

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

TEXTURAS DE IMAGENS UTILIZANDO CONCEITOS DE MORFOLOGIA MATEMÁTICA

DISSERTAÇÃO APRESENTADA NO

CURSO DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

COMO ASPIRANTE AO GRAU DE MESTRE EM SENSORIAMENTO REMOTO

CENTRO ESTADUAL DE PESQUISA EM SENSORIAMENTO REMOTO E METEOROLOGIA

POR

LUÍS OTÁVIO THOMPSON CLARO

ORIENTADOR: PROFESSOR Dr. VITOR HAERTEL

Bento Gonçalves, 9500

Porto Alegre, Rio Grande do Sul

18 de dezembro de 1995.

AGRADECIMENTOS

Ao término de um trabalho árduo e de muita dedicação, agradeço a todos aqueles que contribuíram para a sua realização, em especial :

A minha esposa Maiara e a minha filha Mírcea, pelo incentivo e apoio incondicional, pelas noites maldormidas e pelas horas de diversão que lhes roubei;

Aos meus pais, irmãos e cunhado, por não medirem esforços para que o trabalho fosse realizado com a máxima tranquilidade;

Ao professor Vitor Haertel, pelo incansável aconselhamento e fundamental apoio técnico, responsável pela qualidade deste trabalho;

Aos colegas do curso de pós-graduação, pela ajuda dada em suas áreas de especialização;

Aos amigos Eduardo Juan Luiz Posse, Glauber Acunha Gonçalves e Antônio Valente, pelas imagens cedidas, pelos programas desenvolvidos em conjunto e pelas experiências compartilhadas;

Aos amigos Fernando e Sílvia Botelho, pelo acompanhamento e ajuda durante todas as etapas do trabalho;

Ao amigo Newton Luiz Canary, pela ajuda que possibilitou a impressão final deste trabalho;

Ao Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia, seus professores e funcionários, pelo carinho e atenção dispensada em todas as ocasiões.

SINOPSE

A textura é um atributo ainda pouco utilizado no reconhecimento automático de cenas naturais em sensoriamento remoto, já que ela advém da sensação visual causada pelas variações tonais existentes em uma determinada região da imagem, tornando difícil a sua quantificação. A morfologia matemática, através de operações como erosão, dilatação e abertura, permite decompor uma imagem em elementos fundamentais, as primitivas texturais. As primitivas texturais apresentam diversas dimensões, sendo possível associar um conjunto de primitivas com dimensões semelhantes, em uma determinada classe textural. O processo de classificação textural quantifica as primitivas texturais, extrai as distribuições das dimensões das mesmas e separa as diferentes distribuições por meio de um classificador de máxima-verossimilhança gaussiana. O resultado final é uma imagem temática na qual cada tema representa uma das texturas existentes na imagem original.

ABSTRACT

Texture is one of the important characteristics used in identifying objects or regions of interest in an image, whether the image be an aerial photograph or a satellite image.

Textural features contain information about the spatial distribution of tonal variations within a band.

Although it is quite easy for human observers to recognize and describe in empirical terms, texture has been extremely refractory to precise definition and to analysis by digital computers.

Several approaches have been suggested in the literature. One approach is to consider texture as composed of basic units or primitives. According to this principle, image texture can be described by the number, size, and shape of its primitives.

This study implements the techniques provided by mathematical morphology to classify a digital image using its textural structure. Morphological operations are used to estimate the textural attributes of the classes present on a scene. Maximum-likelihood classifiers can then be used to perform the classification procedure.

ÍNDICE ANALÍTICO

	Página
AGRADECIMENTOS	ii
SINOPSE	iii
ABSTRACT	iv
LISTA DE ILUSTRAÇÕES	viii
CAPÍTULO 1 INTRODUÇÃO	10
CAPÍTULO 2 REVISÃO BIBLIOGRÁFICA	13
2.1. FUNÇÕES DE AUTOCORRELAÇÃO.....	13
2.2. PROCESSAMENTO ÓPTICO	13
2.3. TRANSFORMADAS DIGITAIS.....	14
2.4. MATRIZES DE COCORRÊNCIA	15
2.5. MORFOLOGIA MATEMÁTICA	15
CAPÍTULO 3 METODOLOGIA.....	16
3.1 TEXTURA.....	16
3.2. PRINCÍPIOS BÁSICOS DA QUANTIFICAÇÃO DE IMAGENS	19
3.2.1. PRINCÍPIO DA INVARIÂNCIA QUANTO À TRANSLAÇÃO.....	19
3.2.2. PRINCÍPIO DA INVARIÂNCIA QUANTO À MUDANÇA DE ESCALA	20
3.2.3. PRINCÍPIO DO CONHECIMENTO LOCAL.....	21
3.2.4. PRINCÍPIO DA SEMICONTINUIDADE	22
3.3. MORFOLOGIA MATEMÁTICA	23
3.3.1. EROSÃO	25
3.3.2. DILATAÇÃO	26
3.3.3. ABERTURA.....	26
3.4. GRANULOMETRIAS	27
3.4.1. AXIOMAS BÁSICOS DA GRANULOMETRIA	28
3.4.2 GRANULOMETRIA EM NÚMERO E EM DIMENSÃO.....	29

3.4.3. REPRESENTAÇÃO NORMALIZADA DAS GRANULOMETRIAS.....	30
3.4.4. GRANULOMETRIAS POR ABERTURA.....	32
3.5. CLASSIFICAÇÃO TEXTURAL PELA MÁXIMA-VEROSSIMILHANÇA GAUSSIANA	34
3.5.1. FUNÇÃO DE DECISÃO	34
3.5.2. MÉTODO DA MÁXIMA-VEROSSIMILHANÇA.....	35
3.5.3. ESTIMAÇÃO DOS PARÂMETROS DA FUNÇÃO DISCRIMINANTE	37
3.6. BINARIZAÇÃO	40
3.6.1. BINARIZAÇÃO PELA MÉDIA.....	41
3.6.2. BINARIZAÇÃO PELA MEDIANA.....	42
3.6.3. BINARIZAÇÃO PELA ANÁLISE DE HISTOGRAMA.....	42
CAPÍTULO 4 EXPERIMENTOS	44
4.1. IMAGEM SINTÉTICA.....	44
4.1.1. CLASSIFICAÇÃO TEXTURAL DA IMAGEM SINTÉTICA.....	45
4.1.1.1. GRANULOMETRIAS POR ABERTURAS.....	46
4.1.1.2. ESTIMAÇÃO DOS PARÂMETROS NA DISTRIBUIÇÃO GRANULOMÉTRICA	49
4.1.1.3. CLASSIFICAÇÃO PELA MÁXIMA-VEROSSIMILHANÇA GAUSSIANA ..	50
4.2. IMAGEM REAL	51
4.2.1. CLASSIFICAÇÃO TEXTURAL DA IMAGEM REAL	53
4.2.1.1. BINARIZAÇÃO.....	54
4.2.1.2. GRANULOMETRIAS POR ABERTURAS DA IMAGEM REAL.....	54
4.2.1.3. CLASSIFICAÇÃO TEXTURAL DA IMAGEM REAL.....	57
CAPÍTULO 5 RESULTADOS E CONCLUSÕES	59
5.1. CLASSIFICAÇÃO VISUAL DA IMAGEM REAL	59
5.2. ANÁLISE VISUAL DAS CLASSES TEXTURAIS	60
5.3. ANÁLISE DO PROCESSO DE BINARIZAÇÃO	60

