

SYS 528642
Instituto de Geociências
Biblioteca
Registro 20281
Data 01/06/2000

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

CENTRO ESTADUAL DE PESQUISA EM SENSORIAMENTO REMOTO E METEOROLOGIA

CURSO DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

FEICOES DE TEXTURA PARA CLASSIFICACAO DE IMAGENS

Autor: Sandra Eliza Vielmo Cogo

Orientador: Prof. Vitor Francisco Haertel

T
528.8
C676f
1994

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em Sensoriamento Remoto, Área Teórica no Centro Estadual de pesquisas em Sensoriamento Remoto e Meteorologia da Universidade Federal do Rio Grande do Sul.

Porto Alegre, janeiro de 1994.

BIBLIOTECA VÍTOR HAERTEL
UFRGS
Instituto de Geociências
Biblioteca
Data 24/01/94

AGRADECIMENTOS

Ao término deste trabalho quero agradecer às pessoas e Entidades que contribuíram para a sua conclusão:

Ao professor Vitor Haertel da UFRGS pelo empréstimo de sua experiência na orientação deste trabalho;

Ao professor Rudiney S. Pereira da UFSM pela contribuição no desenvolvimento do programa computacional;

Aos amigos Regis, Alfonso, José Carlos e Laurindo pela contribuição técnica;

Aos funcionários e colegas de curso, pelo apoio e carinho;

Ao Departamento de Matemática da UFSM, pelo apoio no desenvolvimento deste trabalho;

Ao Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia (CEPSRM) da UFRGS.

RESUMO

FEIÇÕES DE TEXTURA PARA CLASSIFICAÇÃO DE IMAGENS

Sandra Eliza Vielmo Cogo

Janeiro, 1994

Presentemente, os métodos utilizados no processo de classificação de imagens, em sua grande maioria, fazem uso exclusivamente dos atributos espectrais. Nesta pesquisa, são introduzidos os atributos espaciais, em particular a textura, no processo de classificação de imagens digitais. As informações de textura são quantificadas pelo método das matrizes de co-ocorrência, proposto por Haralick, e organizadas em um formato similar ao utilizado nas bandas espectrais, gerando desta forma canais de textura. Com a implementação deste atributo em adição aos espectrais, obtêm-se um acréscimo na exatidão obtida no processo de classificação de imagens.

ABSTRACT

TEXTURAL FEATURES FOR IMAGE CLASSIFICATION

Sandra Eliza Vielmo Cogo

January, 1994

Most of the digital image classification methods presently available are based on image spectral attributes. In this study image texture is introduced into the classification process along with the spectral data. Gray level co-occurrence matrices as proposed by Haralick were used to generate "texture bands" formatted in a similar way as in the conventional spectral bands. The proposed algorithm was then tested using satellite imagery. The results have shown a gain in accuracy with respect to the more conventional classification procedures based only on image spectral attributes.

SUMÁRIO

	Página
LISTA DE FIGURAS	vii
LISTA DE TABELAS	ix
LISTA DE SÍMBOLOS UTILIZADOS	x
CAPÍTULO I - INTRODUÇÃO	01
CAPÍTULO II - REVISÃO BIBLIOGRÁFICA	06
CAPÍTULO III - MATERIAIS E MÉTODOS	20
III.1 - Matrizes de Co-ocorrência Espacial	20
III.2 - Feições de Textura	27
III.3 - Método de Classificação	32
III.4 - Descrição da Área de Estudo	35
III.5 - Descrição do Programa Computacional	37
CAPÍTULO IV - RESULTADOS.....	40
IV.1 - Processamentos da Imagem	40
IV.2 - Análise Qualitativa	49
IV.3 - Análise Quantitativa	52
CAPÍTULO V - CONCLUSÕES E RECOMENDAÇÕES	58
REFERÊNCIAS BIBLIOGRÁFICAS	60
ANEXO I: Listagem do Programa Computacional	64

LISTA DE FIGURAS

		Página
Figura II.1	Áreas circulares no domínio das frequências ..	10
Figura II.2	Áreas em forma de cunha no domínio das frequências	11
Figura III.1	Representação de pixels vizinhos em relação a um pixel central	21
Figura III.2	Forma geral da matriz de co-ocorrência	22
Figura III.3	Exemplo de região associada com os níveis de cinza	24
Figura III.4	Matrizes de co-ocorrência associadas à região da Figura III.3	24
Figura III.5	Forma geral de uma imagem de dimensão $N_y \times N_x$..	26
Figura III.6	Gráfico da função $f(x) = x \log x$	30
Figura III.7	Regiões homogênea e heterogênea	31
Figura III.8	Bandas espectrais 3 e 5 do LANDSAT TM 5	36
Figura III.9	Área de estudo, Parque Nacional das Emas	37
Figura III.10	Descrição do programa desenvolvido	39
Figura IV.1	Feições de textura obtidas no 1 ^o processamento da imagem	42
Figura IV.2	Feições de textura obtidas no 2 ^o processamento da imagem	44

Figura IV.3	Feições de textura obtidas no 3 ^o processamento da imagem	46
Figura IV.4	Feições de textura obtidas no 4 ^o processamento da imagem	48

LISTA DE TABELAS

	Página
Tabela IV.1 Componentes principais para a classificação II.	53
Tabela IV.2 Componentes principais para a classificação III	54
Tabela IV.3 Componentes principais para a classificação IV.	54
Tabela IV.4 Componentes principais para a classificação V..	54
Tabela IV.5 Resultados para a classificação I	55
Tabela IV.6 Resultados para a classificação II	55
Tabela IV.7 Resultados para a classificação III	56
Tabela IV.8 Resultados para a classificação IV	57
Tabela IV.9 Resultados para a classificação V	57

LISTA DE SÍMBOLOS UTILIZADOS

N_x = número de pixels na direção horizontal

N_y = número de pixels na direção vertical

D_x = domínio espacial horizontal

D_y = domínio espacial vertical

$N^2 = N_x \cdot N_y$ = número de pixels na imagem

N_g = número de níveis de cinza

$(x,y), (k,l), (m,n)$ = coordenadas de um pixel no domínio espacial

(u,v) = coordenadas de um pixel no domínio das frequências

$f(x,y)$ = brilho ou nível de cinza associado ao pixel (x,y)

i, j = níveis de cinza

d = distância entre pixels vizinhos

C = pixel central da janela

(r,s) = coordenadas do pixel central da janela móvel

$I(k,l)$ = transmissão de uma transparência da imagem até a posição
 (k,l)

$\rho(x,y)$ = função de auto-correlação

$F(u,v)$ = transformada de Fourier discreta

R_1, R_2 = raios no domínio das frequências

Φ_1, Φ_2 = ângulos no domínio das frequências

$\phi_{R_1 R_2}$ = feição de textura baseada em áreas circulares

$\phi_{\Phi_1 \Phi_2}$ = feição de textura baseada em áreas em forma de cunha

c = comprimento de uma série

N_r = número de séries

$q(i,c)$ = número de séries de um nível de cinza i e comprimento c

$\underline{X}_{k,l}$ = vetor de atributos associado ao pixel (k,l)

\underline{x} = vetor genérico de atributos

P_{ij} = $P(i,j)$ = número de pares de pixels, um com nível de cinza i e outro com nível de cinza j (entradas da matriz de co-ocorrência)

P_H = matriz de co-ocorrência horizontal

P_V = matriz de co-ocorrência vertical

P_{DD} = matriz de co-ocorrência diagonal direita

P_{DE} = matriz de co-ocorrência diagonal esquerda

R = fator de normalização da matriz de co-ocorrência

f_1 = feição do segundo momento angular

f_2 = feição de entropia

f_3 = feição do momento da diferença

f_R = valor da feição em número real

f_B = valor da feição em byte

f_{\max} , f_{\min} = valores máximo e mínimo da feição em número real, respectivamente

$\omega(j)$ = j -ésima classe presente na cena

$p[\underline{x}/\omega(j)]$ = probabilidade condicional de \underline{x} , dada a classe $\omega(j)$.

$p[\omega(j)/\underline{x}]$ = probabilidade " a posteriori" da classe $\omega(j)$ acontecer, dado \underline{x}

$p[\omega(j)]$ = probabilidade " a priori" da classe $\omega(j)$

$p[\underline{x}]$ = função densidade de probabilidade incondicional de \underline{x}

K = número de pontos da amostra

$\underline{\mu}_j$ = vetor média da classe $\omega(j)$

\underline{m}_j = estimativa do vetor média da classe $\omega(j)$

$\underline{\Sigma}_j$ = matriz de covariância da classe $\omega(j)$

\underline{C}_j = estimativa da matriz de covariância da classe $\omega(j)$

FEIÇÕES DE TEXTURA PARA CLASSIFICAÇÃO DE IMAGENS

CAPÍTULO I

INTRODUÇÃO

Uma imagem pode ser analisada através de seus atributos, os quais podem ser classificados em três grupos: espectrais, espaciais e de contexto. Os atributos espectrais estão relacionados com o brilho, isto é, a quantidade de energia refletida pelos alvos que compõem a imagem. Esses atributos são especialmente utilizados no caso de imagens multiespectrais. Os atributos espaciais contêm informações a respeito de itens como forma de objetos (alvos) e textura da imagem e os atributos de contexto estão relacionados à informação obtida de áreas vizinhas àquela sendo analisada.

Presentemente, os métodos utilizados no processo de classificação de imagens, em sua grande maioria fazem uso exclusivamente dos atributos espectrais, por serem de quantificação mais fácil. Este fato acarreta uma perda na exatidão da classificação de imagens, pois não estão sendo utilizadas todas as informações disponíveis na imagem. Historicamente, pesquisadores têm mostrado um grande interesse no uso da informação espacial, em particular a textura, para aplicações em Sensoriamento Remoto.

Não existe uma definição precisa nem uma aproximação matemática formal para a quantificação da textura de uma imagem, mas todas as definições estão relacionadas à impressão de

rugosidade e contraste criada pela variação de tonalidade ou repetição de padrões visuais sobre a superfície. Os fotointérpretes, por exemplo, utilizam simultaneamente esses conceitos interrelacionados quando identificam feições da superfície em uma imagem. Assim os conceitos de textura e tonalidade estão interrelacionados, como por exemplo, a relação entre partícula e onda.

A tonalidade refere-se ao brilho de uma superfície, e sua percepção depende da quantidade de luz emitida ou refletida pela superfície e conseqüentemente ao valor dos níveis de cinza dos pixels em uma imagem. A textura, por outro lado, está associada com variações no valor do brilho entre pixels próximos entre si.

Considera-se que a textura é formada por "grupos de pixels" que internamente tem um nível de cinza uniforme. Geralmente, estes grupos são chamados primitivas tonais. O tamanho (número de pixels), sua distribuição espacial ao longo da imagem e os valores dos níveis de cinza entre as primitivas tonais definem a textura (fina, grosseira, ...). Assim, as relações intuitivas básicas entre tonalidade e textura são as seguintes: Quando uma pequena região em uma imagem apresenta pouca variação das primitivas tonais, a propriedade dominante passa a ser a tonalidade. Quando essa região tem uma grande variação das primitivas tonais, a textura torna-se a propriedade dominante. Crucial nesta distinção é o número de primitivas tonais distintas existentes. Quando este número decresce, a propriedade tonalidade predominará. De fato, quando a região é reduzida a um pixel, a única propriedade presente é a tonalidade.

Quando o número de primitivas tonais distintas aumenta, a propriedade textura predominará.[10]

Quando o padrão espacial das primitivas tonais é aleatório e a variação dos níveis de cinza é alta, uma textura fina resultará. Quando o padrão espacial torna-se mais definido e a região envolve um número maior de pixels, uma textura grosseira resultará. Assim, a textura pode ser relacionada com frequências espaciais, devido a que texturas finas são mais ricas em altas frequências espaciais do que as texturas grosseiras.

Em suma, para caracterizar a textura, deve-se caracterizar as propriedades das primitivas tonais, bem como as interrelações espaciais entre elas.

A aplicação de tonalidade e textura para análise digital requer uma caracterização quantitativa dos conceitos visuais. Medidas de radiância adquiridas por varredores multiespectrais e traduzidas em contadores digitais nas CCTs, quantificam a tonalidade. Essas medidas de tonalidade têm sido usadas para o reconhecimento de padrões via análise de imagens digitais.

A quantificação da informação de textura, no entanto, não é diretamente adquirida pelos sistemas sensores e deve ser extraída a partir dos valores dos contadores digitais na imagem.

