos a bordo de satélites ou aviões. Dentro dos respectivos campos, tem-se:

- 1) Geologia: identificação de tipos de terreno, exploração de minerais, localização de falhas, estudos de erosão.
- 2) Agricultura e Agronomia: identificação e planejamento de culturas, análise de prejuízos causados por incêndios, geadas e pragas, controle de desmatamento.
- 3) Ecologia: detecção e monitoramento de poluição, análise de qualidade de água.
- 4) Hidrologia e Hidrografia: monitoramento de cursos de rios, mapeamento da costa.
- 5) Geografia: planejamento rural e urbano, planejamento de estradas, pesquisa de recursos.
- 6) Cartografia: construção e revisão de mapas.

Pela importância e diversidade de aplicações, pode-se avaliar o impulso dado pelo desenvolvimento de técnicas de sensoriamento remoto à área de processamento digital de imagens. De fato, devido à grande quantidade de dados obtidos através desses sensores, tornou-se necessária uma utilização de meios automáticos para processar e analisar esta informação.

Uma imagem multiespectral contém na realidade várias imagens (canais) da mesma cena, onde cada canal contém a resposta, em termos de reflectância daquela região, a uma faixa estreita do espectro eletromagnético incidente sobre ela. Normalmente, são utilizados 4 canais (0.5-0.6, 0.6-0.7, 0.7-0.8, 0.8-1.1 μ m), correspondendo a faixas nas regiões de verde, vermelho, infravermelho próximo e intermediário. Assim, um ponto da imagem pode ser interpretado como um ponto no espa

ço espectral 4-dimensional, onde cada coordenada representa o nível de reflectância para a cor correspondente à região que ele representa.

A classificação automática de imagens multiespectrais baseia-se no fato de que cada material apresenta uma resposta espectral única. Isto é ilustrado na Figura I.1, onde se tem as respostas típicas da água, do solo e da vegetação. Desta forma, a informação dos quatro canais, em conjunto, é utilizada para tentar separar tipos distintos de materiais, de modo que materiais diferentes ocupem regiões distintas no espaço espectral 4-dimensional (assinaturas). Se as diversas classes são especificadas através de assinaturas ou através de densidades de probabilidade sobre o espaço espectral, então uma classe é atribuída a um ponto, se este pertence à assinatura correspondente àquela classe, ou se ela é a classe mais provável.

No primeiro caso, tem-se um procedimento determinístico que é o método utilizado, originalmente, pelo sistema IMAGE-100. A vantagem desse método é a possibilidade de treinamento e classificação poderem ser feitos para cada classe (tema), separadamente das demais. Embora seja possível minimizar a sobreposição de assinaturas, através de vários refinamentos na fase de treinamento, se acontecer de um ponto pertencer a mais de uma assinatura, o sistema se omitirá da classificação. No segundo caso (Classificação estatística pelo sistema MAXVER desenvolvido no INPE) este problema é superado, obtendo-se precisão bastante superior no processo.

A classificação, discutida acima, é em geral a mais utilizada, principalmente, em imagens multiespectrais. Ela é feita numa base de celsa de resolução, uma vez que cada ponto da imagem é classificado isoladamente, não sendo para isso considerada a vizinhança do mesmo.

Pode-se também fazer a classificação numa base de bloco de celas de resolução contíguas. Um exemplo seria o caso da identificação do tipo de cultura de um campo inteiro de plantação. A chave

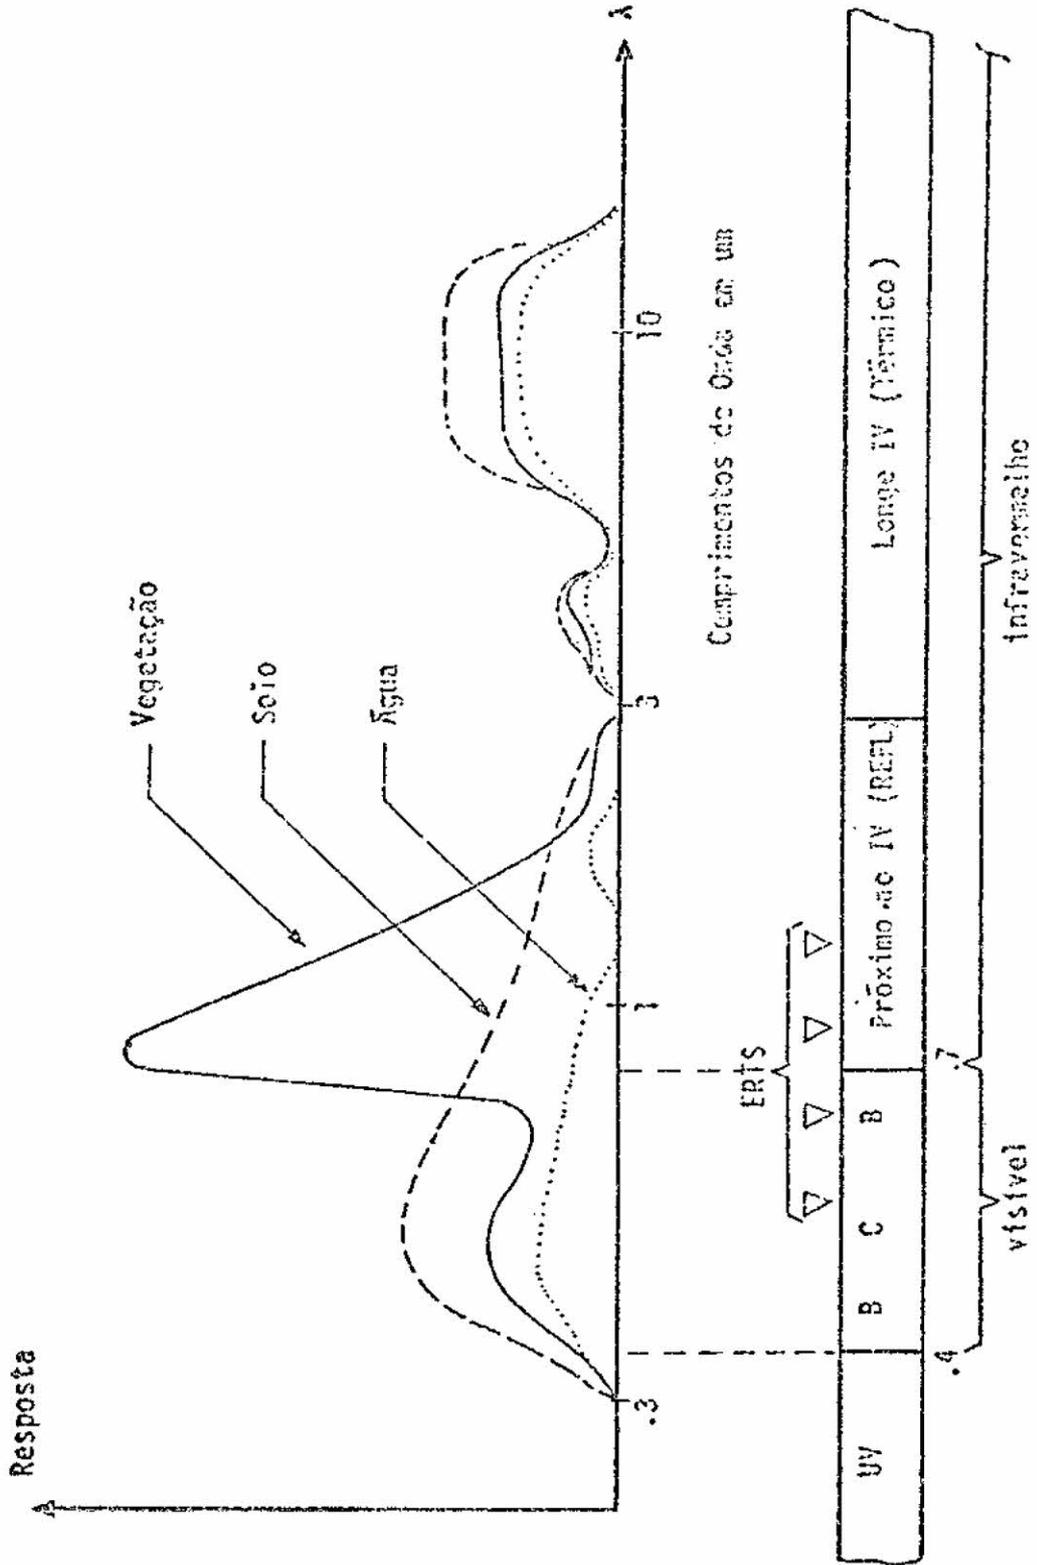


Fig. I.1 - Respostas espectrais típicas

da classificação deste tipo é a definição de um conjunto de características significativas, que contenham a informação de interesse, contida no bloco. Obviamente este conjunto é muito dependente da aplicação que se tem em vista. Por exemplo, um bom conjunto de características, para fins de classificação de microfotografias de células do sangue, talvez não fosse viável para diagnóstico automático de radiografias do tórax, nem tampouco para reconhecimento do tipo de terreno de certa região. Porém, uma vez escolhido esse conjunto de características, pode-se utilizar uma das diversas técnicas de reconhecimento de padrões, para efetuar a classificação propriamente dita (categorização).

No presente trabalho, sô consideraremos a classificação feita numa base de bloco de celas de resolução contíguas (janela). Portanto, as etapas distintas, em que um sistema classificador desse tipo se divide, são:

- 1) Preprocessamento: nesta fase, a janela a ser classificada passa por uma ou várias operações, de modo a evidenciar determinadas características que serão usadas para representá-la, ou então, com a finalidade de tornar estas características, invariantes em relação à posição, orientação, etc.
- 2) Extração de características: consiste na realização de uma série de medidas sobre a janela preprocessada, com a finalidade de se obter um vetor de características (ou primitivas) único, que represente aquela janela. A finalidade desta etapa é a redução da complexidade do sistema, cujo desempenho vai depender de uma boa escolha das características a serem extraídas (estas devem caracterizar propriedades comuns a todos os membros de cada classe). Como já foi dito, esta é a parte mais dependente daquilo que o sistema se propõe a classificar.
- 3) Categorização: como resultado da segunda etapa, tem-se uma ênupla de números reais, representando a janela em questão. Esta ênupla pode ser imaginada como um ponto dentro do espaço n-dimensional. Tem-se, então, um problema típico da área de reconhecimento de padrões, onde existe um grande número de métodos

para o projeto de categorizador (Tou and Gonzales, 1974; Fukunaga, 1972; Meisel, 1972).

A Figura I.2 apresenta um sistema prático para classificação automática de imagens

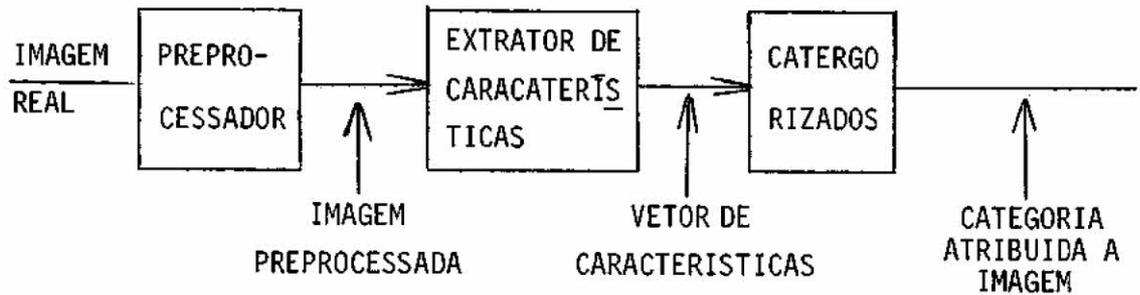


Fig.I.2 - Sistema para classificação automática de imagens.

Sendo uma imagem o objeto da classificação, é natural que se utilizem características similares àquelas usadas pelo ser humano, na interpretação visual de uma fotografia. Para isto, ele utiliza três propriedades fundamentais: tonalidade, textura e contexto. Estas características sempre estão presentes numa imagem, embora eventualmente uma delas possa estar mais evidente. Da mesma forma, tem-se 3 tipos de características que podem ser utilizadas para efeito de classificação:

- espectrais: descrevem, em termos estatísticos, a distribuição dos níveis de cinza dos pontos do bloco considerado.
- textura: contêm informação sobre a distribuição especial das variações de níveis de cinza, dentro de um canal.
- contextuais: trazem informação derivada dos pontos ou blocos de imagem que estão mais próximos ao bloco que está sendo analisado.

É interessante notar que, embora seja fácil para um observador humano reconhecer e descrever, em termos empíricos, a textura, ela tem sido refratária a uma definição precisa e a uma análise exata por computadores digitais (Haralick et al., 1973 c).

No Capítulo II, tratar-se-ã da textura e dos tipos mais comuns de técnicas utilizadas para medi-la.

1.2 - OBJETIVOS

Haralick et al., (1973 c) sugeriram uma sãrie de medi das de textura, baseadas nas matrizes de coocorrãncia ou de dependãn cia espacial de nãveis de cinza. Os resultados encontrados mostraram a utilidade dessas caracterãsticas na classificaãõ de microfotografias, de rochas e de tipos de terreno, em imagem multiespectrais de satãli tes e em fotografias aãreas.

Este trabalho consiste na implementaãõ de programas no Image-100, visando a extraãõ das caracterãsticas de textura, cita das, em conjunto com caracterãsticas espectrais, e subsequente utiliza çãõ na classificaãõ de tipos de terreno. A imagem utilizada foi uma do LANDSAT de nã 175152-123730-7, obtida na passagem do dia 1/6/75. Um mapa geolãgico foi considerado como a verdade terrestre, para efeito de anãlise de desempenho das caracterãsitcas.

Foi desenvolvido tambãem um programa para visualizaãõ, no terminal Tektronix, da capacidade de separaãõ de duas classes quais quer, utilizando uma determinada caracterãstica.

O computador utilizado foi um PDP 11/45, que ã o contro lador de processos do sistema IMAGE-100, com uma memãria central de 48K. A linguagem usada em todos os programas foi FORTRAN-IV.

CAPÍTULO II

TEXTURA

2.1 - TEXTURA VISUAL

O mundo que nos cerca contém uma grande variedade de texturas. De fato, a textura é uma propriedade inerente a todas as superfícies. Pode-se qualificá-la como sendo fina, grossa, irregular, lisa, linear e mais um sem número de adjetivos.

Embora todos tenham noção do significado de textura, é muito difícil defini-la em termos científicos precisos. Pickett (1970) observa que, para um padrão visual ser visto como uma textura, ele deve ter as seguintes características:

- 1) um grande número de elementos (variações espaciais em intensidade ou comprimentos de onda);
- 2) os elementos e as regras de espaçamento ou arranjo podem ser arbitrariamente manipulados, desde que uma característica de repetitividade ainda continue;
- 3) desde que haja suficiente detalhe em um pequeno ângulo de visão, uma textura característica desponta, mesmo quando os elementos básicos ou os espaçamentos são aleatoriamente distribuídos.

Vê-se que os atributos básicos de uma textura visual são *muitas e repetitivas variações*

Não é ainda bem conhecida a maneira pela qual o ser humano detecta e analisa informação textural, no processo de percepção visual de uma cena. Julesz (1965 e 1975) considera que existem dois níveis distintos de percepção visual de textura. Um espontâneo ou impressionista, caracterizado por uma percepção pura e outro deliberado, que exige a utilização de processo cognitivos para ser completa a per

cepção. Trabalhando com imagens artificiais obtidas por computador, ele investiga a importância da textura na percepção visual humana e analisa as diversas limitações dessa percepção.