5.4. ANÁLISE DAS BANDAS TEXTURAIS.....	62
5.5. INFLUÊNCIA DA RESOLUÇÃO ESPACIAL NO PROCESSO DE CLASSIFICAÇÃO.....	62
5.6. COMPARAÇÃO ENTRE CLASSIFICAÇÃO VISUAL E PROCESSO DE CLASSIFICAÇÃO TEXTURAL.....	63
5.7. CONCLUSÕES.....	64
BIBLIOGRAFIA.....	66

LISTA DE ILUSTRAÇÕES

Figura	Página
Figura 1. Sistema sol/alvo/satélite	17
Figura 2. Características espectrais da água, vegetação e solo	17
Figura 3. Exemplo de imagem tritextural	18
Figura 4. Princípio da invariância quanto à translação	20
Figura 5. Invariância quanto à mudança de escala da projeção de um objeto	21
Figura 6. Exemplo de transformação que segue o princípio do conhecimento local	22
Figura 7. Imagem digital de um caminhão	24
Figura 8. Elementos estruturantes utilizados em operações morfológicas	24
Figura 9. Figura A erodida por um elemento estruturante B	25
Figura 10. Dilatação da figura A pelo elemento estruturante B	26
Figura 11. Abertura de um retângulo por um disco	27
Figura 12. Exemplo de distribuição em número e em dimensão	30
Figura 13. Funções distribuição e densidade granulométrica de um conjunto aberto por um elemento estruturante hexagonal	33
Figura 14. Funções de decisão para duas classes texturais	35
Figura 15. Obtenção das bandas texturais	39
Figura 16. Exemplo de binarização pela média	42
Figura 17. Binarização pela análise de histograma	43
Figura 18. Imagem binária sintética	45
Figura 19. Elementos estruturantes utilizados na abertura da imagem real	46
Figura 20. Granulometrias por abertura com elementos estruturantes horizontais de tamanhos (a) 2 (b) 3 (c) 4 (d) 5 e (e) 6	47
Figura 21. Granulometrias por abertura com elementos estruturantes verticais de tamanhos (a) 2 (b) 3 (c) 4 (d) 5 e (e) 6	47

Figura 22. Granulometrias por abertura com elementos estruturantes diagonais direitos de tamanhos (a) 2 (b) 3 (c) 4 e (d)	48
Figura 23. Granulometrias por abertura com elementos estruturantes diagonais esquerdos de tamanhos (a) 2 (b) 3 (c) 4 e (d)	48
Figura 24. Banda textural das médias	49
Figura 25. Banda textural das variâncias	50
Figura 26. Imagem sintética classificada texturalmente	51
Figura 27. Imagem textural real	52
Figura 28. Alvos presentes na imagem real	52
Figura 29. Localização geográfica da região em estudo	53
Figura 30. Imagem real binarizada	54
Figura 31. Granulometrias com elementos estruturantes horizontais	55
Figura 32. Granulometrias com elementos estruturantes verticais	55
Figura 33. Granulometrias com elementos estruturantes diagonais direitos	56
Figura 34. Granulometrias com elementos estruturantes diagonais esquerdos	56
Figura 35. Banda textural das médias	57
Figura 35. Banda textural das variâncias	57
Figura 37. Imagem real classificada	58
Figura 38. Classificação visual da imagem real	59
Figura 39. Análise do processo de binarização	61
Figura 40. Matriz de contingência da classificação visual x classificação computacional	64

CAPÍTULO 1

INTRODUÇÃO

O sensoriamento remoto dos recursos naturais, apesar de ser uma ciência recente, já produziu uma grande quantidade de informações sobre o planeta Terra, graças ao avanço no desenvolvimento de satélites com dimensões cada vez menores, maior vida útil e melhores resoluções espaciais e espectrais.

Os satélites têm sensores que captam uma parte da energia eletromagnética vinda do Sol que é refletida pela Terra . A energia que chega aos sensores, vinda da região da Terra por onde o satélite está passando, é quantificada digitalmente antes de ser enviada para estações terrestres, para posterior processamento. O valor digital que é enviado à Terra é proporcional a energia que o alvo está refletindo [17].

O satélite "enxerga" a região está sendo imageada como uma matriz bidimensional na qual cada ponto é um valor discreto proporcional a reflectância daquele ponto na superfície da Terra. A transformação desta matriz em uma imagem digital é feita pela associação de cada ponto da mesma a um *pixel* do sistema utilizado para a sua visualização.

A imagem, assim obtida, contém informações de natureza diversa a respeito da porção da superfície da Terra imageada. Com base nesses dados e utilizando algoritmos adequados, é possível reconhecer, em ambiente de computador, os diversos tipos de cobertura do solo presentes na cena. Esse processo é denominado de "Classificação da Imagem" [15].

Este reconhecimento é feito a partir dos dados, ou informações, contidos nas células que compõe a imagem digital e são geralmente denominados de atributos [17] .

Os atributos podem ser agrupados em três grandes categorias:

- atributos espectrais;
- atributos espaciais e
- atributos de contexto.

Os atributos espectrais referem-se diretamente ao brilho de cada célula, isto é, à quantidade de energia eletromagnética refletida ou emitida pelo terreno, em várias regiões do espectro. Por serem mais facilmente quantificáveis, os atributos espectrais têm sido tradicionalmente os mais utilizados no processo de classificação automática por computador. A não utilização dos demais atributos implica, obviamente, na não utilização da totalidade da informação contida na imagem.

Os atributos espaciais têm sido muito bem aproveitados por fotointérpretes, mas há sempre a subjetividade, fazendo com que uma mesma imagem, ao ser interpretada por duas pessoas, apresente discrepâncias entre as duas classificações. Para evitar a subjetividade humana e acelerar o processo de classificação espacial, alguns métodos computacionais têm sido desenvolvidos para a discriminação de textura, um dos mais importantes atributos espaciais em imagens.

Os atributos de contexto são utilizados para classificar uma determinada região com base no conhecimento das regiões vizinhas a mesma. Da classificação de contexto resulta um mapa temático consistente com as classificações espectrais e espaciais.