A análise da informação de textura em uma imagem requer necessariamente uma análise de pixels em uma vizinhança. Por isso, exatamente como o processo de filtragem espacial é mais

demorado computacionalmente que outras operações, os algoritmos de extração da informação de textura geralmente requerem um tempo computacional consideravelmente maior do que um algoritmo pixel-a-pixel, como por exemplo, o que implementa a razão de bandas espectrais.

O interesse científico desse trabalho é a aplicação da textura no processo de classificação de uma imagem digital. Para tal, as características texturais serão quantificadas e organizadas em um formato similar ao utilizado nas bandas espectrais, gerando dessa forma bandas texturais ou canais de textura. A geração desses canais exige processos mais elaborados e que vêm sendo alvo de atenção de vários pesquisadores.

Além disso, a implementação dos atributos de textura em adição aos espectrais, constitui-se em um passo importante na melhoria dos resultados de classificação das imagens digitais. Nesta dissertação, os capítulos estão organizados da seguinte forma.

No capítulo II, são apresentadas algumas aproximações descritas na literatura para a quantificação da textura em uma imagem. Além disso, são relatadas algumas aplicações associadas a estas aproximações.

O modelo matemático adotado neste trabalho consiste no método das matrizes de co-ocorrência dos níveis de cinza sugerido por Haralick *et alii* [9]. Este método é descrito detalhadamente no capítulo III. Além disso, são descritas as feições de textura utilizadas para posterior aplicação no processo de classificação

via máxima verossimilhança Gaussiana. Também, é feita uma descrição da área de estudo utilizada e do programa computacional desenvolvido.

Os processamentos executados na imagem e as análises qualitativas e quantitativas dos resultados encontram-se no capítulo IV.

Finalmente, no capítulo V são apresentadas as conclusões e recomendações deste trabalho com base nos resultados obtidos. No anexo I, encontra-se o programa computacional desenvolvido.

CAPÍTULO II

REVISÃO BIBLIOGRÁFICA

Embora facilmente percebida visualmente, a textura de uma imagem não tem uma definição precisa ou uma aproximação matemática formal para sua quantificação. Essa situação, torna a textura de uma imagem, um tanto difícil para modelagem. No entanto, tentativas para modelar feições espaciais, em particular a textura, podem ser encontradas na literatura especializada.

Uma excelente coleção de artigos, relatando progresso nesta área pode ser encontrado em Rosenfeld [19].

A modelagem da textura de uma imagem é muito importante para uma boa compreensão das características espaciais de uma imagem digital. Na prática, as características texturais são quantificadas por métodos heurísticos. Uma revisão de técnicas de extração da textura de uma imagem pode ser encontrada em Araújo [1] e Haralick [10].

Os modelos heurísticos para caracterização da textura de uma imagem, relatados na literatura, estão baseados na intuição ou percepção individual dos pesquisadores. Algumas das aproximações mais tradicionais para quantificação da textura de uma imagem são:

- Funções de auto-correlação (Auto-correlation Function)
- Espectro da potência de Fourier (Fourier Power Spectrum)
- Comprimento da série de um nível de cinza (Gray Level Run Length)

- Matrizes de co-ocorrência dos níveis de cinza (Gray Level Co-occurrence Matrices)
- Matrizes de co-ocorrência generalizadas (Generalized Co-occurrence Matrices)
- Transformadas de textura (Texture Transforms)

- FUNÇÕES DE AUTO-CORRELAÇÃO:

Uma textura particular é constituída de regiões, chamadas primitivas tonais, as quais são entidades geralmente uniformes tendo aproximadamente as mesmas dimensões, enquanto dentro de uma mesma região textural. Quando essas regiões elementares têm grandes dimensões, o resultado é uma textura grosseira. Uma dimensão pequena resulta em texturas finas. A função de auto-correlação é uma feição sensível a esse aspecto da textura, isto é, diz respeito ao tamanho das primitivas tonais.[10]

Como descrito em Haralick [10], a função de auto-correlação pode ser facilmente compreendida, considerando um experimento idealizado. Considere duas transparências, as quais são cópias exatas uma da outra. Cobrindo uma completamente com a outra e com uma fonte de luz uniforme, mede-se a luz média transmitida através da dupla transparência. Após, translada-se uma transparência relativa a outra e mede-se unicamente a luz média transmitida através da porção da imagem onde uma transparência cobriu a outra. Um diagrama dessas medidas como função da posição transladada (x,y) e normalizada em relação à posição inicial (x=0, y=0), descreve a função de auto-correlação

bidimensional da transparência da imagem.

Seja $I(k,l)$ a transmissão de uma transparência da imagem até a posição (k,l) . Assumimos que dentro de uma região retangular $0 \leq k \leq L_x$ e $0 \leq l \leq L_y$, a transmissão é nula e (x,y) representa a translação em x e y , respectivamente. Para texturas grosseiras, a auto-correlação diminuirá lentamente com a distância, enquanto para texturas finas diminuirá rapidamente com a distância. A função de auto-correlação $\rho(x,y)$ para a transparência da imagem é formalmente definida por:

$$\rho(x,y) = \frac{L_x L_y}{(L_x - |x|)(L_y - |y|)} \frac{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} I(k,l)I(k+x,l+y)dkdl}{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} I^2(k,l)dkdl}$$

onde

x,y são as translações ao longo das direções x e y , respectivamente;

$0 \leq k \leq L_x$ e $0 \leq l \leq L_y$ definem uma região fora da qual a transmissão da imagem é nula;

$I(k,l)$ denota a transmissão da transparência de uma imagem até a posição (k,l) .

Kaiser [15] relata experimentos onde verifica se a função de auto-correlação tem alguma relação com a textura que os fotointérpretes observam em imagens.

- ESPECTRO DA POTÊNCIA DE POTÊNCIA:

A técnica do espectro da potência de Fourier é

amplamente usada como um instrumento na análise da textura de imagens, sendo obtida com o uso da Transformada de Fourier. A Transformada de Fourier Discreta de uma imagem digital é dada por:

$$F(u,v) = \frac{1}{N^2} \sum_{x=1}^N \sum_{y=1}^N f(x,y) e^{-2\pi i(xu + yv)}$$

onde:

$f(x,y)$ é o brilho do pixel (medido geralmente em valores de contador digital)

x,y : coordenadas do pixel no domínio espacial

u,v : coordenadas no domínio das frequências ou de Fourier, com $1 \leq u,v \leq N$.

O Espectro da Potência de Fourier é dado por

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

onde * denota o complexo conjugado.

A distribuição radial dos valores em $|F|^2$ é sensível a rugosidade da textura em f . Uma textura grosseira terá altos valores de $|F|^2$ concentrados perto da origem, significando baixas frequências espaciais. Enquanto, uma textura fina gerará valores de $|F|^2$ mais afastados da origem, significando altas frequências espaciais.

Uma feição de textura baseada em áreas circulares no

domínio de Fourier, que é sensível a característica acima é da forma:

$$\phi_{R_1 R_2} = \sum_{\substack{R_1^2 < u^2 + v^2 < R_2^2 \\ 1 \leq u, v \leq N}} |F(u, v)|^2$$

para vários valores de R_1 e R_2 , conforme a figura II.1.




Figura II.1: Áreas circulares no domínio das frequências.

Similarmente, $|F(u, v)|^2$ é sensível a direcionalidade da textura de uma imagem, que pode ser detectada pela análise de áreas em forma de cunha no domínio de Fourier. Assim, a direcionalidade da textura pode ser analisada por:

$$\phi_{\Phi_1 \Phi_2} = \sum_{\substack{\Phi_1 < \text{tg}^{-1}(v/u) < \Phi_2 \\ 1 \leq u, v \leq N}} |F(u, v)|^2$$

para vários valores de Φ_1 e Φ_2 , conforme a figura II.2.

Essas duas feições descritas são sensíveis à frequência espacial ou a direcionalidade da textura, mas não a ambos simultaneamente.




Figura II.2: Areas em forma de cunha no domínio das frequências.

Vários experimentos usando o Espectro da Potência de Fourier para a análise da textura de uma imagem são relatados em Weszka *et alli* [24].

- COMPRIMENTO DA SÉRIE DE UM NÍVEL DE CINZA:

Se examinarmos uma sequência de pixels contíguos ao longo de uma imagem, ocasionalmente podemos encontrar séries de pixel consecutivos que têm o mesmo nível de cinza. Assim, o comprimento da série de um nível de cinza (Gray Level Run Length) é definido como uma sequência de pixels linearmente adjacentes, todos tendo o mesmo nível de cinza, isto é, o mesmo valor para o contador digital.

A textura da imagem pode ser caracterizada pela quantidade $q(i,c)$, onde i representa um dado nível de cinza (ou intervalo de níveis de cinza) e c representa o comprimento da série, isto é, número de pixels adjacentes segundo uma dada

direção com o mesmo nível de cinza i .

A frequência $q(i,c)$ representa o número de séries de nível de cinza i e comprimento c , os quais ocorrem em uma imagem ao longo de uma dada direção.

Imagens de textura fina produzem um grande número de séries de comprimento pequeno, enquanto textura grosseira causa um grande número de séries de comprimento longo. Também, direcionalidade da textura pode ser investigada somando-se os comprimentos das séries de nível de cinza ao longo de diferentes direções.

Weszka *et alii* [24] derivou as seguintes feições a partir dos comprimentos das séries de nível de cinza para caracterizar textura em fotografias aéreas:

Ênfase no Comprimento da Série (Long Run Emphasis):

$$\text{LRE} = \frac{\sum_{i=1}^{N_g} \sum_{c=1}^{N_r} c^2 q(i,c)}{\sum_{i=1}^{N_g} \sum_{c=1}^{N_r} q(i,c)}$$

Distribuição dos níveis de cinza (Gray Level Distribution):

$$\text{GLD} = \frac{\sum_{i=1}^{N_g} \sum_{c=1}^{N_r} (\sum q(i,c))^2}{\sum_{i=1}^{N_g} \sum_{c=1}^{N_r} q(i,c)}$$

Distribuição do comprimento da série (Run Length Distribution):

$$RLD = \frac{\sum_{c=1}^{N_r} (\sum_{i=1}^{N_g} q(i,c))^2}{\sum_{i=1}^{N_g} \sum_{c=1}^{N_r} q(i,c)}$$

Porcentagem da série (Run Percentage):

$$RPC = \sum_{i=1}^{N_g} \sum_{c=1}^{N_r} \frac{q(i,c)}{N^2}$$

onde N^2 é o número de pixels na imagem, $q(i,c)$ é o número de séries de comprimento c e nível de cinza i , N_g é o número de níveis de cinza e N_r o número de séries.

Para detectar direcionalidade da textura, os comprimentos das séries dos níveis de cinza são usualmente medidos ao longo das direções 0° , 45° , 90° e 135° .

Os experimentos relatados por Weszka *et alli* [24] mostram que este método geralmente é inferior a outros métodos propostos, como por exemplo, Espectro da Potência de Fourier e Matrizes de co-ocorrência dos níveis de cinza.

- MATRIZES DE CO-OCORRÊNCIA DOS NÍVEIS DE CINZA:

As matrizes de co-ocorrência dos níveis de cinza têm sido utilizadas por muitos pesquisadores para descrever textura em uma imagem.[5, 10, 11]

Chen *et alii* [2] mostra que a aproximação das matrizes de co-ocorrência dos níveis de cinza é mais útil para discriminação da textura que outros métodos como Espectro da Potência de Fourier ou o comprimento da série de um nível de cinza.

Neste método é assumido que as características texturais de uma dada imagem podem ser adequadamente especificadas por um conjunto de matrizes de dependência espacial dos níveis de cinza, as quais são baseadas nas frequências de ocorrência de pares de níveis de cinza com determinada separação.

Haralick *et alii* [9] obteve estatísticas a partir de matrizes de co-ocorrência dos níveis de cinza e utilizou-as para classificar fotografias aéreas e imagens de satélite. Uma classificação correta de 82% foi obtida utilizando um conjunto de fotografias aéreas com oito classes (residencial antiga, residencial nova, lago, charco, pântano, urbana, ferrovia, mato ou bosque). Esta mesma aproximação foi também usada para classificar imagens LANDSAT MSS que incluem sete classes (mata costeira, matas, culturas anuais, área urbana, pequenos e grandes campos irrigados e corpos d'água), obtendo uma classificação correta de 84%, quando feições texturais e espectrais foram utilizadas. Experimentos também foram feitas com um conjunto de fotografias obtidas em microscópios que incluem cinco classes distintas. Neste caso, uma classificação correta de 89% foi obtida.