Também na aplicação específica em imagens, não se encontra um método perfeito de análise de textura. Sabe-se, entretanto, que ela desempenha papel importante, na detecção e no reconhecimento de objetos (Pickett, 1970), e na discriminação de tipos diferentes (Haralick et al., 1973 c e Haralick e Bosley, 1973 a). Hawkins (1970) mostra as dificuldades existentes no trabalho de extração de informação textural e conclui que a classificação de texturas é uma das mais difíceis tarefas, no campo de processamento de imagens.

A textura pode ser analisada em dois níveis: o estatístico e o estrutural. Do ponto de vista estatístico, a textura é definida através de um conjunto de parâmetros estatísticos, obtidos de um grande número de medidas locais, feitas na imagem. Do ponto de vista estrutural, tenta-se localizar elementos que ocorrem repetidamente e descobrir as regras de organização dos mesmos, dentro de determinadas subáreas da imagem. Quando se trabalha com imagens naturais, geralmente se utiliza o método estatístico, pois o estrutural é mais complicado.

A seguir serão mostradas algumas das técnicas mais comuns, usadas para fins de classificação de imagens, no sentido considerado neste trabalho, que é o de discriminação de blocos de células de resolução, em categorias preespecificadas.

2.2 - ESPECTRO E POTÊNCIA DE FOURIER

A transformada de Fourier, de uma imagem $f(x,y)$, é definida como:

$$F(u,v) = \int_{-\infty-\infty}^{+\infty+\infty} \int e^{-2\pi j (ux + vy)} f(x,y) dx dy$$

O valor da potência num ponto (u,v) é:

$$|F(u,v)|^2 = F(u,v) \cdot F^*(u,v)$$

As características de textura, baseadas em medidas do espectro de potência de Fourier, utilizam dois fatos:

- 1) A distribuição radial (no espaço transformado) dos valores de potência está relacionada à rugosidade da textura. Enquanto uma textura grossa tem valores altos de potência perto da origem, numa textura fina, os valores de potência são mais espalhados.
- 2) A distribuição angular dos valores de potência está relacionada à direcionalidade (existência de bordas e linhas numa certa direção) da textura. Uma textura orientada numa direção θ terá valores altos de potência, concentrados perto da perpendicular a esta direção.

Estes fatos sugerem que sejam usadas características de textura, que sejam relacionadas às médias da potência, ao longo de anéis centrados na origem (para análise de rugosidade) e ao longo de cunhas (para análise de direcionalidade)

A transformada discreta de Fourier, de uma imagem digital de $N \times N$ pontos, é:

$$F(u,v) = \frac{1}{N^2} \sum_{m=0}^{N-1} \sum_{n=0}^{N-1} f(m,n) e^{2\pi j (\mu u + \nu v)},$$

$$0 \leq u, v \leq N-1$$

Tem-se, então, dois tipos padrões de medida de textura, baseados no espectro de potência:

$$\Phi_{r_1, r_2} = \sum_{r_1^2 < u^2 + v^2 < r_2^2} |F(u,v)|^2, \quad r_1 \text{ e } r_2 \text{ arbitrários.}$$

$$\Phi_{\theta_1, \theta_2} = \sum_{\theta_1 \leq \text{tg}^{-1}(v/u) < \theta_2} |F(u,v)|^2, \quad \theta_1 \text{ e } \theta_2 \text{ arbitrários.}$$

Pode-se também fazer uma combinação desses tipos, o que corresponderia a calcular o somatório dos valores de potência, na interseção de anéis e cunhas.

Pelo fato de, em geral, a imagem não ser periódica, sendo seus lados opostos descontínuos, aparece uma direcionalidade adicional na horizontal e na vertical, que não deve ser levada em conta.

2.3 - ESTATÍSTICAS DE DIFERENÇAS DE NÍVEIS DE CINZA

Considere-se uma imagem digital $f(m,n)$ quantizada em N níveis de cinza. Para um deslocamento arbitrário $d = (\Delta m, \Delta n)$, onde Δm e Δn são inteiros, é computado um vetor N -dimensional p_d , da seguinte forma: sua i -ésima componente $p_d(i)$ é o número de pares de pontos da imagem separados de d , tendo uma diferença de níveis de cinza igual a i . Se este vetor for normalizado, $p_d(i)$ fornece uma estimativa da probabilidade de que $f_d(m,n) = |f(m,n) - f(m + \Delta m, n + \Delta n)|$ assumo o valor i .

Observe-se que, para uma textura grossa e d pequeno, comparado ao tamanho do elemento de textura, é esperado que os pares de pontos separados de d tenham, normalmente, níveis de cinza próximos, de modo que $p_d(i)$ assume valores altos para i 's baixos. Da mesma forma, se a textura for fina e d for comparável ao tamanho do elemento, então, espera-se uma melhor distribuição dos valores das componentes de p_d .

Medindo-se o grau de espalhamento dos valores em p_d para vários d 's pode-se, então, ter uma medida da rugosidade da textura. Tem-se por exemplo, as características:

$$\text{- Contraste: } \text{CON} = \sum_{i=1}^{N-1} i^2 \cdot p_d(i)$$

$$\text{- Média : } \text{MED} = \frac{1}{N} \sum_{i=1}^{N-1} i \cdot p_d(i)$$

Além dessas características, pode-se obter informação adicional sobre a direcionalidade da textura, quando se comparam os diversos graus de espalhamento de p_d à medida que a direção de d é variada e sua magnitude é mantida constante.

Outro conjunto de característica deste tipo pode ser obtido através de vetores p_d extraídos, não a partir de pares de pontos isolados, mas fazendo-se uma média de níveis de cinza sobre um grupo de pontos vizinhos.

2.4 - ESTATÍSTICAS DE COMPRIMENTOS DE CADEIAS

Dividem-se os N níveis de cinza em M faixas distintas. Uma matriz é, então, obtida de modo que seu elemento $p(i,j)$ seja o número de cadeias de comprimento j , em uma direção θ , consistindo de pontos, cujos níveis de cinza estejam dentro da i -ésima faixa.

É bem intuitivo o significado dessas cadeias: se uma textura é grossa, espera-se encontrar cadeias longas, ao passo que se a textura for fina, as cadeias serão mais curtas.

Utilizando-se parâmetros convenientes dessa matriz (por exemplo, um que dependa fortemente do número de cadeias longas), é possível obter medidas do tipo de textura da imagem. A direcionalidade pode ser medida através do levantamento de várias dessas matrizes, uma para cada direção θ das cadeias.

Como este tipo de medidas é muito dependente de ruído, pode-se fazer um pré-processamento, que consiste em um alisamento da imagem, de modo a minimizar esta influência.

CAPÍTULO III

ESTATÍSTICAS DE OCORRÊNCIAS

No segundo capítulo foram citados dois tipos de medidas de textura, baseadas em estatísticas de propriedades locais. Num, estas propriedades eram diferenças de níveis de cinza e no outro, comprimento de cadeias.

Neste capítulo, é mostrado com mais detalhes um terceiro tipo de estatísticas proposto por Haralick (1973 c), baseado nas matrizes de dependência espacial de níveis de cinza, ou matrizes de ocorrência. Assume-se que toda a informação de textura, existente, pode ser convenientemente representada (ou codificada) por um conjunto de matrizes computadas, para várias direções e distâncias entre pares de celas de resolução da imagem.

3.1 - MATRIZES DE COCORRÊNCIA

Suponha-se que a imagem digital em análise, com N níveis de cinza, seja retangular e constituída de N_x celas de resolução na direção horizontal e N_y celas de resolução na direção vertical. Uma tal imagem será denominada janela. Aqui, não se considera pontos, mas celas de resolução, porque pode-se também trabalhar com vizinhanças de pontos elementares, e portanto, com níveis de cinza médios nestas vizinhanças. Sejam:

$$L_x = \{1, 2, \dots, N_x\} \dots \text{domínio espacial horizontal}$$

$$L_y = \{1, 2, \dots, N_y\} \dots \text{domínio espacial vertical}$$

$$G = 1, 2, \dots, N \dots \text{conjunto dos níveis de cinza possíveis.}$$

$$L_y \times L_x \dots \text{conjunto de todas as celas de resolução da janela.}$$

Nesta notação, a imagem seria uma função I , que associa a cada cela de resolução, algum nível de cinza, isto é, $I: L_x \times L_y \rightarrow G$.

Cada matriz é construída de modo que, para uma direção θ e uma distância especificada d , seu elemento $P(i,j)$ seja a frequência de ocorrência na janela de pares de resolução distanciados de d , numa posição a θ^0 , uma com nível de cinza i e a outra com nível de cinza j .

São usadas direções θ iguais a 0^0 , 45^0 , 90^0 e 135^0 . Definindo formalmente cada matriz, tem-se:

$$P(i,j,d,0^0) = \# \{((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid k-m=0, |l-n|=d, \\ I(k,l) = i, \quad I(m,n) = j\}$$

$$P(i,j,d,90^0) = \# \{((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid |k-m|=d, l-n=0, \\ I(k,l) = i, \quad I(m,n) = j\}$$

$$P(i,j,d,45^0) = \# \{((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid (k-m=d, l-n=-d) \\ \text{ou } (k-m = -d, l-n=d), I(k,l) = i, I(m,n) = j\}$$

$$P(i,j,d,135^0) = \# \{((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid (k-m=d, l-n=d) \\ \text{ou } (k-m=-d, l-n=-d), I(k,l)=i, I(m,n) = j\}$$

onde $\#$ significa o número de elementos do conjunto.

Na realidade, como se pode ver das definições das matrizes, o conceito de distância, utilizado, não foi euclidiano:

$$\text{dist}((k,l),(m,n)) = \max\{|k-m|, |l-n|\}$$

Pode-se também observar que essas matrizes são simétricas, isto é, $P(i,j,d,\theta) = P(j,i,d,\theta)$.

A Figura III.1 mostra uma imagem simples 4 x 4, com 3 níveis, e as matrizes correspondentes no caso da distância ser unitária.

$\begin{matrix} 1 & 1 & 2 & 3 \\ 1 & 2 & 3 & 3 \\ 2 & 2 & 2 & 3 \\ 3 & 1 & 1 & 2 \end{matrix}$	$P_0 = \begin{bmatrix} 4 & 3 & 1 \\ 3 & 4 & 3 \\ 1 & 3 & 2 \end{bmatrix}$	$P_{45} = \begin{bmatrix} 2 & 1 & 1 \\ 1 & 4 & 3 \\ 1 & 3 & 2 \end{bmatrix}$
	$P_{90} = \begin{bmatrix} 2 & 4 & 0 \\ 4 & 2 & 3 \\ 0 & 3 & 4 \end{bmatrix}$	$P_{135} = \begin{bmatrix} 0 & 4 & 1 \\ 4 & 4 & 1 \\ 1 & 1 & 2 \end{bmatrix}$

Fig. III.1 - Imagem simples e matrizes de coocorrência correspondentes.

Na determinação, por exemplo, do elemento (3,2) da matriz horizontal ($\theta = 0^\circ$), conta-se o número de pares de celas adjacentes, horizontalmente, tal que a primeira tenha nível 3 e a segunda nível 2.

Devido à definição das matrizes, nota-se que cada par de celas contíguas é contado duas vezes. A primeira no levantamento da entrada (i,j) da matriz, e a segunda no da entrada (j,i), onde i e j são os níveis de cinza das duas celas.

Pode-se fazer uma normalização de cada uma dessas matrizes, de modo que a soma de todos os seus elementos unitária. Para isto é necessário o cálculo do número R de celas de resolução vizinhas (de acordo com θ e d). No caso de distância 1, tem-se:

$\theta = 0^\circ$: para cada linha existem $2(N_x - 1)$ pares de celas vizinhas. Como existem N_y linhas, há um total de $R_H = 2N_y (N_x - 1)$

$\theta = 90^\circ$: analogamente, $R_V = 2N_x (N_y - 1)$

$\theta = 45^\circ$: para cada linha, à exceção da primeira, existem $2(N_x - 1)$ pares de células vizinhas. Então $R_D = 2(N_x - 1)(N_y - 1)$

$\theta = 135^\circ$: analogamente, $R_E = 2(N_y - 1)(N_x - 1)$

Para uma distância d qualquer, obviamente menor que N_x e N_y , tem-se:

$$R_H = 2N_y(N_x - d)$$

$$R_D = 2(N_x - d)(N_y - d)$$

$$R_V = 2N_x(N_y - d)$$

$$R_E = 2(N_x - d)(N_y - d)$$

Após a normalização, pode-se encarar um certo elemento $P(i,j)$ de cada matriz, como sendo uma estimativa da probabilidade de que um dado par de células de resolução, satisfazendo a relação espacial para a qual a matriz foi computada, tenha níveis de cinza i e j . Embora a normalização não traga informação adicional sobre a textura da imagem, uma vez que os elementos $p(i,j)$ são iguais aos $P(i,j)$ da matriz não normalizada, a menos que uma constante multiplicativa adequada, ela se apresenta muito útil em dois aspectos:

- 1) aspecto computacional: após a extração das matrizes, é feito um intenso processamento, visando a obtenção de características de textura. Algumas operações envolvidas podem levar a uma ultrapassagem da capacidade de representação de números reais no computador. Isto ocorre, principalmente, quando a janela é constituída de muitas células de resolução:
- 2) de certa forma a normalização torna as características independentes das dimensões da janela que representam, dependendo apenas do tipo de textura contida. Ou seja, duas janelas com texturas idênticas, uma estando contida na outra, forneceriam as mesmas características. Isto, entretanto, ocorre dentro de certos limites, pois se a janela menor for muito pequena, ela po

de não conter informação de textura suficiente, de modo que seria mal caracterizada.

A esta altura é interessante citar dois aspectos relacionados à obtenção das matrizes de coocorrência. O primeiro é o fato de que o número de operações necessárias, para processar uma janela, é diretamente proporcional ao número n de celas de resolução existentes. Em comparação, para se obter transformadas de Fourier ou Hadamard, para fins de medida de textura, este número seria proporcional a $n \cdot \log n$. O segundo aspecto é que só há necessidade de trazer, à memória do computador, duas linhas da janela ao mesmo tempo, não havendo, portanto, forte exigência de armazenamento neste tipo de processamento.

3.2 - A EQUALIZAÇÃO DO HISTOGRAMA

No processo de digitalização da imagem, cada valor do grau de cinza é quantizado sobre uma faixa finita de níveis possíveis. Em consequência, pode ser computado um histograma de níveis de cinza que, a menos de uma constante, seria uma estimativa da função densidade de probabilidade da variável nível de cinza para aquela imagem.

A equalização do histograma consiste num processo após o qual, todos os níveis de cinza, da imagem transformada, apresentam a mesma frequência de ocorrência.

Embora a textura e a tonalidade sejam duas propriedades que se interrelacionam, é natural e desejável que duas imagens de uma mesma cena, uma com níveis de cinza iguais aos da outra, a menos de uma constante aditiva (o que equivale a um histograma deslocado), forneçam características de textura iguais. A equalização do histograma garante que duas imagens, uma sendo transformação monotônica da outra, fornecem os mesmos resultados (Haralick et al., 1973 c).

Na prática, esta transformação monotônica pode ser devida a diferenças de iluminação, revelação, filmes, lentes ou digitalizador.