Apesar de sua importância, uma definição formal de textura não existe. No entanto, os pesquisadores a tem caracterizado como sendo as variações tonais repetitivas e organizadas que podem ser distinguidas em uma pequena região de uma imagem. Este conceito é também a chave do caminho a ser seguido para que a textura possa ser caracterizada. Deve-se, de alguma maneira, extrair da imagem os tipos diferentes de

variações tonais existentes e estimar a correspondente função densidade de probabilidade a ela associada.

Nesta dissertação, busca-se desenvolver um processo de discriminação textural em imagens reais utilizando técnicas de morfologia matemática [2,16]. A morfologia matemática dispõe de ferramentas que possibilitam decompor uma imagem complexa em uma série de elementos mais simples, as primitivas texturais [8], ou conjuntos de "grãos" portando determinadas características texturais. A classificação textural é feita pela análise dos tamanhos e das distribuições dos grãos nas diferentes regiões da imagem.

Esta dissertação está dividida em 5 capítulos:

- Capítulo 1 : Introdução;
- Capítulo 2: Revisão Bibliográfica;
- Capítulo 3: Metodologia;
- Capítulo 4: Experimentos e
- Capítulo 5: Resultados e conclusões.

No capítulo 2 é feita uma revisão bibliográfica sobre o assunto, na qual são citados os principais trabalhos publicados sobre o tema.

No capítulo 3 é descrita a base teórica da pesquisa.

No capítulo 4 são aplicados os conhecimentos teóricos visando a classificação de uma imagem sintética e de uma cena natural.

O capítulo 5 apresenta os resultados obtidos com o método na classificação de uma cena natural e as conclusões a respeito dos mesmos.

CAPÍTULO 2

REVISÃO BIBLIOGRÁFICA

A literatura sobre classificação de imagens com base em atributos texturais conta com um número considerável de modelos desenvolvidos, grande parte fundamentados em processos estatísticos. Trabalhos como o do professor Dougherty [5] utilizando conceitos de morfologia matemática, no entanto, ainda são raros. Haralick [8] reuniu em seu trabalho as principais abordagens sobre a classificação textural de imagens, as quais estão relacionadas nos itens seguintes.

2.1. FUNÇÕES DE AUTOCORRELAÇÃO

As funções de autocorrelação caracterizam uma imagem com base no tamanho de suas primitivas tonais [8]. Primitivas tonais grandes são associadas a texturas grosseiras e primitivas tonais pequenas a texturas finas. A primitiva tonal, neste modelo, é o tom de cinza. Para verificar se as funções de autocorrelação guardavam alguma relação com a textura, o pesquisador Kaizer [9] comparou as funções de autocorrelação de sete imagens de uma região do Ártico, com a classificação visual das mesmas sete imagens por um grupo de vinte fotointérpretes. Os resultados revelaram um coeficiente de correlação de 0.99.

2.2. PROCESSAMENTO ÓPTICO

Os processos ópticos baseiam-se no fato de que a distribuição da amplitude da luz na frente e atrás do plano focal de uma lente são as transformadas de Fourier uma da outra [14]. Os padrões de distribuição de luz produzidos por lentes são conhecidos como "padrões de difração de Fraunhofer". Um experimento importante para a comprovação

do método foi feito por Lendaris e Stanley [11], que consistia na iluminação de pequenas seções circulares de fotografias aéreas. As seções circulares eram identificadas pelos padrões de Fraunhofer. O objetivo do experimento era discriminar áreas construídas pelo homem de outras áreas. O processo chegou a até 90% de precisão na classificação.

2.3. TRANSFORMADAS DIGITAIS

Neste método, a imagem digital é subdividida em pequenos quadrados não sobrepostos. Aplicando-se um processo de transformação, como Fourier, Hadamard ou outro, as subimagens, no novo sistema de coordenadas, têm uma interpretação relacionada à frequência espacial. Como a frequência espacial está intimamente relacionada à textura, é possível utilizar este método para discriminar texturas [8].

Gramenopoulos [6] usou a técnica de transformadas empregando senos e cossenos em imagens LANDSAT. Seu interesse era o reconhecimento de tipos de terrenos. Ele chegou a conclusão de que frequências espaciais superiores a 3.5 ciclos/Km e inferiores a 5.9 ciclos/Km eram suficientes para discriminar diversos tipos de terrenos.

Kirvida e Jhonson [10] compararam as transformadas rápidas de Fourier, Hadamard e Slant à textura de imagens LANDSAT sobre o estado americano de Minnesota. Eles usaram subimagens de 8 x 8 *pixels* e cinco categorias: madeira-de-lei, conífera, descampado, cidade e água. Usando apenas informações espectrais eles chegaram a 74% de identificação correta. Acrescentando as informações texturais às espectrais, o método alcançou uma correção de 99%. Os resultados foram muito semelhantes para as diferentes transformadas utilizadas.

2.4. MATRIZES DE COCORRÊNCIA

O método das matrizes de coocorrência [7] estuda a distribuição espacial e a dependência espacial entre os tons de cinza em uma área local. A ocorrência de tons de cinza pode ser definida como uma matriz de frequências relativas com que dois *pixels* vizinhos, separados por uma determinada distância, ocorrem na imagem, um com um tom de cinza "i" e outro com um tom de cinza "j". Há uma relação entre a variação dos tons de cinza com a textura, tornando possível a utilização deste método na classificação textural.

Haralik et al. [7] obteve com as matrizes de coocorrência um acerto de 84% na identificação de texturas em imagens LANDSAT da baía de Monterey, na Califórnia.

2.5. MORFOLOGIA MATEMÁTICA

Este processo foi proposto por Matheron [12]. A idéia básica é a de um elemento estruturante, um forma geométrica qualquer, que se desloca sobre a imagem binária gerando uma nova imagem binária. Propriedades texturais podem ser obtidas através da parametrização do elemento estruturante e o número de elementos encontrados na nova imagem, em função desse parâmetro.

Dougherty [5] gerou momentos granulométricos locais com auxílio da morfologia matemática e os classificou pela máxima-verossimilhança gaussiana [15]. Ele aplicou o método em imagens sintéticas com a inclusão de ruídos aleatórios. Obteve resultados que variaram de 80 a 99% de precisão, em função do tipo de ruído empregado.

CAPÍTULO 3

METODOLOGIA

A metodologia desenvolvida nesta dissertação está baseada fundamentalmente nos trabalhos de Matheron [13], Serra [16] e Dougherty e Giardia [4].

As técnicas de Morfologia Matemática foram desenvolvidas em 1965 por Matheron [13] como uma ferramenta em suas investigações envolvendo a relação entre a geometria de meios porosos e a correspondente permeabilidade. Na mesma época, Serra [16], utilizando conceitos semelhantes, desenvolveu um método para quantificar alguns elementos em seus estudos geológicos os quais buscavam prever as propriedades de moagem de minério de ferro. Dougherty [5], em 1991, utilizando os axiomas básicos da morfologia matemática, criou um processo de classificação de texturas em imagens binárias. A aplicação de métodos de Morfologia Matemática para fins de classificação de imagens digitais em Sensoriamento Remoto com base em atributos de textura, constitui-se no tópico central da metodologia desenvolvida nesta dissertação.