A ampla classe de imagens usadas e classificadas com boa exatidão é indicativo do poder e da generalidade deste

método. As matrizes de co-ocorrência dos níveis de cinza serão discutidas com maiores detalhes no capítulo III.

- MATRIZES DE CO-OCORRÊNCIA GENERALIZADAS:

Essa aproximação para análise da textura foi proposta por Davis *et alii* [3]. Está baseada nas ocorrências associadas ao máximo local de alguma propriedade da imagem. Seguindo essa aproximação, a imagem real é substituída por outra imagem que indica a posição da propriedade local (por exemplo, borda) na imagem original.

A matriz de co-ocorrência generalizada é obtida a partir desta nova imagem, fazendo uso de uma descrição local e de uma característica espacial definida. A descrição local descreve algum máximo local e a característica espacial impõe as condições que devem ser satisfeitas por dois máximos locais para ser contado como um elemento da matriz de co-ocorrência generalizada.

Como um exemplo, o máximo local pode ser bordas. Neste caso, a descrição pode ser a orientação da borda.

A dimensão da matriz de co-ocorrência generalizada é dado pelo número de descrições adotadas. No exemplo acima, a descrição pode ser a orientação de uma borda nas direções 0° , 45° , 90° e 135° . Neste caso, a matriz de co-ocorrência generalizada será uma matriz quadrada de dimensão igual a quatro. A característica espacial definida neste mesmo exemplo pode ser a distância entre duas bordas. Se a distância entre duas bordas,

uma com orientação de 0° e a outra orientada de 45° , é menor que um limiar predeterminado, então uma unidade adicional é acrescentada ao elemento (1,2) da matriz de co-ocorrência generalizada.

Similarmente à matriz de co-ocorrência dos níveis de cinza, estatísticas podem ser calculadas a partir da matriz de co-ocorrência generalizada.

Experimentos em cinco classes de texturas distintas são descritos em Davis *et alli* [3], usando bordas como máximo local. Os resultados apresentados são promissores.

- TRANSFORMADAS DE TEXTURA:

Os métodos descritos anteriormente tentam caracterizar a textura de uma imagem via a distribuição espacial dos níveis de cinza ao longo de um segmento da imagem ou por quantificação da quantidade de bordas ou alguma outra propriedade também em um segmento da imagem. Todos designam feições texturais por segmentos da imagem, não para pixels individuais, isto é, os segmentos da imagem são considerados entidades uniformes a partir do ponto de vista textural. Todo pixel em um segmento é assumido como pertencente a uma mesma classe na imagem. Esses métodos têm provado sua utilidade na classificação de imagens em Sensoriamento Remoto, mas não trazem vantagem de resolução fornecida pelos dados da imagem.[13]

Hsu [13] e Irons *et alli* [14] propuseram outra

aproximação para quantificação da textura de uma imagem através da construção de um novo canal de dados a partir dos canais espectrais observados.

Considerando uma imagem multiespectral e representando por $f(k,l,\lambda)$ o nível de cinza de um pixel localizado na posição (k,l) da banda espectral λ , uma transformada de textura constrói um canal de dados adicional λ_1 tal que o valor $f(k,l,\lambda_1)$ designado para cada pixel caracteriza de alguma forma a textura da imagem ao redor do pixel (k,l) . Este novo canal é referido como uma transformada de textura ou simplesmente como canal de textura.

O caminho mais simples para construir um canal de textura é pela implementação do conceito de janela móvel. De acordo com essa aproximação, cada pixel individual na imagem serve como um ponto central ao redor do qual um grupo de pixels vizinhos é consistentemente definido e referido como a janela. Usualmente a janela consiste de arranjos quadrados de 3x3 ou 5x5 pixels. Alguma medida baseada nos níveis de cinza dos pixels dentro da janela é feita e designada para o pixel central. Exemplos são a média e a variância dos níveis de cinza. Movendo a janela ao longo da imagem e considerando cada pixel sucessivamente como o centro da janela, constrói-se um novo canal de dados.

Distintas propriedades estatísticas podem ser implementadas. Exemplos de propriedades estatísticas que podem ser usadas para construção das transformadas de textura são:

$$\text{Média: } \underline{m} = \frac{\sum_{k=1}^N \sum_{l=1}^N \underline{X}_{kl}}{N^2}$$

$$\text{Variância: } \text{Var} = \frac{\sum_{k=1}^N \sum_{l=1}^N (\underline{X}_{kl} - \underline{m})^2}{N^2 - 1}$$

$$\text{Asimetria: } \text{Skew} = \frac{\sum_{k=1}^N \sum_{l=1}^N (\underline{X}_{kl} - \underline{m})^3}{(N^2 - 1)(\text{Var})^{3/2}}$$

$$\text{Curtose: } \text{Kurt} = \frac{\sum_{k=1}^N \sum_{l=1}^N (\underline{X}_{kl} - \underline{m})^4}{(N^2 - 1)(\text{Var})^2}$$

$$\text{Amplitude: } \text{Range} = \max(\underline{X}_{kl}) - \min(\underline{X}_{kl})$$

onde N^2 é o número de pixels na janela e \underline{X}_{kl} é o vetor dos níveis de cinza para o pixel (k,l) , com $1 \leq k, l \leq N$.

Qualquer combinação de canais espectrais e canais de textura pode ser usado na classificação de imagens. Uma vantagem dessa aproximação é que os canais de textura têm o mesmo formato dos canais espectrais, o que facilita sua implementação na maioria dos algoritmos já existentes.

Hsu [13] relata experimentos usando canais de textura na classificação de fotografias aéreas de alta e baixa altitudes para quatro locais teste no Estado de Nova York. As fotografias foram previamente digitalizadas em um canal de dados de oito bits. Treze canais de textura foram construídos e usados para classificação de fotografias aéreas em sete classes, usando um algoritmo da distância de Mahalanobis. Hsu [13] relata uma exatidão de classificação de 85% a 90%. Irons *et alii* [14] usaram uma aproximação similar para classificar imagens LANDSAT MSS. Sete canais de textura foram construídos a partir de quatro canais espectrais. Ambas técnicas de classificação supervisionada e não supervisionada foram usadas pelos dois pesquisadores. No entanto, nesses experimentos foi registrada uma baixa exatidão na classificação. O único resultado satisfatório foi obtido a partir da transformada da variância. Este canal respondeu bem como detector de bordas, um resultado que era esperado. Irons *et alii* [14] observa que diferenças na resolução do terreno (57m x 82m para LANDSAT MSS versus 2,67m x 2,67m e 17,3m x 17,3m em Hsu [13]) podem ser responsáveis pela diferença na exatidão da classificação.

CAPÍTULO III

MATERIAIS E MÉTODOS

No capítulo II, mostrou-se que não existe uma única aproximação para quantificar a textura de uma imagem. Várias aproximações foram descritas, mostrando resultados de estudos de pesquisadores interessados na quantificação da textura para posterior aplicação no processo de classificação de imagens. Em geral, essas aproximações foram baseadas na intuição ou percepção individual dos pesquisadores.

Dentre as várias aproximações descritas, adotaremos a aproximação baseada no método das matrizes de co-ocorrência dos níveis de cinza, sugerida por Haralick *et alii* [9].

III.1 - MATRIZES DE CO-OCORRÊNCIA ESPACIAL

Suponhamos uma imagem com N_x pixels na direção horizontal, N_y pixels na direção vertical e que o nível de cinza associado a cada pixel seja quantizado por N_g+1 níveis. Seja $D_x = \{1, 2, \dots, N_x\}$ o domínio espacial horizontal, $D_y = \{1, 2, \dots, N_y\}$ o domínio espacial vertical e $G = \{0, 1, 2, \dots, N_g\}$ o conjunto dos N_g+1 níveis de cinza quantizados. Então $L_y \times L_x$ é o conjunto de pixels da imagem ordenada por suas designações linha-coluna.[5]

A imagem pode ser representada por uma função que designa um valor de nível de cinza para cada pixel ou par de coordenadas em $D_y \times D_x$.

No método proposto por Haralick *et alii* [9], as componentes essenciais para conceituação de textura são descritas por quatro matrizes, através das quais as feições de textura são estimadas. Essas matrizes são chamadas matrizes de dependência espacial dos níveis de cinza dos pixels vizinhos, ou simplesmente matriz de co-ocorrência espacial, segundo uma determinada orientação angular e uma distância d .

Para descrição dessas matrizes deve-se enfatizar a noção de pixels vizinhos mais próximos entre si. Considerando um pixel - excluindo os pixels da borda da imagem - que possui oito pixels vizinhos mais próximos, como na figura III.1 abaixo:




Figura III.1: pixels vizinhos do pixel central C.

Observa-se que os pixels 1 e 5 são vizinhos mais próximos de C, na orientação horizontal; os pixels 3 e 7 são vizinhos mais próximos de C, na orientação vertical; os pixels 4 e 8 são vizinhos mais próximos de C, na orientação da diagonal direita (45°); e os pixels 2 e 6 são vizinhos mais próximos de C, na orientação da diagonal esquerda (135°). Esta informação é exclusivamente espacial e não tem ligação com os valores dos níveis de cinza.

Neste método, é assumido que a informação de textura está contida na relação espacial que os níveis de cinza têm um com o outro. Mais especificamente, pode-se assumir que a informação de textura é adequadamente especificada pela matriz de frequências relativas P_{ij} com que dois pixels vizinhos, separados por uma distância d , ocorrem na imagem, um com nível de cinza i e outro com nível de cinza j . Tais matrizes de dependência espacial são função da distância d e da relação angular entre os pixels utilizados em sua construção.

A forma geral de uma matriz de co-ocorrência espacial $P=(P_{ij})$, de ordem $(N_g+1) \times (N_g+1)$, onde N_g+1 é o número de níveis de cinza quantizados na imagem, é dada por:

		níveis de cinza			
		0	1	...	N_g
0	#(0,0)	#(0,1)	...	#(0, N_g)	
1	#(1,0)	#(1,1)	...	#(1, N_g)	
⋮	⋮	⋮	⋮	⋮	
N_g	#(N_g ,0)	#(N_g ,1)	...	#(N_g , N_g)	

Figura III.2: Forma geral da matriz de co-ocorrência.

Mais precisamente, pode-se dizer que cada entrada $\#(i,j)$ da matriz de co-ocorrência é o número total de pares de pixels vizinhos que ocorrem em uma imagem, um com nível de cinza i e o outro com nível de cinza j , segundo uma distância d e uma dada orientação angular.

Para cada região da imagem pode-se construir quatro

matrizes de co-ocorrência espacial:

P_H - matriz de co-ocorrência Horizontal (0°)

P_V - matriz de co-ocorrência vertical (90°)

P_{DD} - matriz de co-ocorrência diagonal direita (45°)

P_{DE} - matriz de co-ocorrência diagonal esquerda (135°)

Assim, supondo que $f(k,l)=i$ e $f(m,n)=j$, onde (k,l) e (m,n) definem as posições de um par de pixels em termos de linhas e colunas e i, j são os níveis de cinza quantizados, as frequências não normalizadas para os ângulos $0^\circ, 45^\circ, 90^\circ$ e 135° são definidas por:

$$P_H(i,j) = P(i,j,d,0^\circ) = \#\{ ((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) / \\ k-m=0, |l-n|=d, f(k,l)=i \text{ e } f(m,n)=j \}$$

$$P_{DD}(i,j) = P(i,j,d,45^\circ) = \#\{ ((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) / \\ k-m=d, l-n=-d, f(k,l)=i \text{ e } f(m,n)=j \}$$

$$P_V(i,j) = P(i,j,d,90^\circ) = \#\{ ((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) / \\ |k-m|=d, l-n=0, f(k,l)=i \text{ e } f(m,n)=j \}$$

$$P_{DE}(i,j) = P(i,j,d,135^\circ) = \#\{ ((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) / \\ k-m=d, l-n=d, f(k,l)=i \text{ e } f(m,n)=j \}$$

onde # denota o número de elementos no conjunto.

Considerando, como exemplo, uma região de uma imagem

digital definida por:

0	0	1
0	1	1
2	2	3

Figura III.3: Região associada com os níveis de cinza.