Além disso, a equalização permite que se fixe o número de níveis de cinza com que se está interessado em trabalhar. Isto é importante, devido à necessidade de armazenamento das matrizes. Existindo N níveis de cinza, é necessário o uso de N^2 palavras reais de memória para cada matriz (ou $N(N+1)/2$, no caso de se utilizar a propriedade de simetria). Acontece que a maioria das imagens apresentam um histograma concentrado numa faixa estreita de níveis de cinza. Aqui, não se tratando de acentuar ou melhorar visualmente o contraste, pode-se simplesmente trabalhar com um número de níveis aceitável pelo computador e compatível com esta faixa estreita do histograma.

No caso específico deste trabalho, a equalização admite que a imagem tenha no máximo 256 níveis (resolução máxima do sistema I-100), transformando-se em 32 níveis equalizados. O mecanismo é similar ao uso na transformação de distribuições em Estatística.

Seja o histograma da imagem no canal, em que a textura vai ser utilizada para efeito de classificação $A(i)$, $i=0,255$. A partir dele, obtêm-se a função de distribuição acumulada dos níveis de cinza, conforme a Figura III.2.

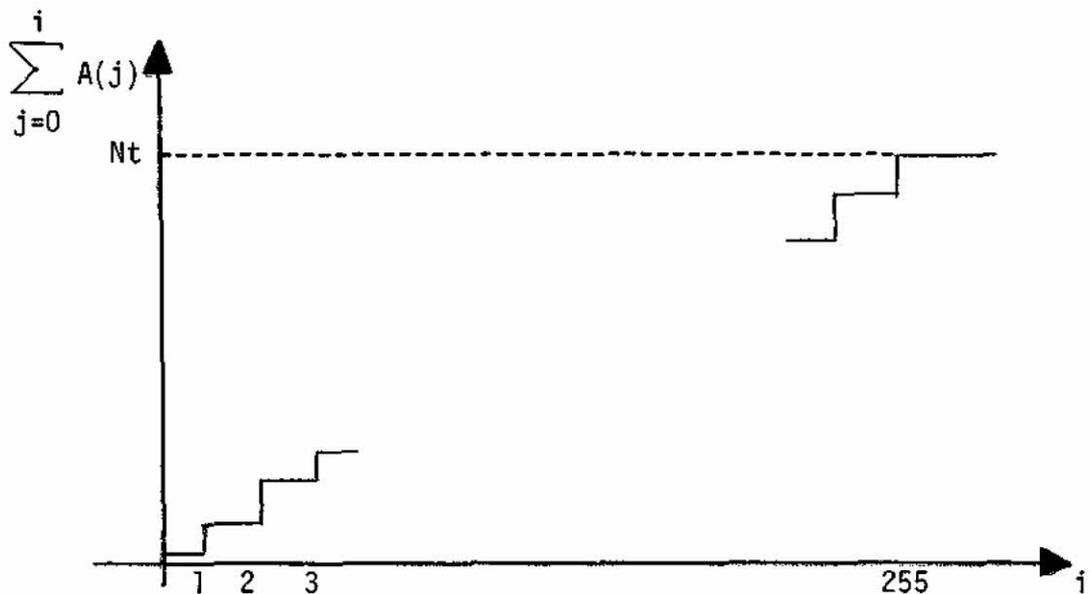


Fig. III.2 - Função de distribuição acumulada

Então, é gerada uma tabela, relacionando os níveis, na imagem original, aos correspondentes após a equalização, de modo que se

$$\left(\frac{K-1}{32}\right) \leq \frac{\sum_{j=0}^i A(j)}{NT} \leq \left(\frac{K}{32}\right) \quad (1)$$

então, ao nível i será assinalado o nível k .

Pelo fato da distribuição ser discreta, aparecem problemas nas transações entre níveis da imagem transformada, quando então um certo nível, na imagem original, teria que ser designado para dois níveis diferentes. Isto seria resolvido com o uso, na fase de equalização propriamente dita, de uma sub-rotina, de números aleatórios de modo a se "rachar" um certo nível em dois outros, fornecendo uma equalização mais refinada. Como isto, forçosamente, demandaria um tempo considerável, resolveu-se fazer, simplesmente, uma escolha pela melhor colocação daquele nível original em um dos dois níveis transformados, não sendo portanto, a equação (1) seguida à risca.

Seria interessante citar que, pelo menos na imagem utilizada, normalmente uma janela de 62 x 62 pontos não apresenta mais que 40 níveis de cinza, com frequência de ocorrência não nula, não sendo, portanto, necessária a utilização de um número maior de níveis na janela equalizada.

3.3 - CARACTERÍSTICAS DE TEXTURA

A seguir, mostra-se como são obtidas as medidas de textura, a partir de cada uma das matrizes de coocorrência (Haralick, 1973c). Como estas matrizes são simétricas, na definição de algumas destas medidas, este fato já foi levado em conta.

Sejam:

N... número de níveis de cinza após a equalização da janela
 $p(i,j)$... elemento (i,j) da matriz de coocorrência já normalizada.

$$\text{ALFA } (i) = \sum_{j=1}^N p(i,j) \dots \text{ soma dos elementos da } i\text{-ésima linha (ou coluna)}$$

$$\text{BETA } (k) = \sum_{i=1}^N \sum_{\substack{j=1 \\ i+j=k}}^N p(i,j), \quad k = 2,3 \dots, 2N \text{ soma dos elementos da } k\text{-ésima diagonal secundária}$$

$$\text{GAMA } (k) = \sum_{i=1}^N \sum_{\substack{j=1 \\ |i-j|=k}}^N p(i,j), \quad k = 0,1 \dots, N-1 \text{ duas vezes a soma dos elementos da } k\text{-ésima diagonal.}$$

$$u = \sum_{i=j}^N \sum_{j=1}^N i p(i,j) = \sum_{i=1}^N i \text{ ALFA } (i)$$

$$v = \left[\left[\sum_{j=1}^N \sum_{i=1}^N i^2 p(i,j) \right] - u^2 \right]^{1/2} = \left[\sum_{i=1}^N i^2 \text{ ALFA } (i) - u^2 \right]^{1/2}$$

Tem-se, então, as características:

1) Momento angular de 2a. ordem: (ASM)

$$F1 = \sum_{i=1}^N \sum_{j=1}^N \{p(i,j)\}^2$$

2) Contraste: (CONT)

$$F2 = \sum_{n=0}^{N-1} n^2 \text{ GAMA } (n)$$

3) Correlação: (COR)

$$F3 = \frac{\left[\sum_{i=1}^N \sum_{j=1}^N (i-j) p(i,j) \right] - u^2}{v^2}$$

4) Variância: (VAR)

$$F4 = \sum_{i=1}^N \sum_{j=1}^N (i-u)^2 p(i,j)$$

5) Momento inverso da diferença: (XIDM)

$$F5 = \sum_{i=1}^N \sum_{j=1}^N \frac{p(i,j)}{1 + (i-j)^2}$$

6) Média da soma: (SUMAVE)

$$F6 = \sum_{i=2}^{2N} i \text{ BETA } (i)$$

7) Variância da soma: (SUMVAR)

$$F7 = \sum_{i=2}^{2N} (i-F6)^2 \text{ BETA } (i)$$

8) Entropia da soma: (SUMENT)

$$F8 = - \sum_{i=2}^{2N} \text{ BETA } (i) \ln (\text{ BETA } (i))$$

9) Entropia: (ENT)

$$F9 = - \sum_{i=1}^N \sum_{j=1}^N p(i,j) \ln(p(i,j))$$

10) Variância da Diferença:

$$F10 = - \sum_{i=0}^{N-1} (i-DIF)^2 \text{ GAMA } (i), \text{ onde } DIF = \frac{N-1}{\sum_{i=0}^{N-1} i \text{ GAMA } (i)}$$

11) Entropia da Diferença: (DIFERENT)

$$F11 = - \sum_{i=0}^{N-1} \text{ GAMA } (i) \ln (\text{GAMA}(i))$$

12) Medida adicional de correlação: (CORME)

$$F12 = \frac{F9 - HXY}{HX} \text{ onde:}$$

$$HX = - \sum_{i=1}^N \text{ ALFA } (i) \ln (\text{ALFA } (i))$$

$$HXY = - \sum_{i=1}^N \sum_{j=1}^N p(i,j) \ln \{ \text{ALFA } (i) \text{ ALFA } (j) \}$$

Além destas, foram sugeridas mais duas outras medidas de correlação:

$$F13 = (1 - \exp \{-1(HXY^2 - F9)\}), \text{ onde}$$

$$HXY2 = - \sum_{i=1}^N \sum_{j=1}^N ALFA(i) ALFA(j) \ln \{ ALFA(i) ALFA(j) \}$$

F14 = (2Q maior autovalor de Q)^{1/2}, onde:

$$Q(i,j) = \sum_{k=1}^N \frac{p(i,k) p(j,k)}{ALFA(i) ALFA(j)}$$

Inicialmente todas as medidas foram implementadas. O F13 geralmente causava problema de "overflow", mesmo com a normalização das matrizes e com utilização de logaritmo decimal no cálculo de F9 e HXY2. O F14, além de exigir uma memória extra, pois a matriz Q deveria ser calculada com precisão estendida, tomava muito tempo da máquina. Por estes motivos não foram mais utilizadas estas duas medidas, na implementação final do programa extrator de características. Em compensação devido à relativa folga de memória, foi possível uma maior interação entre o usuário e o programa, além de grande economia de tempo.

Embora seja difícil explicar o que representa exatamente cada uma destas medidas, é intuitivo, pelo menos para algumas, o seu significado.

Ao se analisar o ASM, vê-se que ele é pequeno quando todos os elementos da matriz são aproximadamente iguais, aumentando a medida que alguns elementos ficam maiores que os outros. Isto pode ser encarado como uma medida de homegeneidade, pois numa imagem homogênea existem poucas transições de níveis de cinza dominantes.

O CONT mede o momento de inércia da matriz em relação à sua diagonal principal. Sendo a medida mais natural do espalhamento dos valores da matriz. Note-se que, se a textura for grossa e a distância d pequena, em relação ao tamanho do elemento de textura, os pares de pontos separados de d devem normalmente ter valores próximos de níveis

de cinza. Isto implica em que os elementos, próximos à diagonal principal, deverão assumir valores elevados. Por outro lado, se a textura for fina e a distância d comparável ao tamanho do elemento de textura, os pares de pontos separados de d terão níveis de cinza mais separados, ou seja, haverá um espalhamento uniforme dos valores da matriz. O CONT medirá, então, a quantidade de variações locais de níveis de cinza, presentes na imagem, ou seja, o contraste.

A correlação (COR) fornece uma medida de quão similares são as linhas ou colunas da matriz de coocorrência. Se os valores são bem distribuídos, tem-se alta correlação, enquanto que, no caso contrário, tem-se baixa correlação (por exemplo, quando os valores longe da diagonal são muito pequenos). Em termos de textura, a correlação fornece uma medida das dependências lineares dos níveis de cinza na imagem (Haralick, 1973 c).

Cada uma das medidas citadas é extraída de uma matriz, sendo, portanto, função da direção e da distância para as quais ela foi obtida. É claro que é bastante informativo o fato de uma certa textura ser direcional, apresentando estruturas em uma certa orientação. Contudo, não se está interessado na direção particular dessas estruturas. É interessante, portanto, que sejam utilizadas características de textura que sejam invariantes à orientação da imagem, mas ao mesmo tempo tragam informação de direcionalidade. Obviamente, não seria o caso de se utilizar diretamente as características obtidas das quatro matrizes.

Foram utilizadas funções dessas características, da seguinte forma: supondo que uma determinada janela tenha características a , b , c e d , correspondendo às quatro direções, obteve-se a média, a faixa de variações e o desvio padrão deste conjunto, os quais são invariantes a uma rotação da janela.

Tem-se, então, um conjunto de 12×3 características de textura que agora poderão ser utilizadas como dados de entrada para o classificador. É certo que existe uma forte dependência entre várias

dessas 36 medidas, e a utilização de todas ao mesmo tempo traria muita informação supérflua ao classificador, sendo, portanto, necessária uma seleção de características. Isto se constitui num problema básico da área de reconhecimento de padrões.

Não consta do presente trabalho um programa de seleção de características. Entretanto, foi implementado um programa (HGRAM) que permite uma comparação das distribuições de duas classes arbitrárias, em relação a uma determinada característica, através de uma discretização dos valores assumidos por esta característica e posterior levantamento dos histogramas relativos às classes escolhidas.

CAPITULO IV

ESTUDO PRINCIPAL

4.1 - DADOS UTILIZADOS

Para este estudo foi utilizada uma imagem do LANDSAT de número 175152-123730-7, do nordeste de Mato Grosso, obtida na passagem do dia 1 de junho de 1975. Um mapa geológico do Departamento Nacional da Produção Mineral, do Ministério das Minas e Energia, foi usado para separar três tipos principais de terreno existentes:

Tipo A: Pré-cambriano

Tipo B: Coberturas detríticas

Tipo C: Pleistoceno

A Figura IV.1 mostra a banda nº 7 da imagem (infravermelho intermediário), que foi escolhida para análise de textura. Foram selecionadas 182 janelas de 62 x 62 pontos, sendo 57 da categoria A, 62 da B e 62 da C.

4.2 - PROCEDIMENTO

Usou-se a mesma resolução obtida com o LANDSAT, ou seja, cada ponto da imagem no sistema I-100, correspondente a exatamente um ponto da imagem do LANDSAT. Como esta é composta de 3240 x 2340 pontos, e a capacidade máxima da memória de imagem do sistema I-100 é de 512 x 512 pontos, foram necessárias várias etapas para que toda a imagem fosse processada.

Considerando-se a resolução da imagem do LANDSAT, onde cada ponto representa uma área de cerca de 70 m x 60m, foi usada a distância unitária para obtenção das matrizes de coocorrência.



Fig. IV.1 - Imagem LANDSAT do nordeste do Mato Grosso.