3.1 TEXTURA

Cada uma das várias categorias de características associadas a determinado objeto, ou a uma classe de cobertura do solo, por exemplo, capaz de distingui-la das demais, é denominado de atributo. Uma imagem oriunda de uma estação orbital (satélite) pode ser descrita com base nos seus atributos. Em uma imagem, os atributos presentes são geralmente agrupados em três categorias: atributos espectrais, espaciais e de contexto. Os atributos espectrais [17] são quantificados pelo comportamento espectral dos vários objetos ou alvos que compõem a cena, conforme registrado pelo sistema sensor. O

comportamento espectral de alvos terrestres é descrito pela habilidade dos mesmos em refletir a energia solar incidente em regiões selecionadas do espectro eletromagnético. Este tipo de atributo é frequentemente o mais utilizado na classificação de imagens, pois é de fácil quantificação, permitindo a sua utilização em algoritmos vários para classificação de imagens digitais. A figura 1 mostra a interação que ocorre no sistema sol, alvo e satélite e a figura 2 , as respostas espectrais típicas da água, vegetação e solo [15].

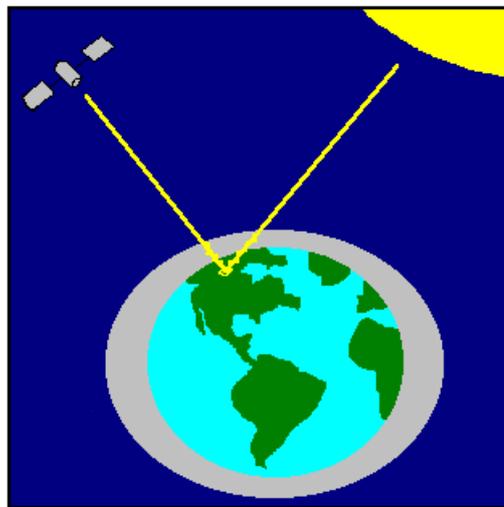


Figura 1. Sistema sol/alvo/satélite

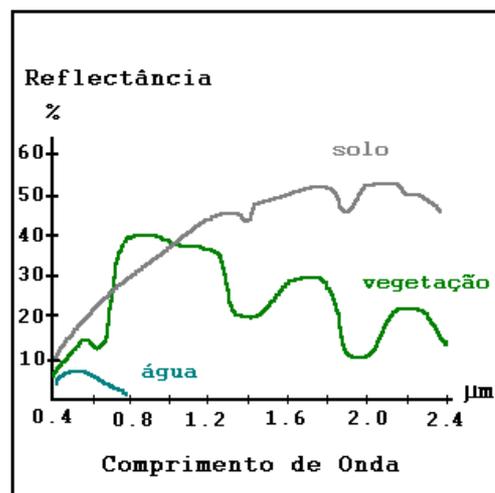


Figura 2. Características espectrais da água, vegetação e solo

Os atributos espaciais [17] estão relacionados com parâmetros como forma, dimensão e textura. O atributo espacial que mais atenção tem recebido em sensoriamento remoto é a textura (figura 3). A textura é um atributo que vem sendo de longa data utilizado em fotointerpretação, como elemento auxiliar no processo de classificação, especialmente na distinção entre duas classes com comportamento espectral similar, como por exemplo, floresta nativa e floresta plantada. A textura é descrita, de forma qualitativa, como "uniforme", "grosseira", "regular", "fina" e "média".

Embora de fácil percepção visualmente, a textura é difícil de ser definida com rigor e também quantificada de modo a permitir sua utilização em algoritmos para classificação de imagens. Segundo Dougherty [5], "textura é a variação tonal repetitiva e organizada em um pequena região de uma imagem".

A caracterização que Dougherty [5] dá a textura, no entanto, não é suficiente para que ela possa ser quantificada. Para que isso seja possível, a imagem deve sofrer alguma transformação geométrica que permita medir ou estimar algum parâmetro sobre a mesma. Nesta pesquisa, as técnicas e os conceitos de morfologia matemática [2] são utilizadas para definir as transformações adequadas.

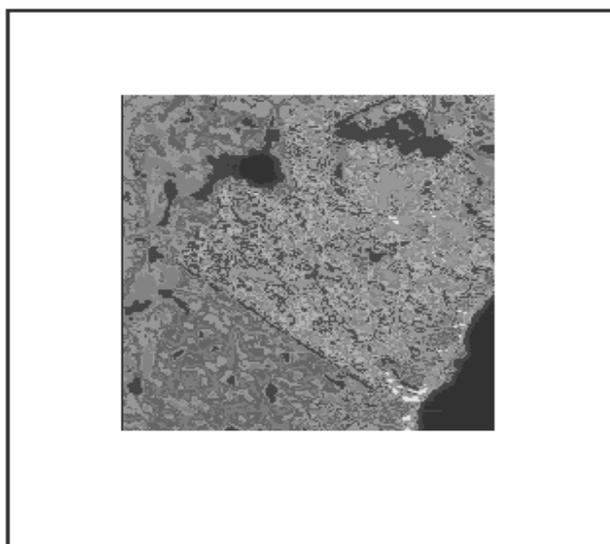


Figura 3. Exemplo de imagem tritextural

3.2. PRINCÍPIOS BÁSICOS DA QUANTIFICAÇÃO DE IMAGENS

O processo de quantificação de imagens deve ser completamente objetivo, independente da sensação visual de cada observador em particular. Para que isto seja alcançado, alguns conceitos devem ser formalizados para que deles se possa obter resultados numéricos. Os princípios básicos da quantificação são quatro: invariância quanto à translação, invariância quanto à mudança de escala, o conhecimento local e a semicontinuidade [16].

3.2.1. PRINCÍPIO DA INVARIÂNCIA QUANTO À TRANSLAÇÃO

Há dois tipos de transformações a serem distinguidas: aquelas que dependem da posição da origem dos eixos de coordenadas e as que não dependem. As operações que não dependem da origem dos eixos de coordenadas são as que interessam ao processo de classificação textural. Um exemplo de uma transformação invariante quanto à translação é mostrado na figura 4 [3]. Em uma imagem, composta por partículas circulares, é aplicada uma transformação visando a eliminar todas as partículas com o diâmetro menor do que um determinado diâmetro. Neste exemplo, a translação de uma partícula de uma região da imagem para outra não evitará que esta partícula seja eliminada se o seu diâmetro for inferior ao definido na transformação. O princípio da invariância quanto à translação é escrito simbolicamente como:

$$\Psi(X_h) = [\Psi(X)]_h \quad (3.01)$$

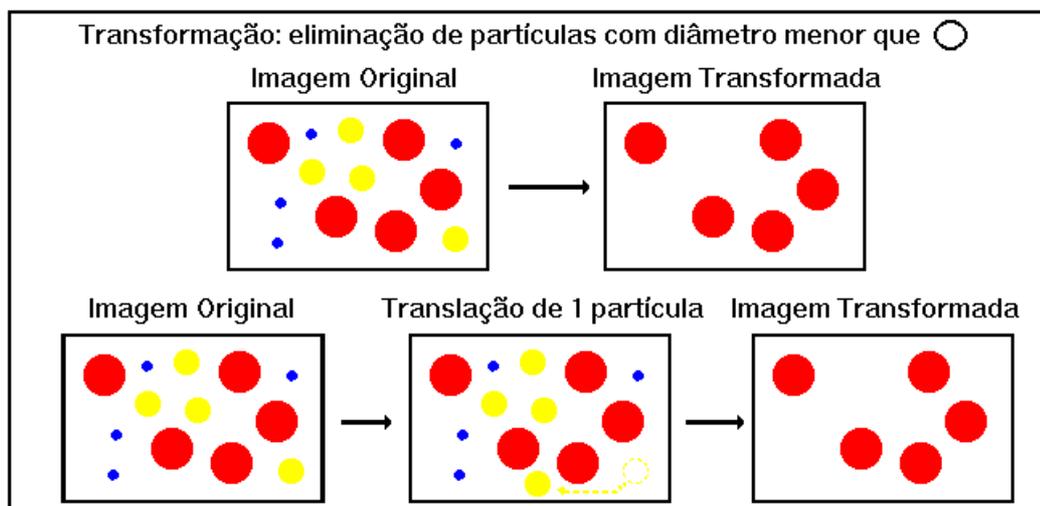


Figura 4. Princípio da invariância quanto à translação

3.2.2. PRINCÍPIO DA INVARIÂNCIA QUANTO À MUDANÇA DE ESCALA

Por este princípio, a transformação sofrida pela imagem não deve depender da escala em que ela esteja. Na prática, freqüentemente texturas idênticas são analisadas utilizando escalas diferentes. Segundo Serra [2], "não há qualquer garantia de que dois geólogos classifiquem um seção geológica microscópica com a mesma ampliação". Uma análise quantitativa deve ser feita de maneira que seja independente da ampliação ou redução sofrida pelos objetos. Usando um exemplo de Serra [2]: desejando-se eliminar partículas cujas dimensões sejam superiores a $10\mu m$ na imagem original, e supondo ainda que após uma ampliação da imagem, essa dimensão passar ao valor 4 cm , então uma transformação invariante quanto à mudança de escala automaticamente passaria a desenvolver a mesma operação (i.e.: eliminação de partículas) para as partículas com dimensão superior a 4 cm .

Este princípio deve ser cuidadosamente observado, pois a invariância quanto a mudança de escala não ocorre sempre. Assim, por exemplo, a soma da superfície com comprimento do perímetro de um objeto não é invariante quanto a mudança de escala,

visto que a superfície é proporcional ao quadrado da constante de ampliação ou redução, enquanto que o perímetro varia linearmente.

A invariância quanto a mudança de escala pode ser definida da seguinte forma:

$$\Psi(\lambda X) = \lambda \Psi(X), \quad \lambda > 0 \quad (3.02)$$

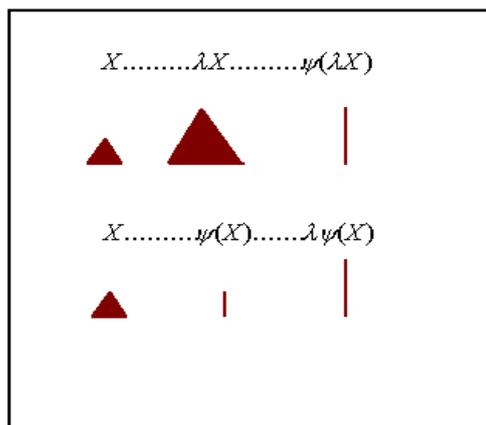


Figura 5. Invariância quanto à mudança de escala da projeção de um objeto

3.2.3. PRINCÍPIO DO CONHECIMENTO LOCAL

Normalmente o conjunto das partículas que compõem uma imagem não é conhecido, mas apenas aquelas contidas em uma subárea, geralmente pequena, e comumente denominada de "janela" ou "máscara" [16]. Conforme a posição relativa desta janela em relação ao conjunto da imagem, pode-se ter partículas totalmente contidas na janela ou partículas, em número variável, apenas parcialmente contidas na janela. O princípio do conhecimento local é satisfeito quando a máscara de medida situar-se em uma região com características locais conhecidas (partículas situadas completamente no interior da janela - figura 6) e a transformação for efetuada dentro destes limites. No caso de discriminação de texturas, a máscara de medida deve estar em uma região que apresente uma textura uniforme, distinta das demais texturas existentes na imagem. Isto é,

a região avaliada deve ser representativa de uma determinada categoria ou classe de textura.

$$[\Psi(X \cap Z)] \cap Z' = \Psi(X) \cap Z' \quad (3.03)$$

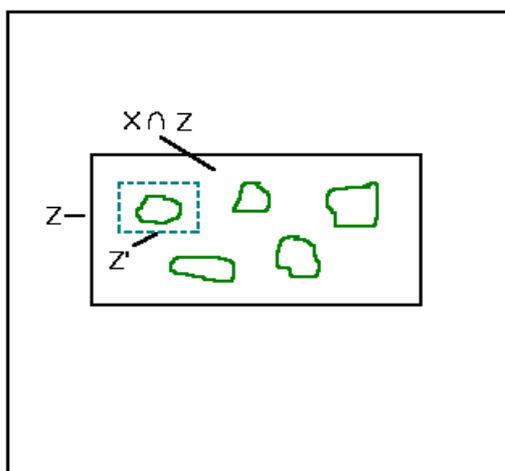


Figura 6. Exemplo de transformação que segue o princípio do conhecimento local

3.2.4. PRINCÍPIO DA SEMICONTINUIDADE

O princípio da semicontinuidade é apresentado por Serra [16] da seguinte maneira: se em um experimento constituído por duas categorias se extrair duas amostras, uma amostra da primeira categoria e outra da segunda, haverá uma região indefinida entre as amostras sobre a qual só se pode afirmar que ela contém a fronteira entre uma categoria e a outra. Em vista disso, qualquer transformação realizada na região de indefinição não é válida, pois não é representativa de nenhuma das duas categorias envolvidas. Para solucionar esta indefinição, são tomadas outras amostras cada vez menores dentro da região desconhecida, até se obter uma amostra que apresente características apenas da categoria que se deseja isolar.

O problema de fronteiras entre classes ocorre com frequência em cenas naturais. Em vista disto, normalmente há uma região na imagem classificada na qual não se pode fazer qualquer tipo de afirmação sobre o tipo de textura presente na mesma.