As quatro matrizes de co-ocorrência para esta região são dadas por:

$$P_H = \begin{bmatrix} 2 & 2 & 0 & 0 \\ 2 & 2 & 0 & 0 \\ 0 & 0 & 2 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \quad P_V = \begin{bmatrix} 2 & 1 & 1 & 0 \\ 1 & 2 & 1 & 1 \\ 1 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$$

$$P_{DD} = \begin{bmatrix} 2 & 0 & 0 & 0 \\ 0 & 2 & 2 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}, \quad P_{DE} = \begin{bmatrix} 0 & 2 & 1 & 0 \\ 2 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$$

Figura III.4: Matrizes de co-ocorrência associadas a região descrita acima.

Observando a matriz P_V , que é a matriz das frequências segundo a orientação vertical (das colunas), o elemento da terceira linha e segunda coluna significa a existência de um único par de pixels na imagem, o primeiro com nível de cinza 2 e o segundo com nível de cinza 1, segundo a orientação vertical.

Observa-se que tais matrizes de co-ocorrência são simétricas, isto é, $P_{ij} = P_{ji}$, pois o número de pares de pixels

existentes em uma imagem, o primeiro com nível de cinza i e o segundo com nível de cinza j é igual ao número de pares de pixels, o primeiro com nível de cinza j e o segundo com nível i .

Além disso, a dimensão dessas matrizes depende unicamente do número de níveis de cinza existentes na imagem, não do tamanho da imagem. No exemplo anterior, a imagem possui quatro níveis de cinza (0, 1, 2 e 3) resultando em matrizes de co-ocorrência de dimensão quatro, embora a região seja de dimensão 3×3 .

Deve ficar claro que os elementos próximos da diagonal principal das matrizes de co-ocorrência estão associados com pares de pixels, cada par contendo dois pixels com valor igual ou quase igual para o nível de cinza. Elementos da matriz localizados longe da diagonal principal correspondem a pares de pixels, cujos integrantes diferem bastante quanto ao valor do nível de cinza.

As matrizes de co-ocorrência podem ser calculadas para vários valores de d , podendo fornecer informações sobre a distribuição espacial dos níveis de cinza dos pixels da imagem, segundo Haertel [8]. Como um exemplo, se uma imagem é formada de regiões com níveis de cinza aproximadamente constante, então um valor pequeno para d será suficiente para detectar essa característica (um grande número de pixels adjacentes com níveis de cinza similares). A correspondente matriz de co-ocorrência terá valores altos para as entradas próximas da diagonal principal. Um valor grande para d pode perder essa feição da imagem e a matriz de co-ocorrência apresentará uma distribuição

mais uniforme para as entradas.

No entanto, na prática as matrizes obtidas usando valores grandes para d não são úteis, pois pares de pixels separados por grandes distâncias tornam-se não-correlacionados e qualquer elemento (i,j) da matriz de co-ocorrência (após normalização) aproxima-se da probabilidade que um par de pixels escolhidos aleatoriamente na imagem tenham níveis de cinza i e j . [8]

Assim, o valor de d deve ser limitado por distâncias para as quais os níveis de cinza dos pixels sejam correlacionados, isto é, distâncias não maiores que o tamanho das regiões da imagem. De fato, as matrizes de co-ocorrência são mais comumente construídas usando a distância d como sendo a unidade, implicando na utilização de pares de pixels imediatamente adjacentes. [8]

Para obtenção do fator de normalização das matrizes de co-ocorrência, somam-se as frequências ou entradas de cada uma delas. Uma outra forma de obtenção, é considerarmos a figura III.5 que descreve uma imagem digital, segundo a posição de seus pixels.

$(1,1)$	$(1,2)$...	$(1,N_x)$
$(2,1)$	$(2,2)$...	$(2,N_x)$
\vdots	\vdots		\vdots
$(N_y,1)$	$(N_y,2)$...	(N_y,N_x)

Figura III.5: Forma geral de uma imagem de dimensão $N_y \times N_x$.

Assim, no sentido horizontal, o número de pares de pixels em cada linha é $2(N_x - 1)$ e o número de linhas é N_y . Portanto, o fator de normalização é $R_H = 2N_y(N_x - 1)$. Na orientação vertical, o número de pares de pixels em cada coluna é $2(N_y - 1)$ e o número de colunas é N_x . Portanto, $R_V = 2N_x(N_y - 1)$. Tanto na orientação da diagonal direita, quanto da diagonal esquerda, o fator de normalização é dado por $2(N_x - 1)(N_y - 1)$. Assim, cada frequência normalizada é obtida dividindo-se a frequência relativa pelo fator de normalização.

III.2 - FEIÇÕES DE TEXTURA

Na busca de feições significativas para descrição digital da informação de uma imagem, é natural a consideração de feições que são utilizadas na interpretação visual tais como feições espectrais e feições de textura.

A textura é uma propriedade inata de uma superfície, contendo informação importante sobre a organização estrutural da mesma e sua relação com o meio no qual está contida. [6,7]

Devido a sua importância e ubiquidade nos dados da imagem, não existe uma definição precisa nem uma aproximação matemática formal de textura. No entanto, a textura é definida como uma propriedade local da imagem, isto é, uma medida das relações entre os pixels em uma região. Assim, qualquer feição de textura significativa deve incluir informações de contraste e frequência espacial dos níveis de cinza desta região.

Haertel [8] observa que na construção das feições de

textura deve-se ter cuidado com a direcionalidade da textura. Qualquer algoritmo que pretende a implementação da textura no processo de classificação da imagem deve ser capaz de reconhecer duas imagens idênticas como iguais, uma rotacionada em relação a outra, isto é, deve ser invariante frente a uma rotação. Este requisito fica aproximadamente satisfeito quando adicionam-se todas as matrizes de co-ocorrência ao longo das quatro orientações (0°, 45°, 90° e 135°) e é feita a normalização deste resultado. Esta operação resulta em uma matriz que é aproximadamente invariante sob rotação da imagem.

Além disso, cada feição de textura deve relatar uma característica textural específica de uma imagem, como por exemplo: homogeneidade, contraste, presença de estrutura organizada dentro da imagem, complexidade e natureza das transições dos níveis de cinza que ocorrem em uma imagem, etc...

Dentre as várias feições sugeridas por Haralick *et alii* [9], consideraremos três feições que serão descritas a seguir:

1) FEIÇÃO DO SEGUNDO MOMENTO ANGULAR (ASM):

Esta feição é definida por

$$f_1[r,s] = \sum_{i=0}^{Ng} \sum_{j=0}^{Ng} \left[\frac{P(i,j)}{R} \right]^2$$

onde r e s são as posições do pixel central da região compreendida pela janela móvel, o fator R é a constante de normalização das frequências da matriz de co-ocorrência, obtida

somando-se os fatores R_H , R_V , R_{DD} e R_{DE} das respectivas matrizes de co-ocorrência e $P(i,j)$ é a frequência relativa obtida somando-se as frequências $P_H(i,j)$, $P_V(i,j)$, $P_{DD}(i,j)$ e $P_{DE}(i,j)$.

Esta feição é uma medida da homogeneidade da imagem.

Em uma imagem homogênea, como mostra a figura III.7(a), existem muito poucas transições dos níveis de cinza. Portanto, a matriz de co-ocorrência associada terá poucas entradas com frequências altas e conseqüentemente a feição f_1 (que é a soma dos quadrados das entradas) terá um valor maior que o valor da feição associada à imagem da figura III.7(b), que caracteriza uma imagem heterogênea. Assim, quanto mais homogênea uma imagem, maior o valor da feição f_1 associado.

2) FEIÇÃO DE ENTROPIA:

Esta feição é definida por

$$f_2[r,s] = - \sum_{i=0}^{Ng} \sum_{j=0}^{Ng} \frac{P(i,j)}{R} \log \left[\frac{P(i,j)}{R} \right]$$

e é uma medida da aleatoriedade ou desorganização presente em uma imagem.

Deve-se observar que o valor do somatório é negativo ou no máximo zero. De fato, as frequências relativas $P(i,j)$ serão no máximo iguais ao fator de normalização R , o que dificilmente ocorre em uma imagem. Assim, o quociente $P(i,j)/R$ assume valores no intervalo $[0,1]$ e a função \log assume valores negativos, neste intervalo. Portanto, o valor do somatório será negativo.

Ainda, um cuidado que deve ser observado computacionalmente é o caso da frequência relativa $P(i,j)=0$, pois $\log P(i,j)$ não existe. Pode-se eliminar este fator, pois $\lim_{P_{ij} \rightarrow 0} P_{ij} \log P_{ij} = 0$ como mostra o gráfico na figura III.6.

Uma outra abordagem que pode ser considerada para essa feição é a variabilidade dos níveis de cinza. Para tal, observando a figura III.7, em (a) temos muito pouca variabilidade dos níveis de cinza, conseqüentemente pouca desorganização da imagem. Em (b), o comportamento se inverte, pois existe uma grande variabilidade dos níveis de cinza, acarretando uma maior desorganização na imagem. Portanto, um maior valor para f_2 nesta imagem.




Figura III.6: Gráfico da função $f(x) = x \log(x)$.

3) FEIÇÃO DO MOMENTO DA DIFERENÇA:

Esta feição é definida por

$$f_3[r,s] = \sum_{n=1}^{N_g} n^2 \left[\sum_{i=0}^{N_g} \sum_{j=0}^{N_g} \left[\frac{P(i,j)}{R} \right] \right]_{|i-j|=n}$$

e é uma medida do contraste ou da quantidade de variação local presente em uma imagem.

Observa-se que as frequências da diagonal principal, onde os níveis de cinza do par são idênticos, não são consideradas nesta feição. A variável n funciona como peso no somatório acima, no sentido que quanto mais distintos entre si os níveis de cinza do par, maior é o peso para essa frequência. Isto caracteriza o conceito de contraste ou maior variação local, onde os níveis de cinza são mais distintos. Assim, o valor de f_3 será maior em regiões de maiores transições dos níveis de cinza. Este fato pode ser observado na figura III.7, onde o contraste é maior na figura III.7(b).




Figura III.7: (a) imagem homogênea; (b) imagem heterogênea

Essas feições de textura são calculadas e atribuídas ao pixel central da janela. Movendo a janela sobre a imagem, obtem-se os canais de textura e teremos tantos canais, quantas as feições de textura consideradas.

III.3 - MÉTODO DE CLASSIFICAÇÃO

A classificação da imagem foi realizada no Sistema SITIM [18] (Sistema de Tratamento de Imagens), utilizando-se o Método da Máxima Verossimilhança Gaussiana. Esse método, um dos mais frequentemente utilizados em classificação de imagens digitais em Sensoriamento Remoto, insere-se no grupo dos processos estatísticos de classificação supervisionada.[17]

O problema de classificação consiste em, dadas várias classes e um alvo suposto pertencer a uma delas, determinar a qual dessas classes o alvo efetivamente pertence. Neste processo, cada ponto da imagem é caracterizado por um vetor de atributos, formado pelos canais espectrais e pelos canais de textura, obtidos acima. Teremos tantas componentes no vetor, quantos os canais espectrais e de textura considerados.

Na formulação estatística do problema, assume-se que o comportamento espectral do pixel pode ser descrito por uma variável aleatória. Para cada classe $\omega(j)$, o comportamento dessa variável é descrito por uma função densidade de probabilidade representada por $p[\underline{x}/\omega(j)]$, onde \underline{x} é o vetor de atributos e $\omega(j)$ representa a j -ésima classe.[4,17]

Dado, então um ponto \underline{x} , deve-se atribuí-lo a classe cuja probabilidade condicional $p[\omega(j)/\underline{x}]$ seja máxima. Utilizando o Teorema de Bayes, essa função de probabilidade pode ser expressa, mais adequadamente por:

$$p[\omega(j)/\underline{x}] = \frac{p[\underline{x}/\omega(j)]p[\omega(j)]}{p[\underline{x}]} \quad j=1,2,\dots,M$$

onde:

- $p[\underline{x}/\omega(j)]$ é a função Verossimilhança da classe $\omega(j)$

$$p[\underline{x}] = \sum_{j=1}^M p[\omega(j)]p[\underline{x}/\omega(j)]$$

- $p[\omega(j)/\underline{x}]$ é a probabilidade da classe $\omega(j)$ condicionada ao vetor \underline{x} , também chamada probabilidade "a posteriori" da classe $\omega(j)$, sendo dado \underline{x} .

- $p[\omega(j)]$ é a probabilidade de ocorrência da classe $\omega(j)$, também chamada probabilidade "a priori" ou probabilidade incondicional da classe $\omega(j)$.