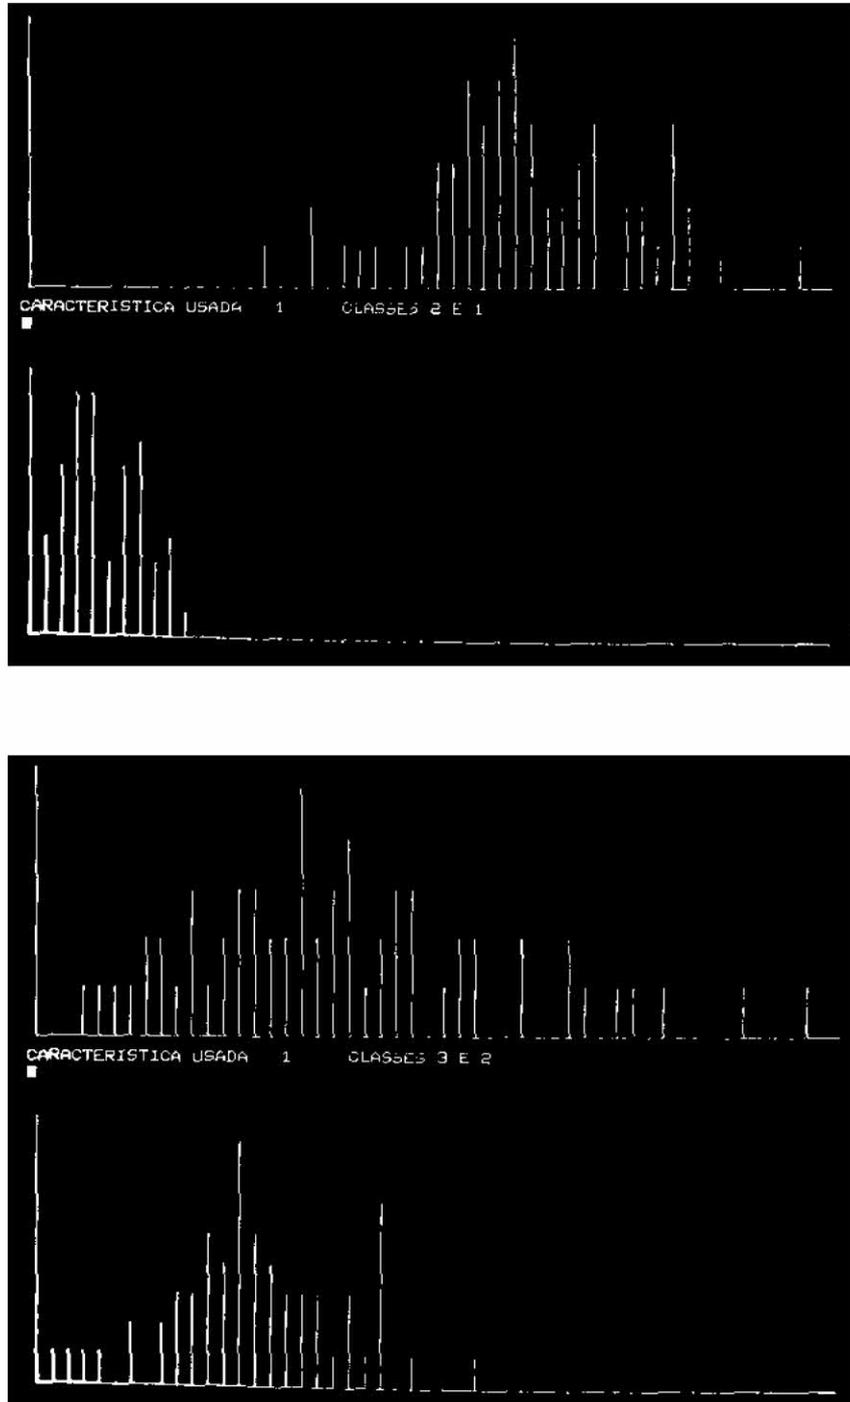


Fig. IV.2 - Características: ASM-M

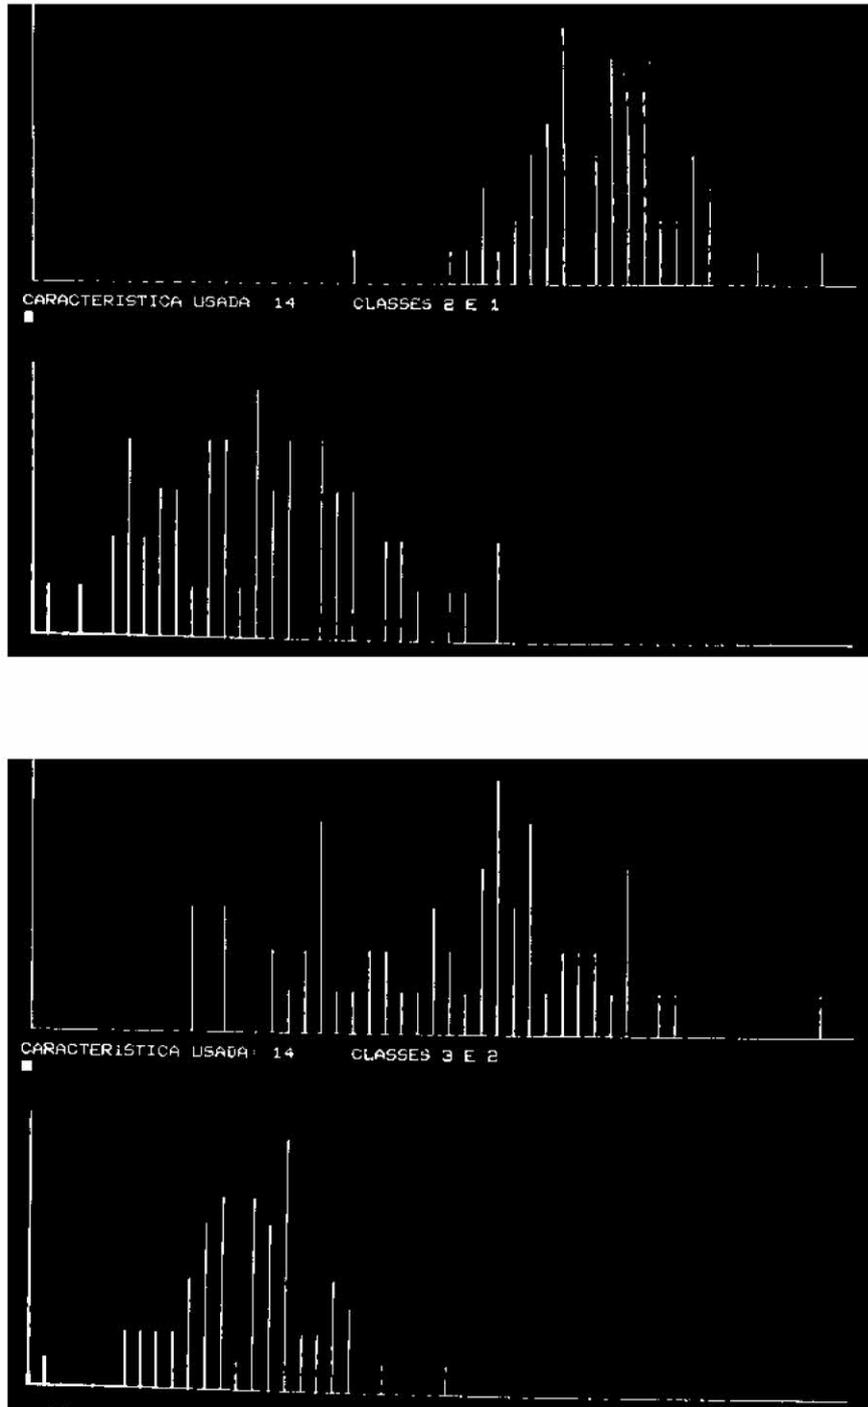


Fig. IV.3 - Característica: XIDM-D

Cada janela foi equalizada em 32 níveis e colocada no canal 5 do sistema I-100, de onde eram extraídas as respectivas matrizes. Como foi visto no Capítulo III, cada tipo de textura fornece um conjunto de 3 características, que são a média, o desvio padrão e a faixa de variação dos valores dessa medida, para as quatro matrizes de coocorrência. Tem-se, então, um total de 36 medidas de textura, as quais serão denominadas pelo tipo de medida seguido da letra M, D ou F, caso se trate, respectivamente, da média, do desvio padrão ou da faixa de variação.

Além dessas 36 medidas de textura, foram, também, computadas 8 medidas espectrais: média e variância dos níveis de cinza dos pontos da janela, para cada um dos 4 canais, perfazendo um total de 44 características para cada janela. O tempo total de processamento, de cada janela, foi por volta de 40 segundos.

Na fase de classificação, o conjunto das 182 janelas foi dividido em duas partes iguais: uma para treinamento do classificador e outra para teste. Portanto, o número máximo de acertos nas Tabelas, que serão mostradas mais adiante é 91.

4.3 - RESULTADOS

Inicialmente foram realizadas classificações, utilizando cada uma das 44 características individualmente. A Tabela IV.1 mostra os resultados obtidos, com o uso do Mín-máx e do vizinho mais próximo (VMP). Nesta Tabela, as características espectrais são designadas pelo número da banda correspondente (4-7), junto com a letra M, no caso de ser média, ou V, se for variância.

É difícil fazer uma análise baseada apenas nos resultados de classificações, usando características individuais. É, porém, impraticável se fazer todas as combinações possíveis de características, para analisar, em bases sólidas, a importância de cada uma delas. Num processo natural e empírico de escolha, pode-se selecionar aquelas que deram melhores resultados individualmente, desprezando-se as demais. Ou então, procura-se uma segunda característica que, junto com a melhor delas, indivi

dualmente dá o melhor resultado e, em seguida, uma terceira, que junto com aquele par, dá o melhor resultado e assim por diante.

No caso deste trabalho não se trata do problema da procura de um conjunto ótimo de características, mas de uma análise da importância das características de textura em geral. Portanto, para uma classificação com pares de características, foram escolhidas as médias de todos os tipos de medidas de textura (12 no total), além da faixa de variação e do desvio padrão do XIDM, que foram exatamente as características de textura de melhor desempenho individual. Das características espectrais, foram desprezadas as duas que deram piores resultados, ou seja 4-V e 5-V.

Fica-se, então, com um total de 20 características para serem utilizadas em classificações, através de pares de características. Os resultados obtidos, quando o classificador usado é o M_{in}-M_{ax}, encontram-se na Tabela IV.2.

O melhor resultado, encontrado com a utilização de pares de características de textura, foi de 85 acertos em 91 possíveis, ou seja, uma percentagem de classificação correta de 93,4%. Isto foi obtido com o uso das características XIDM-D e CORME-M.

Já o melhor resultado, com características espectrais, foi de 87 acertos (95,6%), obtido com o uso das características 7-M e 7-V.

O melhor resultado geral foi 90 acertos, correspondendo a 98,9% de classificação correta, e obtido com um par misto de características, ou seja, uma textural (SUMENT-M) e outra espectral (7-M).

De forma global, os melhores resultados foram os obtidos com pares mistos de características. Isto pode ser melhor compreendido com a ajuda das Figuras IV.2 - IV.6, onde estão colocados alguns histogramas obtidos, usando-se o conjunto inteiro das 182 janelas. Nestas Figuras, as classes 1, 2 e 3 são usadas para designar, respectivamente, os tipos de terreno A, B e C.