3.3. MORFOLOGIA MATEMÁTICA

A morfologia matemática é uma ferramenta criada para a análise de imagens por meio de transformações geométricas. As transformações geométricas em morfologia matemática foram definidas de forma a satisfazer os quatro princípios de quantificação de imagens, anteriormente descritos. Como Serra [16] afirma, a aplicabilidade das técnicas de morfologia matemática depende em muito do fenômeno que se deseja quantificar. Um grafologista pode extrair mais informações de uma assinatura do que uma análise desta por métodos morfológicos. Uma imagem de satélite na qual a curvatura da terra é significativa, também não deve ser analisada morfológicamente, pois as deformações introduzidas tornam a imagem sensível em relação à posição analisada, isto é, violaria o princípio da invariância quanto à translação.

O campo de ação da morfologia matemática no processamento de imagens inclui: realçamento, segmentação, detecção de bordas, análise de textura, análise de partículas e compressão. Técnicas de morfologia matemática vêm sendo empregadas em robótica, microscopia, sensoriamento remoto, imagens em medicina, biologia, metalurgia e reconhecimento automático de caracteres.

A idéia básica em morfologia matemática é investigar uma imagem utilizando um elemento estruturante, verificando como ele se ajusta à imagem à medida em que ele se desloca pela mesma. Elementos estruturantes são conjuntos de *pixels* ativos com uma origem e forma bem definidas, sendo um subconjunto da imagem original. O elemento estruturante se ajusta à região da imagem que ele está explorando, quando a seqüência de *pixels* que o compõem é idêntica à seqüência de *pixels* presentes em uma dada região da

imagem. Nesta dissertação, sempre que se fizer referência a imagem, se estará considerando a mesma como digital e binária. Uma imagem binária digital tem a forma de uma matriz bidimensional com os seus elementos podendo assumir os valores digitais "0" ou "1". Na figura 7 é mostrada uma imagem binária digital e na figura 8, alguns tipos de elementos estruturantes.

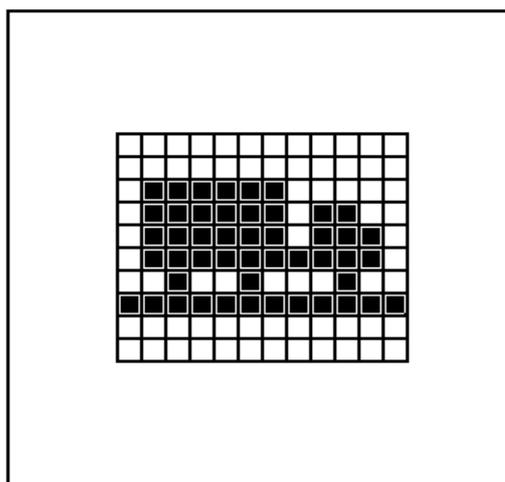


Figura 7. Imagem digital de um caminhão

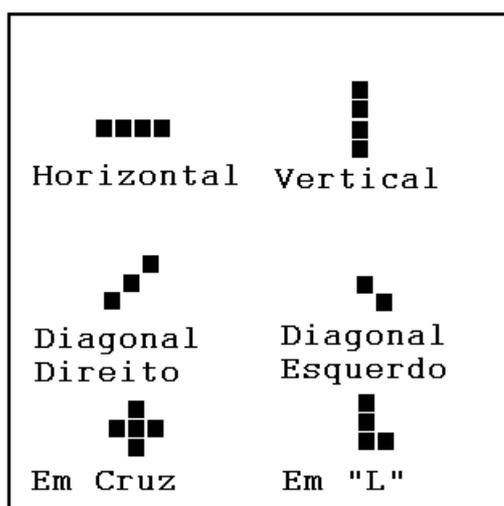


Figura 8. Elementos estruturantes utilizados em operações morfológicas

A maneira como o elemento estruturante se ajusta à imagem é determinada pelo tipo de operação morfológica executada. As operações básicas da morfologia matemática no processo textural são: erosão, dilatação e abertura.

3.3.1. EROSÃO

A erosão [2] é uma operação morfológica resultante da translação de um elemento estruturante ao longo da imagem, marcando os pontos nos quais a origem do elemento estruturante se ajusta à imagem. A origem do elemento estruturante define a região da imagem que deverá ser desativada, ou não, após cada operação morfológica.

Geometricamente, como ilustrado na figura 9 por um objeto no espaço Euclidiano, a erosão de A pelo elemento estruturante B, com origem localizada em seu centro pode ser definida por:

$$A - B = \{x: B + x \subset A\} \quad (3.04)$$

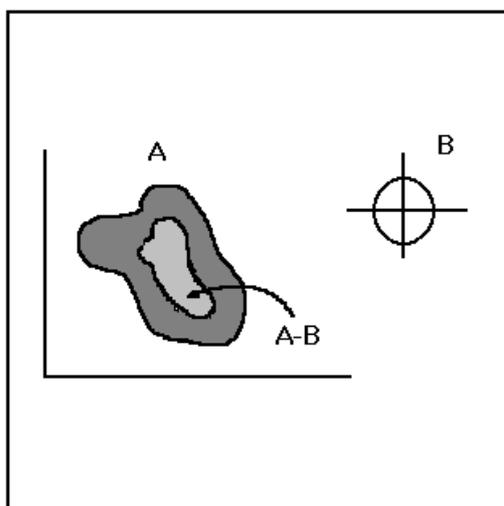


Figura 9. Figura A erodida por um elemento estruturante B

3.3.2. DILATAÇÃO

A segunda operação da morfologia matemática binária é a dilatação [2]. Ela é uma operação dual da erosão, o que permite que ela seja definida por uma lei complementar à da erosão. A dilatação de um conjunto A por um conjunto B é definida por:

$$A + b = \cup \{ A + b : b \in B \} \quad (3.05)$$

A dilatação é feita pela união dos pontos de A e B, em todas as posições de B, nas quais a sua origem está contida em A. A figura 10 ilustra a dilatação de uma figura A por um elemento estruturante linear B.