O cálculo de $p[\omega(j)/\underline{x}]$ pode ser evitado e calculado somente $p[\underline{x}/\omega(j)]$ se verificarmos que $p[\underline{x}]$ é comum a todas as classes e fizermos a suposição de que as classes são igualmente prováveis. É comum, embora não essencial, supor que as classes são igualmente prováveis; isto é, que as probabilidades "a priori" são idênticas para todas as classes. A probabilidade $p[\underline{x}/\omega(j)]$ é denominada verossimilhança e a regra de decisão é

então denominada máxima verossimilhança. Para usar esta regra, a função $p[\underline{x}/\omega(j)]$ deve ser inferida para cada classe. Nesse sistema, as classes são supostas distribuírem-se normalmente nos vários atributos.

Então, a função $p[\underline{x}/\omega(j)]$ assume a forma:

$$p[\underline{x}/\omega(j)] = \frac{1}{(2\pi)^{n/2} |\Sigma_j|^{1/2}} \exp\left[-\frac{1}{2}(\underline{x}-\underline{\mu}_j)^t \Sigma_j^{-1} (\underline{x}-\underline{\mu}_j)\right]$$

onde:

n = número de atributos, isto é, a dimensionalidade do vetor \underline{x} .

$\underline{\mu}_j$ = vetor média da classe $\omega(j)$

Σ_j = matriz de covariância da classe $\omega(j)$

A distribuição normal fica especificada quando se conhece seus parâmetros média ($\underline{\mu}$) e matriz de covariância (Σ). Estes parâmetros podem ser estimados utilizando-se amostras de regiões em que se conhece a verdade terrestre. Supondo que se tenha uma amostra $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_k$ pode-se estimar o vetor média e a matriz de covariância para cada classe $w(j)$ através das fórmulas:

$$\underline{m}_j = \frac{1}{k} \sum_{i=1}^k \underline{x}_i$$

$$C_{-j} = \frac{1}{k} \sum_{i=1}^k (\underline{x}_i - \underline{m}_j)(\underline{x}_i - \underline{m}_j)^t$$


onde, K é o número de pontos da amostra, \underline{m}_j é a estimativa do vetor média $\underline{\mu}_j$ e \underline{C}_j a estimativa da matriz de covariância $\underline{\Sigma}_j$ da classe $\omega(j)$. A estimativa destes parâmetros consiste no que chamamos treinamento do classificador.

III.4 - DESCRIÇÃO DA ÁREA DE ESTUDO

Atualmente, existem vários sistemas de aquisição de dados em Sensoriamento Remoto, para reconhecimento e tratamento de padrões. Um desses sistemas é o Thematic Mapper Scanner (TM) que é o utilizado neste trabalho. Assim, o conjunto de dados foi obtido pelo satélite LANDSAT TM 5 em três faixas do espectro eletromagnético: banda 3 (0.63 - 0.69 μm), faixa do visível (figura III.8(a)); banda 4 (0.76 - 0.90 μm), infravermelho próximo e banda 5 (1.55 - 1.75 μm) no infravermelho médio (figura III.8(b)). As imagens são datadas de 29.07.88, quadrante 224.73-B e compreendem 512 x 512 pixels.

A cena central captada pela imagem corresponde ao Parque Nacional das Emas, ao sul do Estado de Goiás. Nesta área, foram selecionadas três classes (ou categorias) denominadas campo limpo, cerrado e mata galeria, devido a serem dominantes conforme a figura III.9.

Figura III.8: Bandas espectrais



(a) Banda espectral 3.



(b) Banda espectral 5.




Figura III.9: Área de estudo, Parque Nacional das Emas, Goiás.

III.5 - DESCRIÇÃO DO PROGRAMA COMPUTACIONAL

Para obtenção das matrizes de co-ocorrência e feições de textura foi desenvolvido um programa computacional. Este encontra-se no anexo I.

O programa consiste de subrotinas que estão agrupadas num programa principal. A principal subrotina é chamada "

Procedure Tex ", onde são obtidas as matrizes de co-ocorrência e feições de textura.

Na figura III.10 encontra-se uma descrição esquemática deste programa.

Após a obtenção dos quatro processamentos, descritos a seguir no capítulo IV, com a implementação deste programa, utilizou-se o Sistema de Tratamento de Imagens (SITIM) para o processo de classificação, disponível no Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia, da Universidade Federal do Rio Grande do Sul.

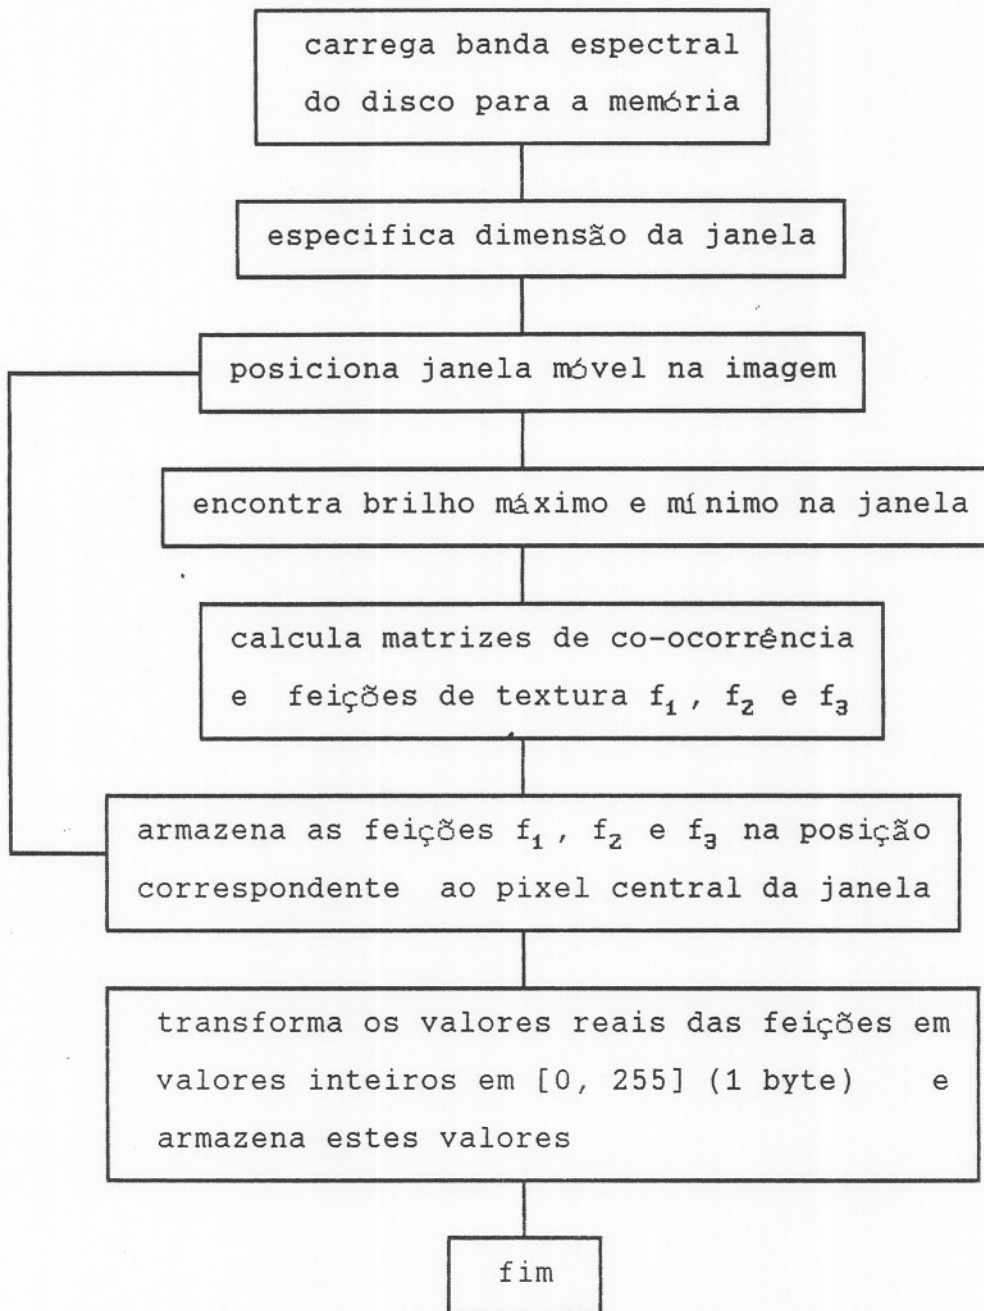


Figura III.10: Descrição do programa desenvolvido.

CAPÍTULO IV

RESULTADOS

Neste capítulo serão descritos os processamentos feitos com a imagem, bem como uma análise qualitativa e quantitativa dos dados obtidos.

IV.1 - PROCESSAMENTOS DA IMAGEM

As feições de textura são obtidas através da matriz de co-ocorrência média, originada da soma das quatro matrizes de co-ocorrência nas orientações 0° , 45° , 90° e 135° . A distância adotada "d" foi de uma unidade, envolvendo portanto pares de pixels imediatamente adjacentes. Utilizando-se o algoritmo computacional, descrito no anexo I, foram desenvolvidos os seguintes processamentos da imagem:

1^o) com a banda espectral 3 e janela móvel de dimensão 3x3, obtêm-se três canais de textura mostrados na figura IV.1.

2^o) com a banda espectral 3 e janela móvel de dimensão 5x5, obtêm-se três canais de textura mostrados na figura IV.2.

3^o) com a banda espectral 5 e janela móvel de dimensão 3x3, obtêm-se três canais de textura mostrados na figura IV.3.

4^o) com a banda espectral 5 e janela móvel de dimensão 5x5, obtêm-se três canais de textura mostrados na figura IV.4.

Quando da obtenção das feições de textura (f_1, f_2 e f_3) deve-se observar que os valores obtidos são números reais. Para posterior introdução no processo de classificação e visualização das mesmas num formato similar ao das bandas espectrais é necessário a conversão desses valores reais para valores inteiros de zero a 255 (um byte), caracterizando dessa forma os canais de textura. Para tal utilizou-se uma transformação linear definida pela função:

$$f_B = \text{ROUND} \left[\frac{255}{f_{\max} - f_{\min}} (f_R - f_{\min}) \right]$$

onde,


f_R é o valor da feição em número real;

f_B é o valor da feição em byte;


f_{\max} , f_{\min} são os valores máximo e mínimo da feição em número real, respectivamente.

As fotografias nas figuras IV.1(a), IV.1(b) e IV.1(c) representam os canais de textura ou bandas texturais, descritas pelas feições de homogeneidade (f_1), feição de entropia (f_2) e feição de contraste (f_3), respectivamente. Essa mesma ordem é válida para as figuras IV.2, IV.3 e IV.4.


Figura IV.1: Feições de textura obtidas no 1^o processamento.



(a) Feição de homogeneidade




(b) Feição de entropia




(c) Feição de contraste


Figura IV.2: Feições de textura obtidas no 2^o processamento.



(a) Feição de homogeneidade




(b) Feição de entropia




(c) Feição de contraste


Figura IV.3: Feições de textura obtidas no 3^o processamento.



(a) Feição de homogeneidade



(b) Feição de entropia




(c) Feição de contraste


Figura IV.4: Feições de textura obtidas no 4^o processamento.



(a) Feição de homogeneidade



(b) Feição de entropia



(c) Feição de contraste

IV.2 - ANÁLISE QUALITATIVA

Em relação às bandas espectrais 3 e 5 (figura III.8) pode-se observar uma maior diferenciabilidade entre as classes na banda 5 (figura III.8(b)), devido as peculiaridades de resposta espectral dos alvos presentes na cena.

Uma primeira análise que pode ser feita em relação aos resultados dos processamentos da imagem é a interpretação visual das feições de textura em comparação com as bandas espectrais 3 e 5 (figura III.8). Os resultados representam bem as descrições feitas para as feições de textura, no capítulo III. De fato, comparando a banda espectral 3 (figura III.8(a)) com as figuras

IV.1(a) e IV.2(a) observamos que, de fato, as regiões onde a imagem, na banda 3, é mais homogênea, a resposta obtida é mais brilhante, caracterizando dessa forma maior homogeneidade nessa região. A mesma análise pode ser feita quando comparamos a banda espectral 5 (figura III.8(b)) com as figuras IV.3(a) e IV.4(a), que representam as feições de homogeneidade obtidas com a banda 5 e janela de dimensão 3x3 e 5x5, respectivamente. Observa-se que embora ocorrendo distinção entre as classes campo limpo e cerrado na banda espectral 5 (figura III.8(b)), a resposta da feição de homogeneidade para as duas classes é semelhante.