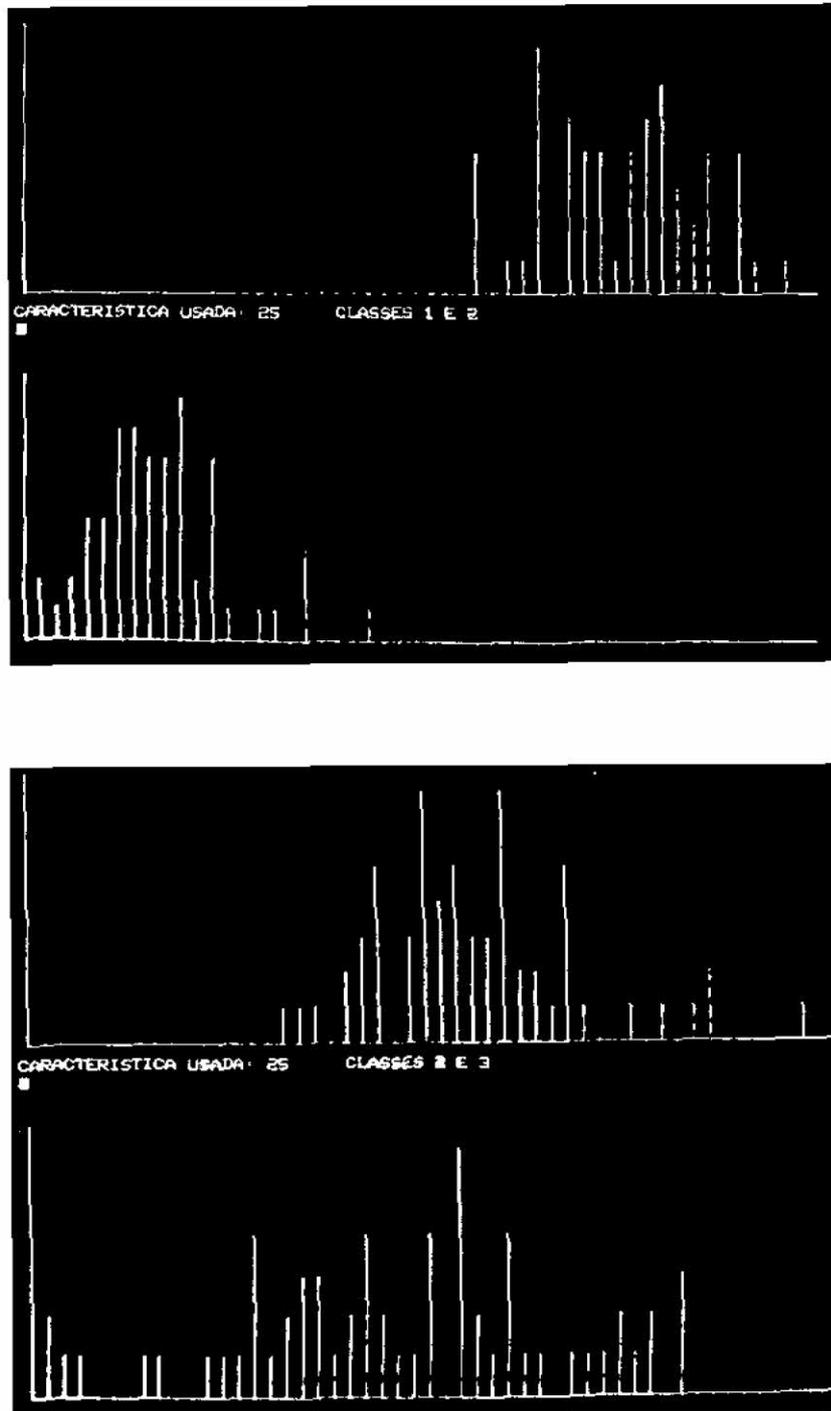


Fig. IV.4 - Característica: ENT-M

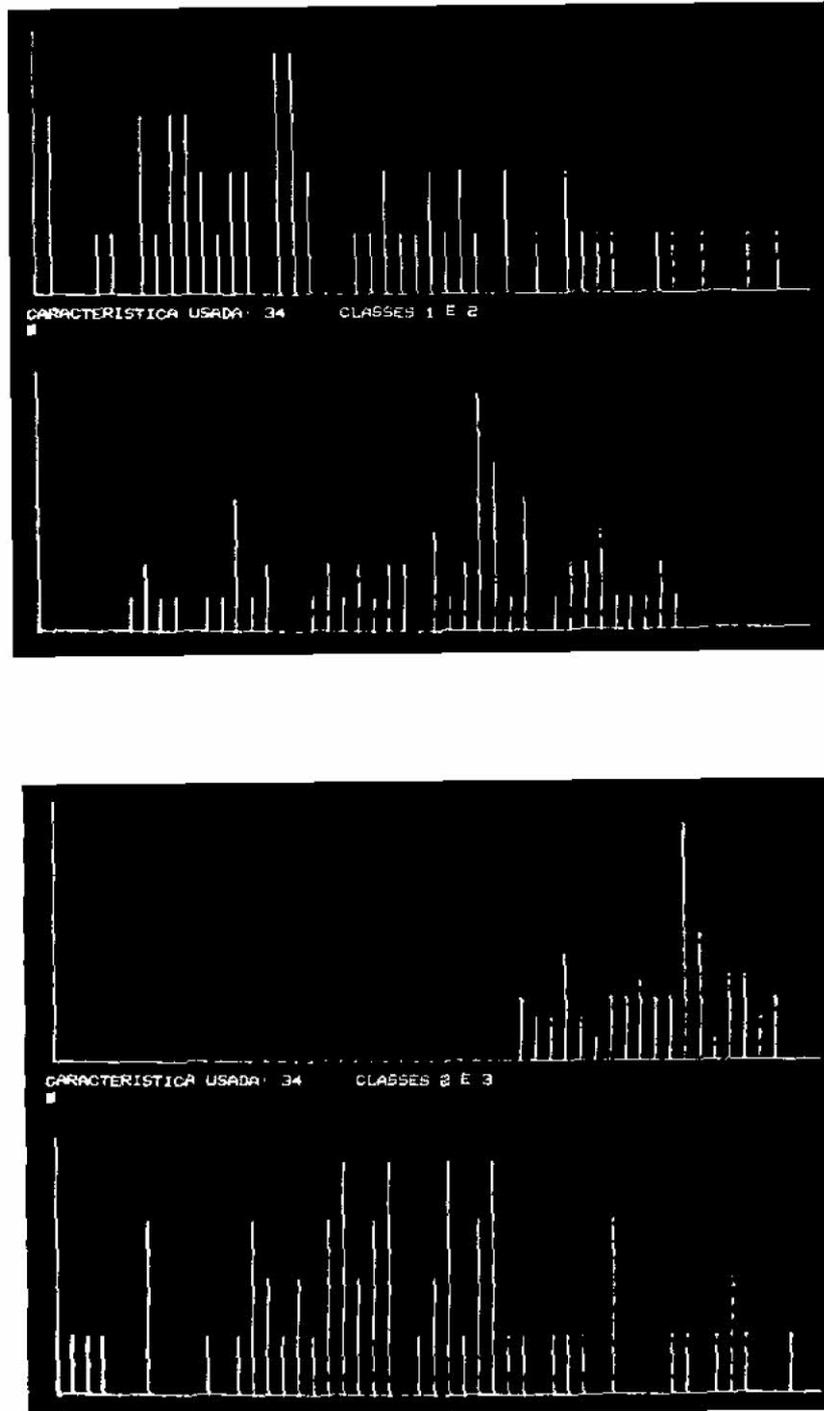


Fig. IV.5 - Característica: CORME-M

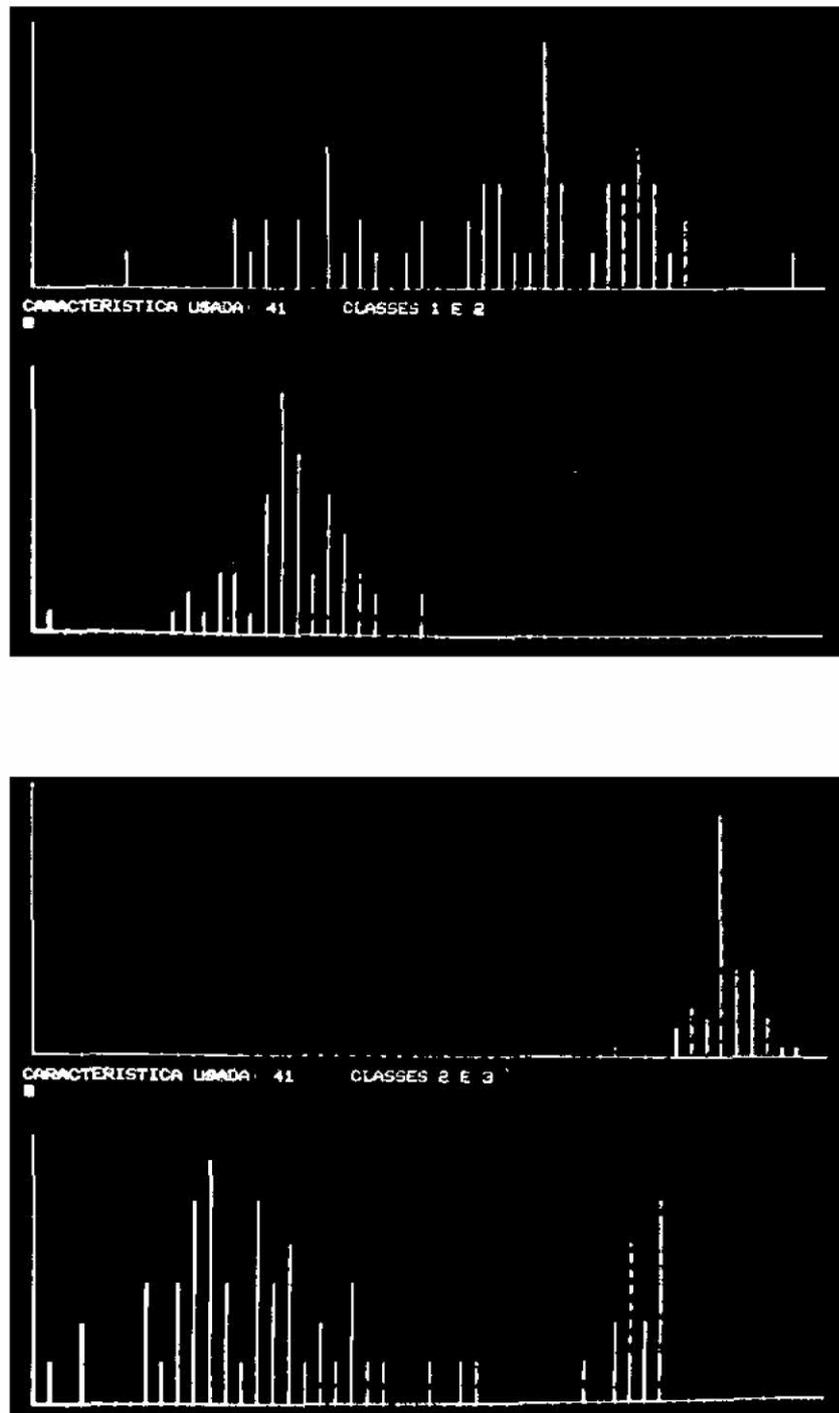


Fig. IV.6 - Característica: 7-M

A Figura IV.2 mostra os histogramas para o ASM-M. Pode-se ver que existe boa separação entre as classes 1 e 2, e deduzir-se que a separação é melhor ainda para as classes 1 e 3. Como o terreno do tipo 2 é mais homogêneo que o do tipo 1, era esperado que os valores assumidos pelo ASM fossem maiores para o tipo 2, o que de fato aconteceu.

A Figura IV.3 mostra os histogramas para o XIDM-D, onde se pode ver que, embora haja certa interseção entre as classes 2 e 1, e 2 e 3, para as classes 1 e 3 ela já é menor. Na realidade, a existência de interseção não implica na inutilidade da característica, pois o simples fato das médias dos valores desta característica serem diferentes, para classes diferentes, já mostra que ela é informativa.

Da mesma forma, podem ser interpretadas as Figuras IV.4 para o ENT-M, e IV.5 para o CORME-M.

A Figura IV.6 mostra as distribuições das classes, quando a característica usada é a média espectral da janela na banda 7 (7-M), que foi utilizada para extração de informação sobre a textura. Pode-se ver que a classe 3 é bem separada da classe 2, e deduzir que a separação é um pouco menor com relação à classe 1. Isto é devido ao fato de que a maior parte do terreno tipo C é bem escura, diferenciando-se dos demais tipos, o que pode ser visualizado na Figura IV.1.

Desta forma, já eram esperados os resultados obtidos, uma vez que em geral as características de textura, usadas individualmente, separam bem as classes 1-2 e 1-3, enquanto que as espectrais (em especial 7-M) separaram bem as classes 2-3.

As medidas espectrais do tipo variância, via de regra, tiveram desempenho mais fraco que as do tipo média, quando usadas em pares mistos de características. Porém, notou-se que os pares de características espectrais, com melhores resultados, foram aqueles que usaram uma do tipo média e a outra do tipo variância.

Em seguida, foi realizado um estudo de classificação, utilizando-se a dimensão do espaço de características igual a 3. Utilizando-se as 20 características anteriores, podiam ser feitas 1140 combinações diferentes para classificação. No entanto, foram consideradas apenas 12 características, sendo 9 texturais e 3 espectrais. As espectrais foram 7-M, 7-V e 6-M. O critério usado para seleção das 9 características de textura foi a soma total de acertos dos pares de características, dos quais cada uma dessas 9 características fez parte, o que pode ser obtido da Tabela IV.2. Foram, então, escolhidas as características ASM-M, VAR-M, XIDM-M, XIDM-D, XIDM-F, SUMVAR-M, SUMENT-M, ENT-M e CORME-M. As tabelas IV.3 - IV.11 mostram os resultados obtidos. A característica chave, indicada, é aquela que sempre foi utilizada para, em conjunto com duas outras constantes da Tabela, fornecer o resultado assinalado.

Várias combinações de características de textura forneceram um resultado de 87 acertos, em 91 possíveis, dando uma percentagem de classificação correta de 95,6%, que foi o máximo obtido com características deste tipo. O melhor resultado obtido foi de 90 acertos (98,9%), com o conjunto formado pelas características XIDM-M, SUMENT-M e 7-M. Apresentam-se, a seguir, as Tabelas de IV.1 a IV.11, mencionadas anteriormente.

TABELA IV.1

NÚMERO DE JANELAS CLASSIFICADAS CORRETAMENTE
UTILIZANDO-SE CARACTERÍSTICAS INDIVIDUAIS

CARACTERÍSTICA	MIN-MAX	VMP	CARACTERÍSTICA	MIN-MAX	VMP
ASM-M	62	66	SUMENT-D	48	41
ASM-D	69	72	SUMENT-F	49	44
ASM-F	68	65	ENT-M	63	66
CONT-M	48	52	ENT-D	41	38
CONT-D	52	57	ENT-F	44	49
CONT-F	48	54	DIFVAR-M	33	45
COR-M	61	54	DIFVAR-D	39	40
COR-D	46	54	DIFVAR-F	41	46
COR-F	42	47	DIFENT-M	59	64
VAR-M	51	42	DIFENT-D	53	49
VAR-D	31	34	DIFENT-F	54	55
VAR-F	32	39	CORME-M	53	51
XIDM-M	64	63	CORME-D	56	53
XIDM-D	77	76	CORME-F	58	48
XIDM-F	77	74	4-M	51	67
SUMAVE-M	55	50	4-V	38	52
SUMAVE-D	42	42	5-M	65	61
SUMAVE-F	35	44	5-V	39	64
SUMVAR-M	61	48	7-M	79	77
SUMVAR-D	50	53	7-V	60	62
SUMVAR-F	44	46	6-M	81	71
SUMENT-M	61	65	6-V	54	59

TABELA IV.6

CARACTERÍSTICA CHAVE: XIDM-D

	SUMVAR-M	SUMENT-M	ENT-M	CORME-M	7-M	7-V	6-M
XIDM-F	81	78	79	85	86	82	86
SUMVAR-M		82	83	85	87	83	86
SUMENT-M			80	87	87	83	87
ENT-M				87	87	83	87
CORME-M					86	84	86
7-M						85	86
7-V							85

TABELA IV.7

CARACTERÍSTICA CHAVE: XIDM-F

	SUMENT-M	ENT-M	CORME-M	7-M	7-V	6-M
SUMVAR-M	81	82	85	86	81	85
SUMENT-M		79	86	86	82	86
ENT-M			86	86	82	86
CORME-M				85	83	85
7-M					84	85
7-V						84

TABELA IV.8

CARACTERÍSTICA CHAVE: SUMVAR-M

	ENT-M	CORME-M	7-M	7-V	6-M
SUMENT-M	76	82	89	76	86
ENT-M		82	89	77	86
CORME-M			85	77	84
7-M				87	86
7-V					86

TABELA IV.9

CARACTERÍSTICA CHAVE: SUMENT-M

	CORME-M	7-M	7-V	6-M
ENT-M	82	89	71	87
CORME-M		89	79	88
7-M			87	89
7-V				85

TABELA IV.10

CARACTERÍSTICA CHAVE: ENT-M

	7-M	7-V	6-M
CORME-M	88	79	87
7-M		87	88
7-V			85

TABELA IV.11

CARACTERÍSTICA CHAVE: CORME-M

CONJUNTO USADO	Nº DE ACERTOS
CORME-M, 7-M, 7-V	86
CORME-M, 7-M, 6-M	82
CORME-M, 7-V, 6-M	85
7-M, 7-V, 6-M	87

De uma maneira geral houve um melhor desempenho com a introdução de uma terceira característica, o que pode ser visto confrontando-se a Tabela IV.2 com as seguintes. Por exemplo, o par ASM-M e VAR-M acertou 75 vezes e, com a introdução de mais uma característica, obtiveram-se resultados maiores ou iguais a 75, o que pode ser visto na 1a. linha da Tabela IV.3. Isto acontece praticamente com todos os pares de características de textura, onde a nova característica introduzida traz bastante informação sobre a separação das classes 2 e 3. Nos pares mistos de características isto, entretanto, não é verdade: por exemplo: o par ASM-M e 7-M que apresentou 88 acertos, com a introdução de mais uma característica, diminuiu ou manteve este desempenho (Tabela IV.3, 3a. coluna da direita para a esquerda). Isto se deve a dois efeitos antagônicos envolvidos: um, que é a informação adicional contida na característica, e outro, que é a sensibilidade demonstrada pelo M̄n-M̄x, a um aumento de dimensionalidade. No Apêndice A.1.1 será comentado este segundo efeito.

De uma maneira geral, pode-se considerar, pelo menos, razoáveis os resultados obtidos com trincas dessas características de textura. O m̄nimo de acertos foi 62 (68%), o m̄ximo foi 87 (95,6%), e a mēdia foi em torno de 81 acertos (89%).

Embora aumentando o tempo consumido, o aumento de dimensionalidade do espaço de características não afeta o desempenho do classificador, baseado na regra de decisão do vizinho mais próximo (VMP). Na Tabela IV.12 estão alguns resultados obtidos, quando se utilizou a dimensão do espaço igual a 4. Neste caso, fez-se uso de características que deram os melhores resultados, quando usadas em trincas.

Como se pode observar na Tabela IV.12, o conjunto de características de textura ASM-M, VAR-M, XIDM-F e CORME-M obteve 100% de classificação correta, quando o VMP foi usado. Na verdade, este resultado não se torna muito raro, quando são utilizadas dimensões maiores que 6.

A esta altura, talvez seja interessante comparar alguns resultados encontrados, com outros existentes. Weszka et al (1976) fazem uma análise comparativa de medidas de textura, com fins de classificação de terrenos. Embora as medidas realizadas sobre as matrizes de coocorrência sejam utilizadas, diretamente, como características de textura (havendo, portanto, sensibilidade à orientação), pode-se notar dois fatos:

- 1) A entropia (ENT) deu resultados similares aos obtidos com o momento angular de 2a. ordem (ASM), quando utilizados individualmente. No caso deste trabalho, isto também ocorreu com relação às médias destes tipos de medidas (Tabela IV.1).
- 2) O XIDM deu resultados piores que o ASM e o ENT, quando usados individualmente, ou em conjunto formados por um mesmo tipo de medida, computada para várias distâncias e direções. Como se usou distância unitária, não se pode confirmar a segunda parte deste resultado. Quanto à primeira parte, pode-se ver, pelos resultados apresentados em Weszka et al (1976), que o desempenho do XDM diminui nitidamente com a distância utilizada, embora, mesmo com distância unitária, ele já seja inferior aos desempenhos do ASM e do ENT. No presente trabalho, se se considerar o XIDM-M como sendo a característica mais próxima das medidas diretas sobre as matrizes, pode-se ver que os resultados não diferem muito (os de

sempenhos do XIDM-M, ASM-M e ENT-M foram 64, 62 e 63, respectivamente), embora o XIDM-M tenha sido um pouco melhor. Entretanto, o XIDM-D e o XIDM-F, individualmente, apresentaram os melhores desempenhos de todas as características de textura implementadas. Essa diferença talvez seja devido ao fato de que uma característica de textura, do tipo desvio padrão ou faixa de variação, está muito mais relacionada à direcionalidade, do que, propriamente, à rugosidade da textura, que é o que está, basicamente, sendo medido através das características usadas em Wieszka, 1976. Ou seja, pelo fato do XIDM-M ter tido um desempenho fraco, não necessariamente o XIDM-D ou XIDM-F devem fornecer maus resultados.