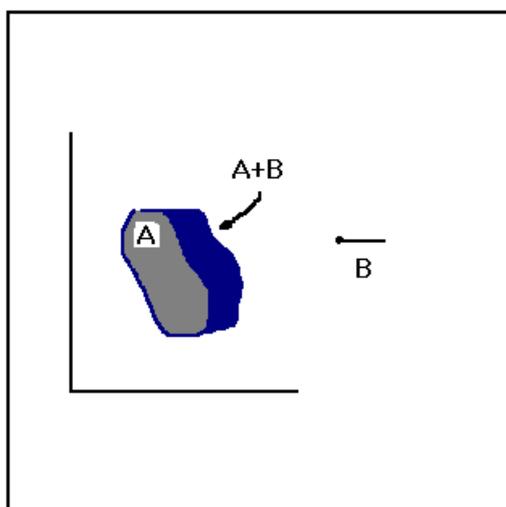


Figura 10. Dilatação da figura A pelo elemento estruturante B

3.3.3. ABERTURA

A abertura [2] é uma operação secundária, já que ela é resultante de uma operação de erosão seguida de uma operação de dilatação. A abertura de uma imagem A por uma imagem B é denotada por $A \circ B$ e é definida como:

$$A \circ B = (A - B) + B \quad (3.06)$$

$$A \circ B = \cup \{B + x : b + x \subset A\} \quad (3.07)$$

A abertura é obtida pela translação de um elemento estruturante ao longo da imagem. O elemento estruturante inspeciona a imagem original e elimina todas as subestruturas da mesma nas quais ele não possa ser completamente inscrito. O processo de abertura pode ser comparado a um processo de peneiração, no qual o elemento estruturante define o tamanho da malha da peneira e a sua forma. Dougherty exemplifica a propriedade de filtro determinada pela abertura de um retângulo por um disco (figura 11). Neste exemplo, a abertura atua como um filtro passa-baixas, pois ocorre a suavização das bordas do retângulo.

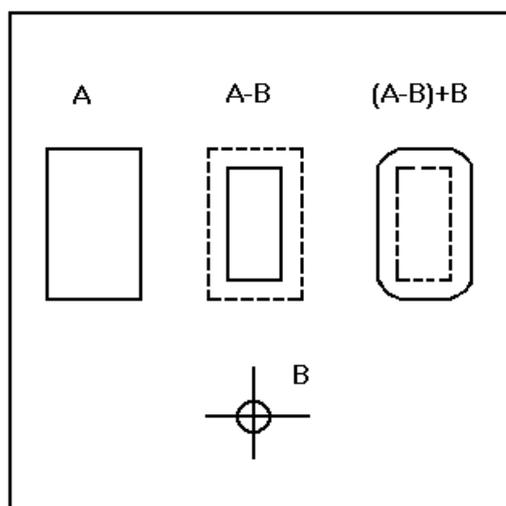


Figura 11. Abertura de um retângulo por um disco

3.4. GRANULOMETRIAS

O método granulométrico [5], ou simplesmente granulometria, oferece uma abordagem para quantificação da textura de uma imagem, e desta forma, a implementação deste atributo ao processo de classificação de imagens em ambiente de computador.

Nesta abordagem a textura da imagem é entendida como o resultado de um conjunto de partículas componentes, denominadas de "primitivas". As características texturais de uma imagem, ou de regiões de uma imagem, ficam definidas pelas dimensões e distribuição espacial das primitivas. Essa abordagem permite a modelagem estatística da textura abrindo a possibilidade de sua utilização em algoritmos para classificação de imagens.

3.4.1. AXIOMAS BÁSICOS DA GRANULOMETRIA

As técnicas de granulometria, conforme propostas por Matheron [12], foram desenvolvidas a partir de três axiomas básicos. Designamos por X o conjunto das primitivas (ou partículas) que compõe uma imagem, e por $T_\lambda(X)$ a transformação destinada a implementar a análise granulométrica. No caso específico desta dissertação $T_\lambda(X)$ representa a operação de "peneiração" da imagem após a abertura. Neste caso, o parâmetro T_λ representa a quantidade de partículas retidas para uma "peneira" de tamanho λ . $T_\lambda(X)$ representa, portanto, uma operação de natureza morfológica.

Os axiomas são os seguintes:

(1) $T_\lambda(X)$ é uma operação anti-extensiva, isto é, o conjunto transformado está incluído no conjunto inicial:

$$T_\lambda(X) \subset X \quad \forall \lambda > 0 \quad (3.08)$$

(2) $T_\lambda(X)$ é uma transformação monotonicamente crescente com X se $Y \subset X$, então:

$$T_\lambda(Y) \subset T_\lambda(X) \quad \forall \lambda > 0 \quad (3.09)$$

(3) O resultado da aplicação sucessiva de duas transformações $T_{\lambda_1}(X)$ e $T_{\lambda_2}(X)$ sobre um mesmo conjunto original X , é independente da seqüência com que as operações são aplicadas:

$$T_{\lambda_1}\left(T_{\lambda_2}(X)\right) = T_{\lambda_2}\left(T_{\lambda_1}(X)\right) = T_{(\lambda_1, \lambda_2)}(X) \quad \forall \lambda_1, \lambda_2 > 0 \quad (3.10)$$

Uma consequência deste terceiro axioma é a idempotência da transformação $T_{\lambda}(X)$. De fato, supondo $\lambda_1 = \lambda_2$ segue que:

$$T_{\lambda}\left(T_{\lambda}(X)\right) = T_{\lambda}(X) \quad (3.11)$$

3.4.2 GRANULOMETRIA EM NÚMERO E EM DIMENSÃO

A análise granulométrica [2] de um conjunto X de partículas (ou primitivas) pode ser feita utilizando como variável independente o parâmetro λ da transformação $T_{\lambda}(X)$ e como variável dependente o resultado da transformação. No caso específico do presente estudo, o conjunto X compreende as várias primitivas que compõe a textura da imagem. O parâmetro λ está associado à dispersão das primitivas e a transformação $T_{\lambda}(X)$ define uma variável (número, dimensão, etc...) associada às primitivas que compõe X .

$T_{\lambda}(X)$ pode ser analisado supondo duas abordagens distintas:

- o número de partículas ou primitivas resultantes da transformação para cada valor de λ (granulometria em número).
- a dimensão (peso, área, volume, etc...) das partículas ou primitivas resultantes para cada valor de λ (granulometria em dimensão).

Os resultados originados por cada um dos dois métodos não são idênticos. No primeiro caso (granulometria em número), à cada partícula ou primitiva é associado o mesmo valor ou peso, independente de suas características. No segundo caso, as

partículas são ponderadas em função de uma característica relevante, como área, volume, peso. A diferença entre os dois procedimentos está ilustrado na figura 12, na qual X é composto por partículas com dimensões distribuídas em três categorias (grande, média e pequena).

O processo de granulometria em número resulta em três barras idênticas associadas respectivamente aos três valores correspondentes de λ . Nenhuma distinção é feita quanto às características (exemplo: dimensão) das partículas envolvidas em cada transformação. Já no processo de granulometria em dimensão, a representação gráfica da figura 13 ilustra claramente a ponderação em função da área, resultando em valores distintos para cada transformação conforme o valor de λ .