Comparando a banda espectral 3 (figura III.8(a)) com as figuras IV.1(b) e IV.2(b), que representam a segunda feição (f_2) obtida com a janela de dimensão 3x3 e 5x5, respectivamente, observamos que regiões onde há uma maior desorganização (maior entropia), a resposta espectral para essa feição é mais brilhante nesta região. Resultados semelhantes são observados quando comparamos a banda espectral 5 (figura III.8(b)) com as figuras IV.3(b) e IV.4(b), que representam a segunda feição obtida com a janela móvel de dimensão 3x3 e 5x5, respectivamente. As feições de entropia salientam também as bordas entre mudanças de classes. Este fato pode ser observado nas bordas entre as classes campo limpo e cerrado ou entre culturas distintas, principalmente nas figuras IV.3(b) e IV.4(b).

Além disso, observa-se que a resposta das feições de homogeneidade e entropia são praticamente opostas, ou seja, enquanto uma feição é mais brilhante, a outra é mais escura, numa mesma região.

Finalmente, comparando a banda espectral 3 (figura III.8(a)) com as figuras IV.1(c) e IV.2(c) observa-se novamente a interpretação feita no capítulo III em relação à terceira feição, isto é, a caracterização do contraste.

A mesma análise pode ser feita comparando-se a banda espectral 5 (figura III.8(b)) e as figuras IV.3(c) e IV.4(c), que representam as feições de contraste obtidas pela banda espectral 5 e a janela móvel de dimensão 3x3 e 5x5, respectivamente. Importante observar que essas feições salientam muito bem as bordas das redes de drenagem, principalmente quando é utilizada a banda espectral 5. Ainda, outro fato a observar é a não detecção da mudança entre as classes campo limpo e cerrado, presente na banda espectral 5 (figura III.8(b)).

Dois questionamentos podem ser feitos. Primeiro, qual das duas bandas espectrais (3 ou 5) mostrou-se mais eficiente na geração dos canais de textura? A banda 5, devido a maior capacidade de diferenciação entre classes, mostrou-se mais eficiente nesse experimento. Pode-se observar este fato comparando visualmente uma mesma feição nos quatro processamentos. Por exemplo, comparando as quatro feições de contraste nas figuras IV.1(c)-IV.4(c), observa-se uma melhor resposta para a feição obtida com a banda espectral 5 e janela móvel de dimensão 3x3 e 5x5.

Um segundo tópico refere-se a qual a melhor dimensão da janela móvel? Nesse particular deve-se enfatizar que não existe uma resposta geral, pois ocorre aqui uma forte dependência das características da cena. O problema apresentado com a dimensão

5x5 é a perda da nitidez nas feições de textura, como pode ser observado nas figuras IV.2 e IV.4. O fato ocorre devido a região compreendida pela janela ser maior, podendo acarretar uma maior variabilidade nos níveis de cinza da janela e provável mudança no valor da feição para o pixel central da janela.

IV.3 - ANÁLISE QUANTITATIVA:

Os resultados aqui descritos referem-se aos obtidos nos processos de classificação, utilizando-se o método da Máxima Verossimilhança Gaussiana, descrito no capítulo III.

Um grupo de 812 pixels distribuídos nas três classes foi dividido em dois conjuntos:

- dados para treinamento;
- dados para teste.

O conjunto para treinamento consta de 430 pixels, onde 160 representam a classe campo limpo, 160 a classe cerrado e 110 a classe mata galeria. Os restantes 382 pixels foram utilizados para teste do classificador, distribuídos em 121 pixels para a classe campo limpo, 121 pixels para cerrado e 140 para a classe mata galeria.

Com a utilização dos dados para treinamento foram obtidas as estimativas dos parâmetros do Método da Máxima Verossimilhança Gaussiana: vetor média e matriz de covariância para cada classe.

Assim, considerando-se os dados para teste foram

executadas as classificações descritas abaixo. Os resultados são apresentados nas matrizes de contingência, onde as entradas da diagonal principal da matriz formada pelas três colunas centrais e linhas superiores indicam a frequência dos pixels corretamente classificados.

Deve-se observar que as classificações II-V foram executadas utilizando-se as três primeiras componentes principais, resultantes de três bandas espectrais e três bandas texturais obtidas nos quatro processamentos descritos anteriormente.

A transformação das componentes principais fornece um número menor de bandas que são combinações das originais. Isto é feito a partir dos autovalores e autovetores da matriz de covariância gerada pelas bandas originais.

Tabela IV.1: Componentes principais para a classificação II.

Banda	3	4	5	B3f1	B3f2	B3f3
Media	34	38	79	22	179	0
Variancia	93	71	473	732	2157	6

PC	Auto-val.(%)	Auto-vetores (*100)					
1	2746 (78)	5	7	14	-45	87	1
2	481 (14)	29	17	92	1	-17	0
3	209 (6)	-2	-1	8	88	45	2
4	48 (1)	93	-23	-25	3	2	1
5	43 (1)	16	95	-24	5	-2	2
6	5 (0)	-1	-2	0	-1	-2	99

Tabela IV.2: Componentes principais para a classificação III.

Banda	3	4	5	D5f1	D5f2	D5f3
Media	34	38	79	17	163	3
Variancia	93	71	473	491	2190	45

PC	Auto-val.(%)	Auto-vetores (*100)					
1	2543 (76)	6	8	17	-33	91	5
2	465 (14)	29	16	90	-9	-24	-2
3	232 (7)	-1	-3	18	93	30	7
4	48 (1)	93	-18	-26	4	0	14
5	41 (1)	7	91	-18	6	-5	34
6	34 (1)	-16	-31	10	-9	-7	92

Tabela IV.3: Componentes principais para a classificação IV.

Banda	3	4	5	B5f1	B5f2	B5f3
Media	34	38	79	11	211	3
Variancia	93	71	473	842	1874	85

PC	Auto-val.(%)	Auto-vetores (*100)					
1	2521 (73)	6	9	19	-49	83	3
2	481 (14)	-28	-14	-83	25	37	6
3	271 (8)	5	2	40	82	38	9
4	79 (2)	5	10	-2	-6	-9	98
5	47 (1)	94	-17	-26	5	3	-3
6	39 (1)	11	96	-19	8	-1	-10

Tabela IV.4: Componentes principais para a classificação V.

Banda	3	4	5	5Df1	5Df2	5Df3
Media	34	38	79	7	205	7
Variancia	93	71	473	612	1904	194

PC	Auto-val.(%)	Auto-vetores (*100)					
1	2266 (68)	6	10	20	-36	89	9
2	512 (15)	-26	-13	-72	47	37	15
3	323 (10)	12	4	56	77	14	19
4	161 (5)	1	5	-3	-19	-17	96
5	47 (1)	95	-10	-28	5	2	0
6	39 (1)	4	97	-17	8	-3	-4

CLASSIFICAÇÃO I

Refere-se à classificação executada com as bandas espectrais 3, 4 e 5 e os resultados obtidos podem ser observados na tabela IV.5.

Tabela IV.5: Matriz de contingência para a classificação I.

	Não classes	campolimpo	cerrado	matagaleria	TOTAL
campolimpo	67	54	0	0	121
cerrado	10	0	111	0	121
matagaleria	35	0	0	105	140
TOTAL	112	54	111	105	382

Observa-se que dos 382 pixels para teste, 270 foram corretamente classificados, totalizando uma exatidão média de 70%.

CLASSIFICAÇÃO II

Refere-se à classificação executada com as três primeiras componentes principais (tabela IV.1) obtidas a partir de seis bandas (três espectrais e três de textura descritas no 1^o processamento). Os resultados da classificação podem ser observados na tabela IV.6.

Tabela IV.6: Matriz de contingência para a classificação II.

	Não classes	campolimpo	cerrado	matagaleria	TOTAL
campolimpo	53	68	0	0	121
cerrado	25	0	96	0	121
matagaleria	11	0	0	129	140
TOTAL	89	68	96	129	382

Observa-se que dos 382 pixels para teste, 293 foram corretamente classificados, totalizando uma exatidão média de 77%.

Classificação III

Refere-se à classificação executada com as três primeiras componentes principais (tabela IV.2) obtidas a partir de seis bandas (três espectrais e três de textura descritas no 2^o processamento). Os resultados da classificação podem ser observados na tabela IV.7.

Tabela IV.7: Matriz de contingência para a classificação III.

	Não classes	campolimpo	cerrado	matagaleria	TOTAL
campolimpo	51	70	0	0	121
cerrado	51	0	70	0	121
matagaleria	8	0	0	132	140
TOTAL	110	70	70	132	382

Observa-se que dos 382 pixels para teste, 272 foram corretamente classificados, totalizando uma exatidão média de 71%.

Classificação IV

Refere-se à classificação executada com as três primeiras componentes principais (tabela IV.3) obtidas a partir de seis bandas (três espectrais e três de textura descritas no 3^o processamento). Os resultados da classificação podem ser observados na tabela IV.8.

Tabela IV.8: Matriz de contingência para a classificação IV.

	Não classes	campolimpo	cerrado	matagaleria	TOTAL
campolimpo	60	61	0	0	121
cerrado	6	0	115	0	121
matagaleria	10	0	0	130	140
TOTAL	76	61	115	130	382

Observa-se que dos 382 pixels para teste, 306 foram corretamente classificados, totalizando uma exatidão média de 80%.

Classificação V

Refere-se à classificação executada com as três primeiras componentes principais (tabela IV.4) obtidas a partir de seis bandas (três espectrais e três de textura descritas no 4^o processamento). Os resultados da classificação podem ser observados na tabela IV.9.

Tabela IV.9: Matriz de contingência para a classificação V.

	Não classes	campolimpo	cerrado	matagaleria	TOTAL
campolimpo	69	52	0	0	121
cerrado	5	0	116	0	121
matagaleria	9	0	0	131	140
TOTAL	83	52	116	131	382

Observa-se que dos 382 pixels para teste, 299 foram corretamente classificados, totalizando uma exatidão média de 78%.

CAPÍTULO V

CONCLUSÕES E RECOMENDAÇÕES

Os resultados obtidos no capítulo anterior mostram a vantagem de usar ambas as características espectrais e texturais de imagens obtidas por satélite para desenvolvimento de procedimentos de classificação.

Com a utilização dos dados para teste, os resultados que apresentaram melhor exatidão em ordem decrescente foram: classificação IV (80%), classificação V (78%), classificação II (77%), classificação III (71%) e classificação I (70%).

Observa-se que o melhor resultado de classificação foi obtido quando utilizamos a banda espectral 5 e janela móvel 3x3 para obtenção das feições de textura. O pior resultado foi obtido quando utilizamos somente as bandas espectrais 3,4 e 5 no processo de classificação, como pode-se observar no capítulo anterior. Assim, todas as classificações com a utilização dos atributos de textura mostraram melhores resultados.

Os 80% de exatidão encontrados como melhor resultado podem ser menor que a exatidão conseguida pela interpretação visual. A diferença de exatidão entre a aplicação automatizada e a interpretação visual, pode ser devida ao fato de que por serem de quantificação difícil, muitos atributos ou informações presentes na imagem e usualmente utilizados em interpretação visual, não o são em classificações via computador. Um exemplo são os atributos de contexto. Por essa razão é conveniente o

desenvolvimento de feições espectrais, texturais e contextuais combinadas para a classificação automatizada.

A introdução de um atributo de natureza espacial (textura), conforme implementado e testado nessa dissertação, mostrou uma contribuição positiva ao processo de classificações via computadores. Comparando os resultados encontrados com trabalhos já existentes na literatura, tal como Haralick *et alii* [9], pode-se observar que os resultados são semelhantes.

Investigações adicionais são necessárias para determinar o tamanho ideal para a janela móvel, se possível, e as distâncias entre pixels vizinhos para calcular as matrizes de co-ocorrência, com o objetivo de otimizar os resultados.

Regiões muito pequenas na imagem podem não ter informação textural suficiente para separar categorias de interesse na imagem, enquanto que regiões muito grandes podem ter alvos pertencentes a várias categorias distintas. Além disso, regiões muito grandes podem exigir maiores espaços de armazenagem de informação.