TABELA IV.12

CONJUNTO DE CARACTERÍSTICAS

CONJUNTO DE CARACTERÍSTICAS	MIN-MAX	VMP
ASM-M, VAR-M, XIDM-D, CORME-M	86	90
ASM-M, VAR-M, XIDM-F, CORME-M	83	91
ASM-M, VAR-M, CORME-M, 7-M	86	89
ASM-M, XIDM-M, XIDM-D, SUMVAR-M	83	87
VAR-M, XIDM-M, XIDM-D, SUMVAR-M	84	85
VAR-M, ENT-M, CORME-M, 7-M	87	89
XIDM-M, XIDM-D, SUMVAR-M, SUMENT-M	85	87
XIDM-M, SUMENT-M, CORME-M, 7-M	89	88
XIDM-D, SUMENT-M, ENT-M, CORME-M	87	86
XIDM-D, ENT-M, CORME-M, 7-M	86	90
SUMENT-M, CORME-M, 7-M, 6-M	88	85
SUMENT-M, 7-M, 7-V, 6-M	87	87

4.4 - CONCLUSÕES

De maneira geral podem ser considerados bons os resultados obtidos, utilizando-se apenas características de textura na discriminação de tipos diferentes de terreno. Mesmo tendo sido utilizada uma imagem em que não era tão óbvia a separação visual, através de textura, de uma das classes (tipo C), os índices de classificação correta chegaram a atingir várias vezes 95,6%, quando o MIn-Máx foi utilizado, e outras vezes chegaram a 100% com o uso do VMP. Os tipos de medidas de textura ASM, XIDM, SUMENT, ENT e CORME foram os que, em geral, forneceram os melhores resultados. O CORME, que ainda não havia sido testado nos trabalhos anteriores, forneceu uma boa opção para distinção entre as classes B e C, as quais, em geral, não foram bem separadas com características de textura individuais (Figuras IV.2 - IV.6)

Globalmente, os melhores resultados ficaram por conta dos conjuntos mistos de características, ou seja, os que utilizavam tanto características espectrais como de textura. Esta conclusão está de pleno acordo com o que foi obtido em Haralick e Bosley (1973a). Entretanto, seria bom frisar que o uso de conjuntos mistos de características está restrito à discriminação entre categorias dentro de uma mesma imagem, uma vez que as características espectrais de uma mesma classe podem variar sensivelmente, de acordo com as condições sob as quais a imagem foi obtida. Desse fato é que decorre a grande vantagem das características texturais sobre as espectrais, uma vez que antes do processamento é realizada a equalização do histograma, que as torna invariantes a condições diferentes, que porventura existam em imagens distintas.

AGRADECIMENTOS

Ao pessoal do IMAGE-100, que em muito contribuiu para a execução do presente trabalho.

À Aparecida Alves Cardoso pela datilografia do relatório final.

A todos que de alguma forma colaboraram para a realização deste trabalho.

BIBLIOGRAFIA

- DYER, C.R.; WESZKA, J.S.; ROSENFELD, A. *Experiments in terrain classification on LANDSAT imagery by texture analysis*. College Park, MD., University of Maryland. Computer Science Center, 1975. (Technical Report, 383).
- FUKUNAGA, K. *Introduction to statistical pattern recognition*. New York, Academic, 1972.
- GENERAL ELECTRIC COMPANY. *IMAGE-100 - System software description*. Daytona Beach, 1974a.
- . *IMAGE-100: user manual*. Daytona Beach, 1974b.
- HALL, E.E., HALL, E.L.; KRUGER, R.P.; DWYER, S.J.III; HALL, D.L.; McLAREN, R.W.; LODWICK, G.S. A Survey of Preprocessing and Feature Extraction Techniques for Radiographic Images. *IEEE Transactions Computers*, C-20(9): 1032-1044, Sep., 1971.
- HARALICK, R.M.; BOSLEY, R. Spectral and Textural Processing of ERTS Imagery. In: *EARTH Resources Technology Satellite-1 Symposium*, 3., Washington, DC., 1973. Proceedings. V.1, p.1929-1969.
- ,; SHANMUGAN, K. Computer Classification of Reservoir Sandstones. *IEEE Transactions Geoscience Electronics*, GE-11 (4): 171-177, Oct., 1973b.
- ,; DINSTEN, I. Textural Features for Image Classification. *IEEE Transactions on Systems, man, and cybernetics*, SMC-3 (6): 610-621, Nov., 1973c.
- HAWKINS, J.K. Textural Properties for Pattern Recognition. In: LIPKIN, B.S.; ROSENFELD, A., ed. *Picture processing and psychopictorics*. New York, Academic, 1970.

- JULESZ, B. Texture and Visual Perception. *Scientific American*, 212 (2): 38-55, Feb., 1965.
- . , Experiments in the Visual Perception of Texture. *Scientific American*, 234 (4): 34-44, Apr., 1975.
- MEISEL, W. *Computer Oriented Approaches to Pattern Recognition*. New York, Academic, 1972.
- PICKETT, R.M. Visual Analysis of Texture in the Detection and Recognition of Object. In: LIPKIN, B.S.; ROSENFELD, A., ed. *Picture processing and psychopictorics*. New York, Academic, 1970.
- ROSENFELD, A. *Picture Processing by Computer*. New York, Academic, 1969.
- TEKTRONIX *Plot-10 terminal control system: user manual*. Beaverton, DR., Tektronix, 1974.
- TOU, J.T. and GONZALES, R.C. *Pattern Recognition Principles*. Reading MA., Addison-Wesley, 1974.
- WESZKA, J.S.; DYER, C.R.; ROSENFELD, A. A Comparative Study of Texture Measures for Terrain Classifications. *Transactions on Systems, Man, and Cybernetics*, SMC-6 (4): 269-285, Apr., 1976.

APÊNDICE A

PROCEDIMENTOS DE CLASSIFICAÇÃO

No programa CATEG, desenvolvido para realizar a etapa de classificação propriamente dita, podem ser utilizados dois classificadores: o MÍN-MÁX e o do vizinho mais próximo.

A.1 - O CLASSIFICADOR MÍN-MÁX

Seja uma amostra designada por um vetor de N características $X = (x_1, x_2, \dots, x_N)$. Este classificador utiliza uma regra de decisão que é de máxima verossimilhança sob a hipótese de que as características são independentes e possuem distribuição uniforme. Se isto for admitido, tem-se que a função densidade de probabilidade para a categoria k é:

$$f(X|k) = \frac{1}{(a_{nk} - b_{nk})}, \text{ para todo } X \text{ tal que}$$

$$b_{nk} \leq x_n \leq a_{nk}, \quad n=1, \dots, N$$

onde, nesta expressão, a_{nk} e b_{nk} definem os valores máximo e mínimo da distribuição uniforme da categoria k , para a componente n .

Assim, uma amostra (x_1, x_2, \dots, x_N) é atribuída a categoria k , se e só se:

$$1) \quad b_{nk} \leq x_n \leq a_{nk}, \quad n=1, 2, \dots, N$$

$$2) \quad \frac{1}{(a_{nk} - b_{nk})} \geq \frac{1}{(a_{nj} - b_{nj})}, \text{ para todo } j, \text{ tal que}$$

$$b_{nj} \leq x_n \leq a_{nj}, \quad n=1, 2, \dots, N$$

Se não existir k , tal que $b_{nk} \leq x_n \leq a_{nk}$, $n=1,2,\dots,N$, então, X é atribuído à categoria k , se esta for a categoria que minimize o termo

$$\sum_{n=1}^N (*) (\min\{|x_n - a_{nj}|, |x_n - b_{nj}|\})^2, j=1,2,\dots,K$$

onde K é o número de categorias e o (*) foi colocado para indicar que não se incluem no somatório, os termos cujos n 's são tais que $b_{nj} \leq x_n \leq a_{nj}$.

A estimativa do intervalo $b_{nk} - a_{nk}$ da distribuição uniforme da categoria k , para a componente n , é feita da seguinte forma: Sejam A_{nk} e B_{nk} os valores máximo e mínimo da componente n , para todas as amostras designadas na categoria k , e M_k , o número dessas amostras. Então:

$$b_{nk} = B_{nk} - \frac{A_{nk} - B_{nk}}{M_k - 1}$$

$$a_{nk} = A_{nk} + \frac{A_{nk} - B_{nk}}{M_k - 1}$$

Vê-se que o intervalo da distribuição uniforme é um pouco maior que o encontrado na fase de treinamento, isto é:

$$a_{nk} - b_{nk} = (A_{nk} - B_{nk}) \cdot \frac{M_k - 1}{M_k - 1}$$

Nota-se que é bastante simples o funcionamento do Mín-Máx. Na fase de treinamento, é determinado o N-paralelepípedo correspondente a cada uma das categorias existentes. Quando, na fase de classificação, uma amostra é apresentada ao classificador, este verifica em qual paralelepípedo ela está contida. Podem então ocorrer 3 casos:

- 1) O paralelepípedo é único: então a amostra é classificada como sendo da categoria correspondente.
- 2) O paralelepípedo não é único: então a classe correspondente ao menor deles é atribuída, pois, de acordo com a hipótese feita, ela é a mais provável.
- 3) A amostra não pertence a nenhum paralelepípedo. Neste caso, procura-se aquele paralelepípedo que está mais perto da amostra, e a classe desse é atribuída à amostra.

O terceiro caso envolve cálculo de distâncias euclidianas, no espaço de características. Como, certamente, as características não têm a mesma ordem de grandeza, é necessária uma normalização, de modo a se atribuir pesos iguais para todas elas. Foi feito um mapeamento linear em cada dimensão do espaço de características, independentemente da classe das amostras, de modo que os valores assumidos variassem entre 0 e 1.

Quando da utilização do M_{in}-M_{ax}, o conjunto total de amostras foi dividido em duas partes iguais: 91 amostras para treinamento, ou determinação dos parâmetros das distribuições pelo classificador, e 91 amostras para teste. Foi verificado que, quando era aumentada a dimensão do espaço de características, crescia o número de ocorrências de classificações, pelo terceiro critério citado, ou seja, mais amostras não pertenciam a nenhum dos paralelepípedos existentes. Isto talvez seja consequência de uma estimativa do intervalo da distribuição uniforme de cada classe, para cada característica, baseada em um número insuficiente de amostras. Como no caso deste trabalho as classes não eram separadas, o uso daquele critério era o que mais resultava em erros de classificação.

Para simplificar uma análise, considerar-se-á o caso em que o intervalo da distribuição, uniforme em cada componente, é estimado como sendo a diferença entre os valores máximo e mínimo das amostras para esta componente. Supondo-se que se faça tal estimativa, baseados em duas amostras apenas, X_1 e X_2 , e que as características sejam realmente independentes e uniformemente distribuídas entre 0 e 1, pode-se, então, calcu

lar a probabilidade de que, pelo menos, uma fração w das amostras venha cair fora do intervalo estimado, no caso de dimensão igual a 1 (Figura A.1).

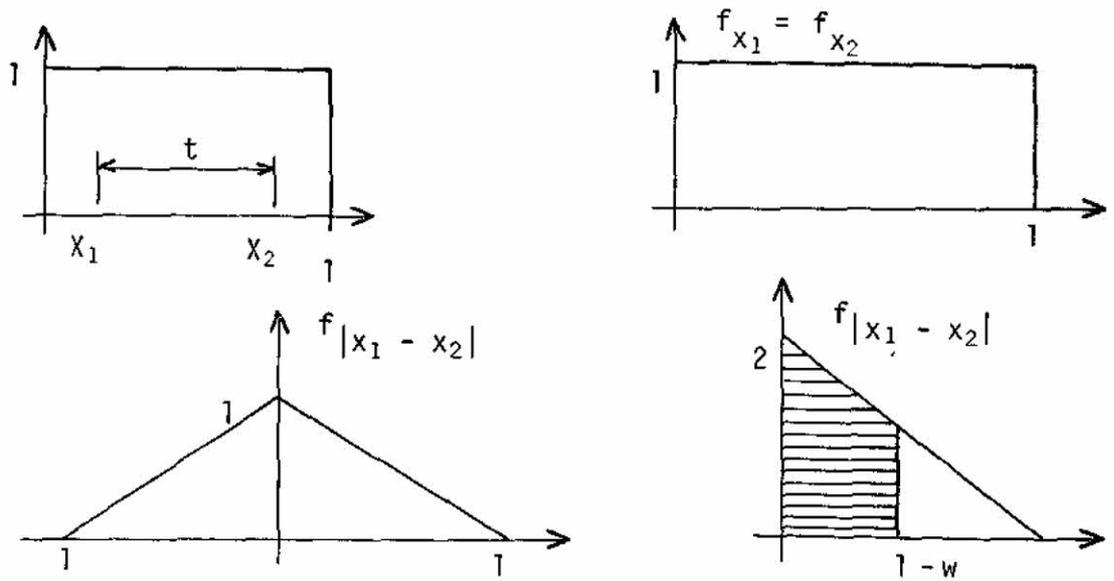


Fig. A.1 - Funções densidade de probabilidade.

A largura do intervalo estimado $\tilde{t} = |x_1 - x_2|$, e a probabilidade que se procura \tilde{e} (Figura A.1).

$$P [1 - |X_1 - X_2| \geq w] = P [|X_1 - X_2| \leq 1 - w]$$

Calculando-se este valor, através da função densidade de probabilidade de variável aleatória $|X_1 - X_2|$, apresentada na Figura A.1, tem-se:

$$P [|X_1 - X_2| \leq 1 - w] = \int_0^{1-w} (2-2y) dy = 1 - w^2$$

Calcule-se agora a probabilidade de que, pelo menos, uma fração y das amostras caiam fora do intervalo estimado, no caso de dimensão igual a 2 (Figura A.2).

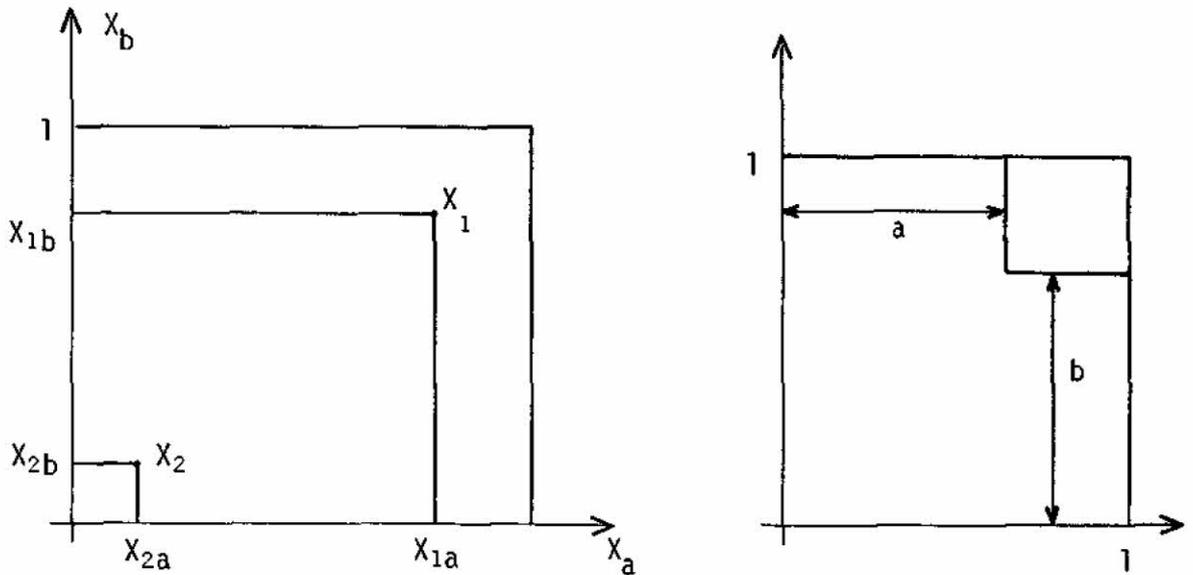


Fig. A.2 - Intervalos bidimensionais.