Há conveniência de progredir nessa direção de pesquisa com a introdução de outros atributos espaciais (forma, dimensão, ...) e de contexto em algoritmos computacionais ou a introdução de outras feições de textura além das utilizadas neste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ARAÚJO, A.A., Texture Analysis: a review, R. Tecnologia e ciência João Pessoa, 1987.
- [2] CHEN, P. C and PAVLIDIS, T., Segmentation by Texture Using a Co-ocurrence Matrix and a Split-and-Merge Algorithm, Computer Graphics and Image Processing, 10, 172-182, 1979.
- [3] DAVIS, L, JOHNS, S. and AGGARWALL, J.K., Texture Analysis Using Generalized Co-ocurrence Matrices, IEEE Transactions on Pattern Analysis and Machine Intelligence, July, 1979.
- [4] FOODY, G.M., CAMPBELL, N.A., TRODD, N.M. and WOOD, T.F., Derivation and Applications of Probabilistic Measures of Class Membership from the Maximum-Likelihood Classification, Photogrammetric Engineering & Remote Sensing, vol.58, No.9, 1335-1341, 1992.
- [5] FRANKLIN, S.E. and PEDDLE, D.R., Image Texture Processing and Data Integration for Surface Pattern Discrimination, Photogrammetric Engineering & Remote Sensing, vol.57, No.4, 413-420, 1991.
- [6] FRANKLIN, S.E. and PEDDLE, D.R., Classification of SPOT HRV Imagery and Texture Features, Int. journal Remote Sensing. vol.11, No.3, 551-556, 1990.

- [7] FRANKLIN, S.E. and PEDDLE, D.R., Spectral Texture for Improved Class Discrimination in Complex Terrain, *int. J. Remote Sensing*, vol.10, No.8, 1437-1443, 1989.
- [8] HAERTEL, V.F., Estimation of Spatial Characteristics in Digital Imagery for Remote Sensing Applications, Thesis, Colorado State University, 1986.
- [9] HARALICK, R.M. SHANMUGAM, K. and DINSTEN, I., Textural Features for Image Classification, *IEEE Transactions on Systems, Man and Cybernetics*, vol.3, No.6, 610-621, 1973.
- [10] HARALICK, R.M., Statistical and Structural Approaches to Texture, *Proceedings of the IEEE*, vol.67, No.5, 786-804, 1979.
- [11] HARALICK, R.M. and SHANMUGAM, K., Combined Spectral and Spatial Processing of ERTS Imagery Data, *Remote Sensing of Environment*, vol3, 3-13, 1974.
- [12] HAWKINS, J.K., Textural Properties or Pattern Recognition Picture Processing and Psycopictories, B.S. Lipkin and A. Rosenfeld editors, Academic Press, New York, 1970.
- [13] HSU, S., Texture-Tone Analysis for Automated Land Use Mapping, *Photogrammetric Engineering & Remote Sensing*, vol.44, No.11, 1393-1404, 1978.

- [14] IRONS, J.R. and PETERSEN, G.W., Texture Transforms of Remote Sensing Data, Remote Sensing of Environment, vol.11, 359-370, 1981.
- [15] KAISER, H., A Quantification of Texture Aerial Photographs, Boston Research Laboratories, Boston University, Boston MA, Technical Note 121, 1955.
- [16] LILLESAND, T.M. and KIEFER, R.W. Remote Sensing and Image Interpretation, 2ª edição, New York, Willey, 1987.
- [17] MANUAL DO SITIM - SITIM 150, Engespaço, 1985.
- [18] RICHARDS, J.A. Remote Sensing Digital Image Analysis, New York, Springer-Verlag, 1986.
- [19] ROSENFELD, A., editor, Image Modeling, New York, Academic Press, 1981.
- [20] ROSENFELD, A. and KAK, A, Digital Picture Precessing, New York, Academic Press, 1981.
- [21] SCHOWENGERDT, R.A., Techniques for Image Processing and Classification in Remote Sensing, New York, Academic Press, 1983.
- [22] SWAIN, P.H. and DAVIS, S.M., Remote Sensing: The Quantitative Approach, New York, McGraw-Hill, 1978.

[23] TOU, J.T. and GONZALEZ, R.C., Pattern Recognition Principles, Addison-Wesley, 1974.

[24] WESZKA, J.S., DYER, C.R. and ROSENFELD, A., A Comparative Study of Texture Measures for Terrain Classification, IEEE Transactions on Systems, Man and Cybernetics, vol6, No.4, 269-285, 1976.

ANEXO I

LISTAGEM DO PROGRAMA COMPUTACIONAL

```

{*-----*}

PROGRAM TEXTURA;

{$R- }
{$M 15520,300000,300000 } { Diretiva para alocação de memória }
{$N+ } { Diretiva p/ usar ou emular coprocessador}
{$E+ }

{*-----+
|Processa uma imagem textura nas direções pré-determinadas |
| . direções => 0 graus 45 graus |
| 90 graus 135 graus |
+-----*}

USES
    CRT,DOS,diálogo; { BIBLIOTECAS Turbo Pascal }

CONST
    compilado = ' 29/01/93 ';
    autor = 'UFSM/UFRGS ';
    CsCompil = '02/12/92';
    lst = ' ';

TYPE
    TyBaite = BYTE; { 8 bits char sem sinal 0..255 }
    TyPalavra= WORD; { 16 bits sem sinal 0..65535 }
    TyReal4 = SINGLE; { SINGLE: 32 bits }
    TyReal8 = DOUBLE; { DOUBLE: 64 bits }
    TyNomeArq= STRING[65];

```

CONST

```
Cs511 = 511;  
Cs512 = Cs511 + 1;           { dimensão da imagem quadrada }
```

TYPE

```
TyIndReg = -1..Cs512;  
TyPtrReg = ^ TyReg;         { apontador p/ linha de varredura }  
TyReg = ARRAY[0..cs511] OF BYTE;  
TyImagMemo=ARRAY[0..cs511] OF TyPtrReg;  
TyRegReal = ARRAY[0..cs511] OF REAL;  
fileregreal = FILE OF TyRegReal;  
TyFreq = ARRAY[0..200] OF BYTE;  
registro = ARRAY[0..cs511] OF BYTE;  
filereg = FILE OF registro;  
FileReal = FILE OF real;
```

VAR

```
pa : TyImagMemo;  
med, imed, jmed : TyFreq;  
arq1, arq2, arq3 : filereg;  
arqq : registro;  
arqx : FileReal;  
f1,f2,f3 : REAL;  
xmax1,xmax2,xmax3,  
ymin1,ymin2,ymin3 : REAL;  
Freq1, Freq2,  
Freq3, Freq4, medfreq : BYTE;  
pi,pf,           {pixel inicial e final}  
ri,rf           : INTEGER; { registro inicial e final}
```

```
medfacc : real;
dm : INTEGER;
arquivo   : STRING[30];
prepara   : boolean;
restaura  : boolean;
cr,lf,crls,ff,esc : char;
```

```
{*-----*}
```

```
PROCEDURE LimpaTela;
```

```
BEGIN
```

```
    CLRSCR
```

```
END;
```

```
{*-----*}
```



```

{*-----*}
{ Consulta diretório e retorna true se arquivo existe }
FUNCTION ChkDir(NomeArq:TyNomeArq):BOOLEAN;
VAR
  HaArq:BOOLEAN;
  Arq :FILE;           { arquivo fictício de teste }
BEGIN
  ASSIGN(Arq,NomeArq);
  {$i- }               { diretiva do compilador }
  RESET(Arq);
  {$i+ }               { diretiva do compilador }
  HaArq:=(IORESULT = 0);      { variável do Turbo Pascal }
  IF HaArq
  THEN BEGIN
    IF FILESIZE(Arq) = 0 THEN HaArq:=FALSE;      { está vazio }
    CLOSE(Arq)
  END;
  ChkDir:=HaArq
END;
{*-----*}

```

```
{*-----*}
PROCEDURE tela1;
BEGIN
  LimpaTela;
  MolduraJanela(1,1,3,80);
  MolduraJanela(5,1,21,80);
  Título(compilado,autor);
  TextoLC(3,36,' GERA TEXTURA DE IMAGENS MULTIESPECTRAIS ',
          Amarelo,Azul);
END;
{*-----*}
```

```

{*-----*}
<Transfere os dados de imagem 512x512 do arquivo para a memória>
PROCEDURE CarregaImagem(VAR pa :TyImagMemo;
                        VAR NomeArq :TyNomeArq; VAR TudoBem :BOOLEAN);
VAR
    Arq      :FILE OF TyReg;
    Reg      :TyReg;
    u,j,v    :TyIndReg;

BEGIN
    IF ABS(MEMAVAIL * 16.0 ) > (1.0 * Cs512 * Cs512) THEN
        BEGIN
            ASSIGN(Arq,NomeArq);
            RESET(Arq);
            j := FILESIZE(Arq);
            TudoBem := j = Cs512;
            IF j > Cs512 THEN j := Cs512;
            u := 0;
            WHILE u < j DO
                BEGIN
                    NEW(pa[u]);          { aloca coluna de 512 bytes de memória }
                    seek(arq,u);
                    READ(Arq,pa[u]^ );   { carrega a área alocada }
                    INC(u);               { ==> u = u + 1 }
                END; { while u }
            CLOSE(Arq)
        END
    ELSE
        BEGIN
            WRITELN;

```

```
WRITELN(' ':10,'Não Há memória suficiente.São necessários: ',  
        1.0 * Cs512 * Cs512:10:0,' bytes.');
```

WRITELN(' ':10,'Retire programas residentes se houverem.');

```
HALT(1)          { Aborta o Programa }
```

END

END;

{*-----*}


```

{ *-----* }
PROCEDURE tela2;
BEGIN
  LimpaLinhas(9,4,14,50);
  TextoLC(9,15,'REGISTRO',AzulC,preto);
  TextoLC(9,27,'PIXEL',AzulC,preto);
  TextoLC(11,4,'inicial',branco,preto);
  TextoLC(14,4,'final',branco,preto);
  MolduraJanDados(10,12,12,22);
  MolduraJanDados(10,24,12,34);
  MolduraJanDados(13,12,15,22);
  MolduraJanDados(13,24,15,34);
  MolduraJanDados(10,3,15,11);
  PoeCursor(11,14);  readln(ri);
  PoeCursor(14,14);  readln(rf);
  PoeCursor(11,26);  readln(pi);
  PoeCursor(14,26);  readln(pf);
END;
{ *-----* }

```

```
{*-----*}
{ Zera arquivo com entradas reais }
PROCEDURE ZeraArquivo(VAR arqr: Fileregreal);

VAR
    i,j : INTEGER;
    regr: TyRegReal;

BEGIN
    FOR i := 0 TO Cs511 DO
        BEGIN
            FOR j := 0 TO Cs511 DO
                regr[j] := 0.0;
                write(arqr,regr);
            END;
        END;
    END;
{*-----*}
```

```

{*-----*}
{ Cálculo das matrizes de co-ocorrência e feições de textura }
PROCEDURE Tex(VAR pa : TyImagMemo; var ri,rf,pi,pf,dm : INTEGER;
              VAR xmax1,xmax2,xmax3,ymin1,ymin2,ymin3: REAL);
VAR
  yy,kk,d : BYTE;          { contadores }
  k,m,b    : INTEGER;
  i,j,r,s  : INTEGER;
  bmi,bma  : BYTE;
  f1,f2,f3 : real;
  arqnome  : string[8];
  regr1, regr2, regr3 : TyRegReal;
  arqr1,arqr2,arqr3 : FileRegReal;
  {*-----*}
  { cálculo do brilho máximo dentro da janela }
  FUNCTION Max(VAR pa : TyImagMemo; n,k,m : INTEGER):BYTE;
  VAR
    x : byte;
    i,j : INTEGER;
  BEGIN
    x := pa[k]^[m];
    FOR i := k TO k+n-1 DO
      FOR j := m TO m+n-1 DO
        IF x < pa[i]^[j] THEN x := pa[i]^[j];
      Max := x;
    END;
  {*-----*}
  { cálculo do brilho mínimo dentro da janela }
  FUNCTION Min(var pa : TyImagMemo; n,k,m : INTEGER):BYTE;

```

```

VAR
    x : byte;
    i, j : INTEGER;
BEGIN
    x := pa[k]^[m];
    FOR i := k TO k+n-1 DO
        FOR j := m TO m+n-1 DO
            IF x > pa[i]^[j] THEN x := pa[i]^[j];
            Min := x;
        END;
    END;
    {*-----*}
    FUNCTION LOG(y:REAL):REAL;
    BEGIN
        IF y > 0 THEN LOG := (LN(y)/LN(10))
        END;
    END;
    {*-----*}
BEGIN
    xmax1 := 0.0; xmax2 := 0.0; xmax3 := 0.0;
    ymin1 := 99999.0; ymin2 := 99999.0; ymin3 := 99999.0;

    LimpaLinhas(9,2,16,50);
    PoeCursor(10,10);
    WRITE('Nome dos arquivos Textura -> ');
    readln(arqnome);

    ASSIGN(arqr1,'c:+ arqnome + '.ft1');
    REWRITE(arqr1);
    ZeraArquivo(arqr1);

    ASSIGN(arqr2,'c:+ arqnome + '.ft2');