A partir da Figura A.2, e levando-se em conta o resultado do anterior, tem-se que:

$$P [1 - |X_{1a} - X_{2b}| \geq a, 1 - |X_{1b} - X_{2b}| \geq b] = (1 - a^2) (1 - b^2)$$

\bar{e} a probabilidade de que, pelo menos, uma fração $1 - (1-a) (1-b)$ das amostras caiam fora da região estimada.

Fixando-se uma certa probabilidade, e comparando-se as frações m nimas esperadas de amostras, caindo fora do intervalo estimado para os casos de dimens o 1 e 2, pode-se ver que \bar{e} realmente esperado um n mero maior de amostras fora da regi o estimada, para o caso de dimens o

2. Por exemplo, com uma probabilidade 90%, espera-se que, pelo menos, 31,6% das amostras caiam fora para o caso de dimensão 1, ao passo que, com di mensão 2, esta percentagem mínima se eleva a 40,2%.

Para uma estimativa baseada em um número muito grande de amostras, a situação não é tão simples assim. Porém, é razoável que ainda neste caso, aumente o número de amostras caindo fora do intervalo, para um aumento de dimensionalidade, uma vez que, para uma amostra cair dentro de uma região a N dimensões, ela precisa estar dentro de cada um dos N in tervalos correspondentes.

Como se pode verificar na descrição do M̄n-M̄x, a largura do intervalo estimado da distribuição uniforme, para cada componente, não é exatamente a encontrada através das amostras de treino, pois existe um fator multiplicativo maior que a unidade, e que é função do número dessas amostras. Entretanto, ainda assim foi verificado um crescimento do número de amostras em teste caindo fora do paralelepípedo estimado, com o aumen to de dimensionalidade.

A.2 - REGRA DE DECISÃO DO VIZINHO MAIS PRÓXIMO

Seja um conjunto de amostras, com classificação conhecida, $\{s_1, s_2, \dots, s_N\}$, e X a amostra sendo classificada. A regra de classifica ção do vizinho mais próximo consiste em atribuir a X a classe do seu vi zinho mais próximo, s^* , onde s^* é tal que:

$$D(s^*, X) = \min \{D(s_\ell, X), \ell = 1, 2, \dots, N\}$$

Nesta expressão, D pode ser qualquer medida de distância. No caso deste trabalho, a distância utilizada foi a própria euclídeana.

De modo a se atribuir a mesma importância a todas as características, deve-se realizar uma normalização, de maneira que todas assumam valores dentro de um mesmo intervalo.

Este classificador, embora mais elementar que o Mfn-Máx, apresenta a desvantagem de ter uma velocidade de classificação menor e mais dependente da dimensão do espaço de características.

APÊNDICE B

LISTAGENS DOS PROGRAMAS

FDRTRAN IV V01B-02 FRI 26-NOV-76 20:19:53 PAGE 002
CURE=08K, UIC=[200,200]. COLETA,LP:/LI:1=D11:COLETA.

```
0055            READ(6,20)W
0056            CALL FRONT(W,74)
0057            IF(W(1).EQ."130)GO TO 2000
0059            L=0
0060            DO 50 K=1,2
0061        50        CALL INTFF(L,W,74,EC(K,J))
0062            IF(EC(1,2).LE.EC(1,1).OR.EC(2,2).LE.EC(2,1))GO TO 30
0064        60        DO 80 J=1,2
0065            WRITE(6,70)J,J
0066        70        FORMAT('SBATA IX',11,',',IY',I1,':',2X)
0067            CALL OUTPUT(7)
0068            READ(6,20)W
0069            CALL FRONT(W,74)
0070            IF(W(1).EQ."130)GO TO 2000
0072            L=0
0073            DO 80 K=1,2
0074        80        CALL INTFF(L,W,74,IC(K,J))
0075            IF(IC(1,2).LE.IC(1,1).OR.IC(2,2).LE.IC(2,1))GO TO 60
C ESCOLHA E DETERMINACAO DOS PARAMETROS DA JANELA
0077        89        CALL JANELA(EC,IC,CC,SC,JOB,IDX,IDY)
0078            IF(JOB.EQ.0)GO TO 2000
0080        27        WRITE(6,90)
0081        90        FORMAT('SQUAL A CATEGORIA DA JANELA ESCOLHIDA?>')
0082            CALL OUTPUT(7)
0083            READ(6,20)W
0084            CALL FRONT(W,74)
0085            L=0
0086            CALL INTFF(L,W,74,ICLASS)
0087            IF(ICLASS.GT.1)GO TO 27
0089            CALL ASSIGN(5,'LP:')
C OBTENCAO DO HISTOGRAMA E CAPACTERISTICAS ESPECTRAIS
0090            DO 120 J=1,4
0091            LX(1,J)=0
0092            LX(2,J)=0
0093        120        LX(3;J)=1
0094            LX(1,5)=-1
0095            CALL IWHL(LX)
0096            DO 150 J=1,255,2
0097            DO 140 I=1,4
0098            DO 140 K=1,3
0099        140        LX(K,1)=LX(K,I)+2
0100            CALL IRHC(CX)
0101            CALL IWHL(LX)
0102            DO 145 M=1,4
0103            DO 145 K=0,1
0104        145        AR(J+K,M)=CX(K+1,M)
0105        150        CONTINUE
0106            CALL IRTOT(LENA)
0107            CALL IRTOT(LENA)
0108            XAREA=RTOT(LENA,2)
0109            DO 170 M=1,4
0110            XMEDIA(M)=0.0
0111            XVAR(M)=0.0
0112            DO 160 J=2,256
0113            ACUM=RUS(AR(J,M))
0114            XMEDIA(W)=XMEDIA(M)+(J-1)*ACUM
```

```
FORTRAN IV          VO18-02          FRI 26-NOV-76 20:19:53          PAGE 003
CORE=08K, UIC=[200,200]          COLETA,LP:/LI:1=DT1;COLETA.

0115 160  XVAR(N)=XVAR(M)+(J-1)*ACUM*(J-1)
0116      XMEDIA(M)=XMEDIA(M)/XAREA
0117      XVAR(M)=XVAR(M)/XAREA-XMEDIA(M)*XMEDIA(M)
0118 170  CONTINUE
      C EQUALIZACAO DO CANAL ESCOLHIDO EM 32 NIVEIS PARA O CANAL 5
0119      AREA=0.0
0120      DO 173 J=1,256
0121 173  AREA=AREA+RUS(AR(J,CHN))
0122      WRITE(6,175)CHN
0123 175  FORMAT(10X,'INICIO DA EQUALIZACAO DO CANAL',I2)
0124      ACUM=RUS(AR(1,CHN))
0125      NI=ACUM*32/AREA
0126      IF(NI.EQ.0)GO TO 176
0128      TOTA=AREA*NI/32
0129      IF(ACUM.GT.TOTA+AREA/64)GO TO 176
0131      NI=NI-1
0132 176  K=NI
0133      NI=NI+1
0134      TABLE(1)=IZ
0135      DO 190 J=2,256
0136      SADI=RUS(AR(J,CHN))
0137      ACUM=ACUM+SADI
0138      NI=ACUM*32/AREA
0139      IF(NI.EQ.K)GO TO 180
0141      TOTA=AREA*NI/32
0142      TOTA=ACUM-SADI
0143      IF((TOTA+ACUM)/2.GT.TOTA)GO TO 178
0145      NI=NI-1
0146 178  K=NI
0147 180  NI=NI+1
0148      IF(NI.GT.32) NI=32
0150 190  TABLE(J)=IZ
0151      LIVV=CC(2,1)-3
0152      LSVV=CC(2,2)+3
0153      LIVH=CC(1,1)-3
0154      LSVH=CC(1,2)+3
0155      DO 220 L=LIVV,LSVV
0156      CALL IRV(CHN,L,BUF)
0157      CALL WAIT
0158      DO 210 J=LIVH,LSVH
0159      K=IBYTE(J-1,BUF)+1
0160 210  BUF(J)=TABLE(K)
0161      CALL IAV(S,L,BUF)
0162      CALL WAIT
0163 220  CONTINUE
      C OBTENCAO DAS MATRIZES DE COCORRENCIA
0164      NN=CC(1,1)+DIST
0165      NORM(1)=2*(IDX-DIST)*IDY
0166      NORM(2)=2*(IDY-DIST)*IDX
0167      NORM(3)=2*(IDX-DIST)*(IDY-DIST)
0168      NORM(4)=NORM(3)
0169      MODQ=1
0170      NB(1)=2
0171      NB(2)=1
0172 240  DO 255 J=1,32
0173      DO 255 I=1,32
```

```
FORTRAN IV          V018-02          FRI 26-NOV-76 20:19:53          PACE 004
CORE=08K, UIC={200,200}          COLETA,LP:/LI:1=DT1:COLETA.

0174 255  P(I,J)=0.0
0175      DO 401 JK=1,DIST
0176      IB=1
0177      JL=CC(2,1)+JK-1
0178      JM=JL+DIST
0179      CALL IRV(5,JL,BUFF(1,IB))
0180      CALL WAIT
0181      DO 400 K=JM,MAK,DIST
0182      CALL IRV(5,K,BUFF(1,NB(IB)))
0183      CALL WAIT
0184      GO TO(300,305,310,315)MODO
0185 300  DO 301 N=NN,IAR
0186      I=IBYTE(N-DIST,BUFF(1,IB))
0187      J=IBYTE(N,BUFF(1,IB))
0188      IF(I.GT.32) I=TABLE(I)
0189      IF(J.GT.32) J=TABLE(J)
0190      P(I,J)=P(I,J)+1.
0192 301  P(J,I)=P(J,I)+1.
0193      GO TO 400
0194 305  DO 302 N=KAR,IAR
0195      I=IBYTE(N,BUFF(1,IB))
0196      J=IBYTE(N,BUFF(1,NB(IB)))
0197      IF(I.GT.32) I=TABLE(I)
0198      IF(J.GT.32) J=TABLE(J)
0200      P(I,J)=P(I,J)+1.
0202 302  P(J,I)=P(J,I)+1.
0203      GO TO 400
0204 310  DO 303 N=NN,IAR
0205      J=IBYTE(N-DIST,BUFF(1,NB(IB)))
0206      I=IBYTE(N,BUFF(1,IB))
0207      IF(I.GT.32) I=TABLE(I)
0208      IF(J.GT.32) J=TABLE(J)
0210      P(I,J)=P(I,J)+1.
0212 303  P(J,I)=P(J,I)+1.
0213      GO TO 400
0214 315  DO 304 N=NN,IAR
0215      I=IBYTE(N-DIST,BUFF(1,IB))
0216      J=IBYTE(N,BUFF(1,NB(IB)))
0217      IF(I.GT.32) I=TABLE(I)
0218      IF(J.GT.32) J=TABLE(J)
0220      P(I,J)=P(I,J)+1.
0222 304  P(J,I)=P(J,I)+1.
0223 400  IB=NB(IB)
0224 401  CONTINUE
0225      WRITE(6,901)MODO
0226 901  FORMAT(1X,'COMPLETA A OBTENCAO DA MATRIZ',I2)
0227      C NORMALIZACAO DAS MATRIZES
0228      DO 405 J=1,32
0229      DO 405 I=1,32
0230 405  P(I,J)=P(I,J)/NORM(MODO)
0231      C OBTENCAO DE CARACTERISTICAS TEXTURAIS A PARTIR DAS MATRIZES
0232      CALL FEXT(VW)
0233      DO 410 I=1,12
0234 406  VPW(I)=VW(I)
0235      GO TO 410
```

```
FORTRAN IV          V01B-02          FRI 26-NOV-76 20:19:53          PAGE 005
CORE=08K, UIC=(200,200)          COLETA,LP:/LI:1=DT1:COLETA.

0236  407  VQW(I)=VW(I)
0237          GO TO 410
0238  408  VRW(I)=VW(I)
0239          GO TO 410
0240  409  VSW(I)=VW(I)
0241  410  CONTINUE
0242          WRITE(6,900)MODO
0243  900  FORMAT(1X,'FIM DA EXTRACAO DE CARACTERISTICAS DA MATRIZ',I2)
0244          MODO=MODO+1
0245          IF(MODO-4)240,240,420
0246  420  DO 450 I=1,12
0247          FEMED(I)=(VPW(I)+VQW(I)+VRW(I)+VSW(I))/4
0248          Z=FEMED(I)
0249          TAB=(VPW(I)-Z)**2+(VQW(I)-Z)**2+(VRW(I)-Z)**2+(VSW(I)-Z)**2
0250          FEDEP(I)=SORT(TAB)
0251          AMAX=AMAX1(VPW(I),VQW(I),VRW(I),VSW(I))
0252          AMIN=AMIN1(VPW(I),VQW(I),VRW(I),VSW(I))
0253  450  FERAG(I)=AMAX-AMIN
0254          WRITE(5,500)((FEMED(I),FEDEP(I),FERAG(I)),I=1,12),((XMEDIA(I),
CXVAR(I)),I=1,4),SC,ICLASS)
0255  500  FORMAT(1X,12(3E17.8,/,),4(2E17.9,/,),5I6.///)
0256          CALL CLOSE(5)
0257          WRITE(3,'NREC')((FEMED(I),FEDEP(I),FERAG(I)),I=1,12),((XMEDIA(I)
CXVAR(I)),I=1,4),SC,ICLASS)
0259          GO TO 89
0259  2000  NRD=NREC-1
0260          WRITE(6,404)NRD
0261  404  FORMAT(1X,'TOTAL DE JANELAS PROCESSADAS=',I4)
0262          CALL CLOSE(3)
0263          STOP
0264          END
```