```



```
REWRITE(arqr2);
```

```
ZeraArquivo(arqr2);
```

```
ASSIGN(arqr3,'c:+ arqnome + '.ft3');
```

```
REWRITE(arqr3);
```

```
ZeraArquivo(arqr3);
```

```
LimpaLinhas(10,5,10,70);
```

```
PoeCursor(10,10);
```

```
write('Dimensao da janela -> ');
```

```
readln(dm);
```

```
fillchar(regr1,sizeof(regr1),0);
```

```
fillchar(regr2,sizeof(regr2),0);
```

```
fillchar(regr3,sizeof(regr3),0);
```

```
{ controle de deslocamento da janela }
```

```
FOR k := 0 TO rf-ri - dm + 1 DO
```

```
  BEGIN
```

```
    r := ri+k+(dm-1) div 2;      {linha do pixel central da janela}
```

```
    FOR m := 0 TO pf-pi - dm + 1 DO
```

```
      BEGIN
```

```
        s := pi+m+(dm-1) div 2; {coluna do pixel central da janela}
```

```
        f1 := 0.0;
```

```
        f2 := 0.0;
```

```
        f3 := 0.0;
```

```
        PoeCursor(18,40);
```

```
        write('r = ',r:5,' s = ',s:5);
```

```
        bmi := min(pa,dm,k,m);
```

```
        bma := max(pa,dm,k,m);
```

< variação dos índices dos níveis de cinza dentro da janela >

```
fillchar(med,sizeof(med),0);
fillchar(imed,sizeof(imed),0);
fillchar(jmed,sizeof(jmed),0);
```

```
yy := 0;
```

```
FOR kk := 0 TO bma-bmi DO
```

```
BEGIN
```

```
FOR d := kk TO bma-bmi DO
```

```
BEGIN
```

```
freq1 := 0;
```

```
freq2 := 0;
```

```
freq3 := 0; { Inicializa as frequências }
```

```
freq4 := 0;
```

```
medfreq := 0;
```

< variação dos pixels dentro da janela >

```
FOR i := ri+k TO ri+dm+k-1 DO
```

```
BEGIN
```

```
FOR j := pi+m TO pi+dm+m-1 DO
```

```
BEGIN
```

< Matriz de co-ocorrência horizontal - 0° >

```
IF (j+1 < m+dm) THEN
```

```
IF ((pa[i]^[j] = kk+bmi) AND (pa[i]^[j+1] = d+bmi)) OR
```

```
((pa[i]^[j] = d+bmi) AND (pa[i]^[j+1] = kk+bmi)) THEN
```

```
BEGIN
```

```
    freq1 := freq1 + 1;
```

```
END;
```

```
{ Matriz de co-ocorrência vertical - 90° }
```

```
IF (i+1 < k+dm) THEN
```

```
IF ((pa[i]^[j] = kk+bmi) AND (pa[i+1]^[j] = d+bmi)) OR  
((pa[i]^[j] = d+bmi) AND (pa[i+1]^[j] = kk+bmi)) THEN
```

```
    BEGIN
```

```
        freq2 := freq2 + 1;
```

```
    END;
```

```
{ Matriz de co-ocorrência diagonal direita - 45° }
```

```
IF (j-1 >= m) AND (i+1 < k+dm) THEN
```

```
IF ((pa[i]^[j] = kk+bmi) AND (pa[i+1]^[j-1] = d+bmi)) OR  
((pa[i]^[j] = d+bmi) AND (pa[i+1]^[j-1] = kk+bmi)) THEN
```

```
    BEGIN
```

```
        freq3 := freq3 + 1;
```

```
    END;
```

```
{ Matriz de co-ocorrência diagonal esquerda - 135° }
```

```
IF (j+1 < m+dm) AND (i+1 < k+dm) THEN
```

```
IF ((pa[i]^[j] = kk+bmi) AND (pa[i+1]^[j+1] = d+bmi)) OR  
((pa[i]^[j] = d+bmi) AND (pa[i+1]^[j+1] = kk+bmi)) THEN
```

```
    BEGIN
```

```
        freq4 := freq4 + 1;
```

```
    END;
```

```
END; { j }
```

```
END; { i }
```

```

IF kk = d THEN
  BEGIN
    freq1 := freq1 * 2;
    freq2 := freq2 * 2;
    freq3 := freq3 * 2;
    freq4 := freq4 * 2;
  END;

```

{ Matriz de co-ocorrência Média }

```

medfreq := freq1 + freq2 + freq3 + freq4;
medfacc := 4*(dm-1)*((2*dm)-1);

```

```

IF medfreq <> 0 THEN ,

```

```

  BEGIN

```

```

    med[yy] := medfreq;
    imed[yy] := kk;
    jmed[yy] := d;

```

{ feição de textura 1 - feição de homogeneidade }

```

f1 := f1 + SQR(med[yy] / medfacc);
IF (imed[yy] <> jmed[yy]) THEN
  f1 := f1 + SQR(med[yy] / medfacc);

```

{ feição de textura 2 - feição de entropia }

```

f2 := f2 - ((med[yy]/medfacc)*LOG(med[yy]/medfacc));
IF (imed[yy] <> jmed[yy]) THEN
  f2 := f2 - ((med[yy]/medfacc)*LOG(med[yy]/medfacc));

```


(feição de textura 3 - feição de contraste)

```
FOR b := 1 TO bma-bmi DO
  BEGIN
    IF (ABS(imed[yy] - jmed[yy]) = b) THEN
      f3 := f3 + (SQR(b)*(med[yy]/medfacc));

    IF (imed[yy] <> jmed[yy]) AND
      (ABS(imed[yy] - jmed[yy]) = b) THEN
      f3 := f3 + (SQR(b)*(med[yy]/medfacc));

    END;
    INC(yy,1);           { incrementa a posição no vetor }
  END; { if medfreq }

  END;   { d }
END;    { kk }

seek(arqr1,r);
seek(arqr2,r);
seek(arqr3,r);

regr1[s] := f1;
write(arqr1,regr1);
if f1 > xmax1 then
  xmax1 := f1;
if f1 < ymin1 then
  ymin1 := f1;

regr2[s] := f2;
write(arqr2,regr2);
```

```
if f2 > xmax2 then
  xmax2 := f2;
if f2 < ymin2 then
  ymin2 := f2;
```

```
regr3[s] := f3;
write(arqr3, regr3);
if f3 > xmax3 then
  xmax3 := f3;
if f3 < ymin3 then
  ymin3 := f3;
```

```
END; { m }
```

```
END; { k }
```

```
CLOSE(arqr1);
```

```
CLOSE(arqr2);
```

```
CLOSE(arqr3);
```

```
END; { begin inicial tex }
```

```
{*-----*}
```

```

{*-----*}
<Transfere os dados de imagem 512x512 da memória para o arquivo>
PROCEDURE GravaImagem(VAR ImagMemo:TyImagMemo;
                      VAR NomeArq :TyNomeArq);{nome arquivo c/imagem}
VAR
  Arq      :FILE OF TyReg;                { 0..511 }
  Reg      :TyReg;
  u,v      :TyIndReg;
BEGIN
  ASSIGN(Arq,NomeArq);
  REWRITE(Arq);
  FOR u := 0 TO Cs511 DO
  BEGIN
    FOR v := 0 TO Cs511 DO
      Reg[v] := ImagMemo[Cs511 - v]^[u];
    WRITE(Arq,Reg)
  END;
  CLOSE(Arq)
END;
{*-----*}

```

```
{*-----*}
{ Zera arquivo imagem com entradas inteiras }

PROCEDURE ZeraArqImagem(VAR arq: FileReg);
VAR
  i,j : INTEGER;
  arqq : registro;
BEGIN
  FOR i := 0 TO Cs511 DO
    BEGIN
      FOR j := '0 TO Cs511 DO
        arqq[j] := 0;
        write(arq,arqq);
      END;
    END;
  END;
{*-----*}
```



```

{*-----*}
( Transforma feições(valores reais) em imagem(valores de brilho))
PROCEDURE Imagem(VAR ArqNome : TyNomeArq; VAR xmax,ymin:REAL;
                 VAR dm,ri,rf,pi,pf : INTEGER;
                 VAR arqnome1 : TyNomeArq; VAR arq : filereg);
VAR
    i,j : INTEGER;
    arqr : FileRegReal;
    regr : TyRegReal;
    arqq : registro;
BEGIN
    fillchar(arqq,sizeof(arqq),0);
    ASSIGN(arqr,'c:+arqnome);
    RESET(arqr);
    ASSIGN(arq,'c:+arqnome1);
    REWRITE(arq);
    ZeraArqImagem(arq);
    FOR i := ri+(dm-1) div 2 TO rf-(dm-1) div 2 DO
        BEGIN
            seek(arqr,i);
            READ(arqr,regr);
            FOR j := pi+(dm-1) div 2 TO pf-(dm-1) div 2 DO
                BEGIN
                    seek(arq,i);
                    arqq[j] := ROUND(255/(xmax - ymin)*(regr[j] -ymin));
                    write(arq,arqq);
                END;
            END;
        CLOSE(arqr);
        CLOSE(arq);
    END;
{*-----*}

```

```

CarregaImagem(pa, NomeArq, TudoBem);
{*-----PROGRAMA PRINCIPAL-----*}
THEN BEGIN
VAR
  MarcaMemo: ^ INTEGER;           { Marca memória "Heap" }
  NomeArq   : TyNomeArq;         { nome arquivo c/ imagem }
  TudoBem   : BOOLEAN;
  arqnome,
  arqnome1  : TyNomeArq;
  arqmax    : TyNomeArq;
  arqr1, arqr2, arqr3 : FileRegReal;
  regr1, regr2, regr3 : TyRegReal;
  i, j      : INTEGER;

BEGIN
  LimpaLinhas(10,5,10,75);
  LimpaTela;
  WRITELN;
  IF PARAMCOUNT < 1
  THEN BEGIN
    WRITELN;
    WRITE('Sintaxe: Textura NomeArquivo.Extensão <CR>');
    HALT(1)
  END;

  NomeArq:=PARAMSTR(1);
  IF ChkDir(NomeArq)
  THEN BEGIN
    TELA1;
    MARK(MarcaMemo);
    TextoLC(10,5,' Carregando Imagem ... ',Amarelo,Azul);

```

```

CarregaImagem(pa, NomeArq, TudoBem);
IF TudoBem
THEN BEGIN

    TELA2;
    Tex(pa, ri, rf, pi, pf, dm, xmax1, xmax2, xmax3, ymin1, ymin2, ymin3);

    arqnome := 'c_5d5.ft1';
    arqnome1 := 'c_5d5.bf1';
    LimpaLinhas(10, 5, 18, 75);
    TextoLC(10, 5, ' AGUARDE I ...', Amarelo, Azul);
    Imagem(ArqNome, xmax1, ymin1, dm, ri, rf, pi, pf, arqnome1, arq1);

    arqnome := 'c_5d5.ft2';
    arqnome1 := 'c_5d5.bf2';
    LimpaLinhas(10, 5, 10, 75);
    TextoLC(10, 5, ' AGUARDE II ...', Amarelo, Azul);
    Imagem(ArqNome, xmax2, ymin2, dm, ri, rf, pi, pf, arqnome1, arq2);

    arqnome := 'c_5d5.ft3';
    arqnome1 := 'c_5d5.bf3';
    LimpaLinhas(10, 5, 10, 75);
    TextoLC(10, 5, ' AGUARDE III ...', Amarelo, Azul);
    Imagem(ArqNome, xmax3, ymin3, dm, ri, rf, pi, pf, arqnome1, arq3);

END; { if tudobem }
RELEASE(MarcaMemo);           { DISPOSE do Pascal ANSI }
WRITELN
END
ELSE BEGIN

```

```
WRITELN(' ':10,'Arquivo não encontrado.');
```

WRITELN(' ':10,'Indique Drive e "PATH".');

END; { if }

LimpaLinhas(10,5,10,75);

TextoLC(10,5,' TÉRMINO DO PROCESSAMENTO !!!',Amarelo,Azul);

END. { programa principal }

{*-----*}