FOPTRAN IV V01B-02 FRI 26-NOV-76 20:21:26 PAGE 001
CORE=09K, OIC=[200,200] COLETA,LP:/LI:1=011:COLETA.

```
0001            SUBROUTINE JANELA(EC,IC,DD,SC,JCB,IDX,IDY)
0002            INTEGER EC(2,2),IC(2,2),DD(2,2),SC(2,2),CURSOR(5)
0003            LOGICAL*1 W(74)
0004    82        CALL OUTPUT(27,12)
0005            WRITE(6,85)EC
0006    85        FORMAT(' EX1=',I6,3X,'EY1=',I6,10X,'EX2=',I6,3X,'EY2=',I6)
0007            WRITE(6,88)IC
0008    88        FORMAT(' IX1=',I6,3X,'IY1=',I6,10X,'IX2=',I6,3X,'IY2=',I6)
0009            WRITE(6,90)
0010    90        FORMAT(/,1X,'ESCOLHA DA JANELA:CR P/ LER COORDENADAS ERTS',/)
0011            NUMB=1
0012    92        CALL OUTPUT(7)
0013            READ(6,20)W
0014    20        FORMAT(74A1)
0015            IF(W(1).EQ."130)GO TO 110
0016            CALL IRK(CURSOR)
0017            DD(1,1)=CURSOR(2)-2*CURSOR(3)-1
0018            DD(1,2)=CURSOR(2)+2*CURSOR(3)
0019            DD(2,1)=CURSOR(4)-2*CURSOR(5)
0020            DD(2,2)=CURSOR(4)+2*CURSOR(5)+1
0021            DO 93 J=1,2
0022            DO 93 K=1,2
0023            DO 93 J=1,2
0024    93        SC(K,J)=DD(K,J)-IC(K,1)+EC(K,1)
0025            IDX=DD(1,2)-DD(1,1)+1
0026            IDY=DD(2,2)-DD(2,1)+1
0027            NUMB=NUMB+1
0028            IF(NUMB.LE.13)GO TO 95
0029            CALL OUTPUT(27,12)
0030            WRITE(6,85)EC
0031            WRITE(6,88)IC
0032            WRITE(6,90)
0033            NUMB=1
0034            WRITE(6,100)SC,IDX,IDY
0035    95        WRITE(6,100)SC,IDX,IDY
0036    100        FORMAT(' X1=',I4,2X,'Y1=',I4,3X,'X2=',I4,2X,'Y2=',
              C'I4,2X,'DX=',I3,2X,'DY=',I3)
0037            GO TO 92
0038    110        WRITE(6,115)
0039    115        FORMAT('SSEGUIR,CICLAR OU PARAR?(S/C/P)>',2X)
0040            CALL OUTPUT(7)
0041            READ(6,20)W
0042            CALL FRONT(W,74)
0043            JOB=1
0044            IF(W(1).EQ."103)GO TO 82
0045            IF(W(1).NE."123.AND.W(1).NE."120)GO TO 110
0046            IF(W(1).EQ."120) JOB=0
0047            RETURN
0048            RETURN
0049            RETURN
0050            RETURN
0051            END
```


FORTRAN IV V018-02 FRI 26-NOV-76 19:15:17 PAGE 001
CORE=08K, UIC=[200,200] SUBROTS,LP:/LI:1=D11:SUBROTS.

```
0001            SUBROUTINE SUMVAR(F6,F7)
0002            COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003            F7=0.0
0004            DO 10 I=2,64
0005            H=1-F6
0006        10    F7=F7+H*H*BETA(I)
0007            RETURN
0008            END
```

FORTRAN IV V018-02 FRI 26-NOV-76 19:15:40 PAGE 001
CORE=08K, UIC=[200,200] SUBROTS,LP:/LI:1=D11:SUBROTS.

```
0001            SUBROUTINE SUMENI(F8)
0002            COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003            F8=0.0
0004            DO 10 I=2,64
0005        10    F8=F8-BETA(I)*ALOG(BETA(I)+1.0E-7)
0006            RETURN
0007            END
```

FORTRAN IV V018-02 FRI 26-NOV-76 19:16:03 PAGE 001
CORE=08K, UIC=[200,200] SUBROTS,LP:/LI:1=D11:SUBROTS.

```
0001            SUBROUTINE ENT(F9)
0002            COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003            F9=0.0
0004            DO 20 I=1,31
0005            F9=F9-(P(I,I))*ALOG(P(I,I)+1.0E-7)
0006            K=I+1
0007            DO 10 J=K,32
0008        10    F9=F9-2*(P(I,J))*ALOG(P(I,J)+1.0E-7)
0009        20    CONTINUE
0010            F9=F9-P(32,32)*ALOG(P(32,32)+1.0E-7)
0011            RETURN
0012            END
```

FORTRAN IV V018-02 FRI 26-NOV-76 19:16:29 PAGE 001
CORE=08K, UIC=(200,200) SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001            SUBROUTINE DIFVAR(F10)
0002            COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003            DIFAVE=0.0
0004            DO 10 I=1,31
0005        10    DIFAVE=DIFAVE+I*GAMA(I+1)
0006            F10=0.0
0007            DO 20 J=0,31
0008            H=I-DIFAVE
0009        20    F10=F10+H*H*GAMA(I+1)
0010            RETURN
0011            END
```

FORTRAN IV V018-02 FRI 26-NOV-76 19:16:53 PAGE 001
CORE=08K, UIC=(200,200) SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001            *SUBROUTINE DIFENT(F11)
0002            COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003            F11=0.0
0004            DO 10 I=0,31
0005            W=GAMA(I+1)
0006        10    F11=F11-W*ALOG(W+1.0E-7)
0007            RETURN
0008            END
```

FORTRAN IV V018-02 FRI 26-NOV-76 19:17:18 PAGE 001
CORE=08K, UIC=(200,200) SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001            SUBROUTINE CORNE(F9,F12)
0002            COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003            HZ=0.0
0004            HXY1=0.0
0005            DO 20 I=1,32
0006            H=ALFA(I)*ALFA(I)
0007            HZ=HZ-(ALFA(I))*ALOG(ALFA(I)+1.0E-7)
0008            A=ALOG(H+1.0E-7)
0009            HXY1=HXY1-A*P(I,I)
0010            N=I+1
0011            IF(N.GT.32)GOTO 30
0012            DO 20 J=N,32
0013            B=(ALFA(I))*ALFA(J)
0014            C=ALOG(B+1.0E-7)
0015            HXY1=HXY1-2*C*P(I,J)
0016        20    HXY1=HXY1-2*C*P(I,J)
0017        30    F12=(F9-HXY1)/HZ
0018            RETURN
0019            END
```

FORTRAN IV V01B-02
CORE=08K, UIC=(200,200)

FBI 26-NOV-76 19:17:44

PAGE 001

SUBROTS,LP:/LI:1=DT1:SUBROTS.

```
0001            SUBROUTINE FEXT(VW)
0002            DIMENSION VW(12)
0003            COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0004            CALL AUX
0005            CALL AUX1
0006            CALL AUX0
0007            CALL ASM(VW(1))
0008            CALL CONT(VW(2))
0009            CALL COR(U,VW(3))
0010            CALL VAR(U,VW(4))
0011            CALL XIDM(VW(5))
0012            CALL SUMAVE(VW(6))
0013            CALL SUMVAR(VW(6),VW(7))
0014            CALL SUMENT(VW(8))
0015            CALL ENT(VW(9))
0016            CALL DIFVAR(VW(10))
0017            CALL DIFENT(VW(11))
0018            CALL CORME(VW(9),VW(12))
0019            RETURN
0020            • END
```


FORTRAN IV V018-02
CORE=08K, GIC=(200,200)

FRI 26-NOV-76 20:26:10

PAGE 003

HGRAM,LP:/LI:1=D11:HGRAM.

```
0117            CALL ANMODE
0118            WRITE(6,800) IFEAT,ICLA
0119    800      FORMAT(1X,'CAPACTERISTICA USADA:',13,5X,'CLASSES ',11,
                  C' E ',11)
0120            READ(6,20)W
0121            CALL OUTPUT(27,12)
0122            GO TO 55
0123    2000    STOP
0124            END
```


FORTRAN IV V01B-02
CORE=08K, UIC=(200,200)

FRI 26-NOV-76 20:26:10

PAGE 002

CATEG,LP:/LI:1=DT1:CATEG.

```
0052      CALL CLOSE(3)
C NORMALIZACAO DOS FEATURES DENTRO DE CADA COMPONENTE
0053      DO 2100 J=1,JDIM
0054          XMAX=X(1,1)
0055          XMIN=XMAX
0056      DO 2050 J=2,NUMB
0057          XMAX=AMAX1(XMAX,X(I,J))
0058      2050 XMIN=AMIN1(XMIN,X(I,J))
0059      DO 2080 J=1,NUMB
0060      2080 X(I,J)=(X(I,J)-XMIN)/(XMAX-XMIN)
0061      2100 CONTINUE
0062      104 WRITE(6,105)
0063      105 FORMAT('SQUER USAR O (M)INMAX OU O (V)IZINHO MAIS PROXIMO?>>')
0064      CALL OUTPUT(7)
0065      READ(6,5)W
0066      CALL FRONT(W,74)
0067      IF(W(1).EQ."130)GO TO 2000
0069      IF(W(1).EQ."126)GO TO 530
0071      IF(W(1).NE."115)GO TO 104
C
C CLASSIFICACAO COM O METODO MINMAX
C
0073      DO 110 I=1,KCLA
0074      110 INIC(I)=0
0075      DO 200 I=1,NUMB,2
0076          J=LX(I)
0077          IF(INIC(J).EQ.1)GO TO 200
0079          DO 150 M=1,JDIM
0080              A(M,J)=X(M,I)
0081      150 B(M,J)=X(M,I)
0082              INIC(J)=1
0083              DO 170 N=1,KCLA
0084                  IF(INIC(N).NE.1)GO TO 200
0086      170 CONTINUE
0087                  GO TO-250
0088      200 CONTINUE
0089                  WRITE(6,210)
0090      210 FORMAT(1X,'ENGANO-NAO EXISTEM TANTAS CLASSES!')
0091                  GO TO 21
C DETERMINACAO DO PARALELEPIPEDO CORRESPONDENTE A CADA
C CLASSE USANDO O CONJUNTO DE TREINO(AMOSTRAS IMPARES)
0092      250 DO 220 N=1,KCLA
0093      220 INIC(N)=0
0094          DO 400 I=1,NUMB,2
0095              N=LX(I)
0096              INIC(N)=INIC(N)+1
0097              DO 230 M=1,JDIM
0098                  A(M,N)=AMAX1(A(M,N),X(M,I))
0099      230 B(M,N)=AMIN1(B(M,N),X(M,I))
0100      400 CONTINUE
0101          DO 430 J=1,KCLA
0102              DO 430 M=1,JDIM
0103                  TETA=(A(M,J)-B(M,J))/(INIC(J)-1)
0104                  A(M,J)=A(M,J)+TETA
0105      430 B(M,J)=B(M,J)-TETA
0106              DO 440 MOD=1,3
```


FORTRAN IV V018-02 FRI 26-NOV-76 20:26:10 PAGE 001
CORE=08K, DIC=[200,200] CATEG,LF:/LI:1=DI1:CATEG.

```
0001            SUBROUTINE TESTA(JDIM,KCLA,A,B,Y,ICAT,MOD)
0002            DIMENSION A(20,5),B(20,5),Y(20),PRB(5),LIM(5)
0003            NO=0
0004            DO 15 I=1,KCLA
0005            LIM(I)=0
0006            DO 5 J=1,JDIM
0007            IF(Y(J).LT.B(J,I).OR.Y(J).GT.A(J,I))GO TO 15
0009        5        CONTINUE
0010            LIM(I)=1
0011            NO=NO+1
0012        15        CONTINUE
0013            IF(NO.EQ.0)GO TO 500
0015            IF(NO.GT.1)GO TO 300
0017            DO 30 I=1,KCLA
0018            IF(LIM(I).EQ.1)GO TO 40
0020        30        CONTINUE
0021            ICAT=1
0022            MOD=1
0023            RETURN
0024        300        PRBM=0.0
0025            DO 350 I=1,KCLA
0026            IF(LIM(I).NE.1)GO TO 350
0028            PRB(I)=1.0
0029            DO 330 J=1,JDIM
0030        330        PRB(I)=PRB(I)/(A(J,I)-B(J,I))
0031            PRBM=PRBM+Y(I)*(PRB(I),PRBM)
0032        350        CONTINUE
0033            DO 360 I=1,KCLA
0034            IF(LIM(I).NE.1)GO TO 360
0036            IF(PRB(I).EQ.PRBM)GO TO 380
0038        360        CONTINUE
0039            ICAT=I
0040            MOD=2
0041            RETURN
0042        500        PRBM=0.0
0043            DO 600 J=1,KCLA
0044            PRB(J)=0.0
0045            DO 550 I=1,JDIM
0046            IF(Y(I).GT.B(I,J).OR.Y(I).LT.A(I,J))GO TO 550
0048            TETA=Y(I)-B(I,J)
0049            TETA=ABS(TETA)
0050            VETA=Y(I)-A(I,J)
0051            VETA=ABS(VETA)
0052            TETA=AMIN1(VETA,TETA)
0053            PRB(J)=PRB(J)+TETA*TETA
0054        550        CONTINUE
0055            IF(J.EQ.1)PRBM=PRB(J)
0057        600        PRBM=AMIN1(PRBM,PRB(J))
0058            DO 710 J=1,KCLA
0059            IF(PRBM.EQ.PRB(J))GO TO 720
0061        710        CONTINUE
0062            ICAT=J
0063            MOD=3
0064            RETURN
0065            END
```

PROPOSTA PARA PUBLICAÇÃO

DATA fev/86

IDENTIFICAÇÃO	TÍTULO <u>Textural Features for Image Classification in Remote Sensing</u>	
	AUTORIA <u>Vitor Haerfel</u> <u>Yosuo E. Shimabukuro</u>	
	PROJETO/PROGRAMA	
	DIVISÃO	
	DEPARTAMENTO	<u>DSR</u>
DIVULGAÇÃO <input checked="" type="checkbox"/> EXTERNA <input type="checkbox"/> INTERNA MEIO: <u>IV SBSR</u>		

REVISÃO TÉCNICA	REVISOR TÉCNICO <u>Nelson Maxarant</u>	APROVADO: <input type="checkbox"/> SIM <input type="checkbox"/> NÃO <input type="checkbox"/> VER VERSO	APROVAÇÕES
	RECEBI EM: <u>18/2/86</u> REVISADO EM: <u>19/2/86</u>	DATA CHEFE DIVISÃO	
	OBSERVAÇÕES: <input type="checkbox"/> NÃO HÁ <input checked="" type="checkbox"/> VER VERSO	APROVADO: <input checked="" type="checkbox"/> SIM <input type="checkbox"/> NÃO <input type="checkbox"/> VER VERSO	
	DEVOLVI EM: <u>19/2/86</u> <u>Nelson Maxarant</u>	<u>28.08.86</u> <u>Tandrin</u>	
	ASSINATURA	DATA CHEFE DEPARTAMENTO	

REVISÃO DE LINGUAGEM	Nº: <u>366</u> PRIORIDADE: <u>2</u>	O(S) AUTOR(ES) DEVE(M) MENCIONAR NO VERSO, OU ANEXAR NORMAS E/OU INSTRUÇÕES ESPECIAIS		DATILOGRAFIA
	DATA: <u>4.9.86</u>			
	REVISADO <input type="checkbox"/> COM <input type="checkbox"/> SEM <input type="checkbox"/> CORREÇÕES <input type="checkbox"/> VER VERSO	RECEBIDO EM:		
	POR: <u>Gloria</u> <u>Tandrin</u>	CONCLUÍDO EM: <u>09/01/86</u>		
DATA: <u>06.10.86</u> ASSINATURA	DATILOGRAFA: <u>Mybelena</u>		ASSINATURA	

PARECER

FAVORÁVEL: SIM VER NÃO VERSO

DATA _____ RESPONSÁVEL/PROGRAMA _____

EM CONDIÇÕES DE PUBLICAÇÃO EM: _____

AUTOR RESPONSÁVEL _____

AUTORIZO A PUBLICAÇÃO: SIM NÃO

DIVULGAÇÃO INTERNA EXTERNA MEIO: _____

OBSERVAÇÕES: _____

DATA _____ DIRETOR _____

SEC	PUBLICAÇÃO: _____ PÁGINAS: _____ ÚLTIMA PÁGINA: _____
	CÓPIAS: _____ TIPO: _____ PREÇO: _____