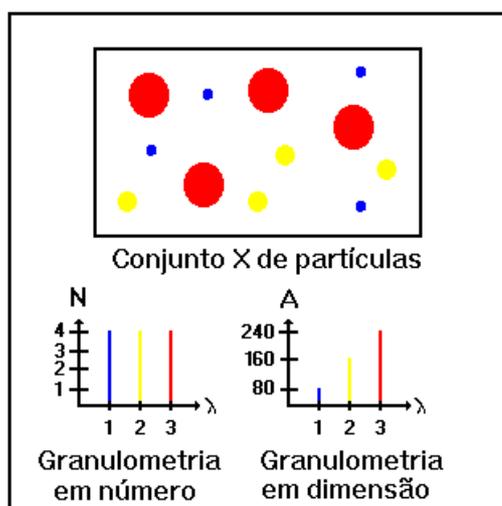


Figura 12. Exemplo de distribuição em número e em dimensão

3.4.3. REPRESENTAÇÃO NORMALIZADA DAS GRANULOMETRIAS

A distribuição do número de partículas, ou de sua dimensão, pode ser representada por uma função. Esta função deverá ser normalizada para que seja possível comparar as granulometrias realizadas em dois conjuntos (ou imagens) distintos. No exemplo da "peneiração" de primitivas texturais, define-se uma função de distribuição acumulada em

número $F(X, \lambda)$, ou simplesmente $F(\lambda)$. Este parâmetro é também conhecido como "Frequência Acumulada" e é dado por:

$$F(\lambda) = \frac{N(X) - N(T_\lambda(X))}{N(X)} \quad 0 < F(\lambda) < 1 \quad (3.12)$$

onde:

$N(T_\lambda(X))$ representa uma transformação aplicada a um conjunto X para um certo valor λ , e

$N(X)$ representa o número de primitivas de tamanho λ do conjunto inicial.

Para as granulometrias em medida, é definida uma função distribuição acumulada em medida $G(\lambda)$. Neste caso:

$$G(\lambda) = \frac{Mes(X) - Mes(T_\lambda(X))}{Mes(X)} \quad (3.13)$$

onde:

$Mes(X)$ representa variáveis como comprimento, área ou volume, conforme a dimensão em que se esteja trabalhando, e

$Mes(T_\lambda(X))$ é a transformação aplicada às variáveis expressas pelo conjunto X .

A função densidade no caso de granulometrias em número pode ser então definida por:

$$f(\lambda) = \frac{n(X, \lambda)}{N(X)} \quad (3.14)$$

$n(X, \lambda)$ é o número de partículas de tamanho λ e $N(X, \lambda)$ o número total de partículas.

Da mesma forma, pode-se escrever a função densidade para o processo de granulometria em dimensão, por:

$$g(\lambda) = \frac{a(X, \lambda)}{A(X)} \quad (3.15)$$

$a(X)$ representa a medida total das partículas associadas ao valor λ nas transformações e $A(X)$ a medida total associada as partículas no conjunto original X .

3.4.4. GRANULOMETRIAS POR ABERTURA

Existem diversas transformações que podem ser aplicadas a imagens, mas a abertura morfológica é a que melhor satisfaz as três regras deduzidas dos axiomas de Matheron [12], já que ela é ao mesmo tempo anti-extensiva, monotonicamente crescente e idempotente.

As granulometrias por abertura [12] são obtidas por elementos estruturantes que analisam a imagem obtendo informações de sua geometria e sua topologia. Um elemento estruturante em forma de cruz, por exemplo, permitirá que sejam identificadas e contadas todas as primitivas texturais que apresentem esta forma. Os elementos estruturantes devem ser convexos (superfícies fechadas) devido a exigência do terceiro axioma de Matheron, que pode ser reescrito para o caso específico de granulometrias por abertura como:

$$O^{\lambda_2 B}(O^{\lambda_1 B}(X)) = O^{\lambda_1 B}(O^{\lambda_2 B}(X)) \quad \forall \lambda_2 > \lambda_1 > 0 \quad (3.16)$$

O elemento estruturante no espaço R^1 é um segmento de reta. No espaço R^2 existe um grande número de possibilidades, escolhendo-se as geometrias mais simples e mais isotrópicas (círculos, hexágonos, octógonos ...).

A figura 13 ilustra a função distribuição acumulada ($G(\lambda)$) e a função densidade $g(\lambda)$ quando foi utilizado um elemento estruturante hexagonal.

$$G(\lambda) = \frac{A(X) - A(O^{\lambda B}(X))}{A(X)} \quad (3.17)$$

Função distribuição em medida

$$g(\lambda) = \frac{A(O^{\lambda B}(X))}{A(X)} \quad (3.18)$$

Função densidade de probabilidade em medida

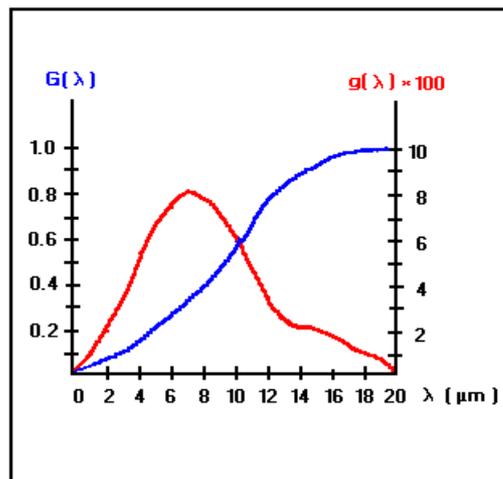


Figura 13. Funções distribuição e densidade granulométrica de um conjunto aberto por um elemento estruturante hexagonal

3.5. CLASSIFICAÇÃO TEXTURAL PELA MÁXIMA-VEROSSIMILHANÇA GAUSSIANA

A última etapa do processo, objeto desta dissertação, é a classificação de imagens utilizando atributos de textura [5]. O método de classificação empregado é o supervisionado, o qual se caracteriza pelos seguintes passos:

- Decisão sobre o número de classes texturais nas quais a imagem original será segmentada;
- Escolha dos conjuntos de *pixels* que serão representantes de cada classe. Estes *pixels* são denominados de "padrões de treinamento do algoritmo";
- Uso dos padrões de treinamento para estimar os parâmetros a serem utilizados pelo algoritmo de classificação; esses parâmetros definirão as funções decisão;
- Após o treinamento do classificador, classificar cada *pixel* da imagem em uma das classes texturais desejadas;
- Produzir uma tabela ou um mapa temático que sumarie o resultado da classificação.

3.5.1. FUNÇÃO DE DECISÃO

A função de decisão adotada é uma função de natureza probabilística [15] que permite classificar cada *pixel* na imagem, em uma das classes texturais presentes na mesma. Os atributos texturais estão distribuídos em bandas texturais, exatamente como os atributos espectrais nas bandas espectrais. Se as classes texturais de uma imagem forem representadas por ω_i $i = 1, \dots, M$, M sendo o número total de classes, então a função de decisão que irá determinar a que classe um *pixel* x pertence é definida como:

$$x \in \omega_i \text{ se } p(\omega_i | x) > p(\omega_j | x) \text{ para todo } j \neq i \quad (3.19)$$

Como a função decisão é uma função probabilística, o *pixel* em teste será classificado na classe para a qual ele apresentar a maior probabilidade de pertencer, como mostra o exemplo da figura 14.

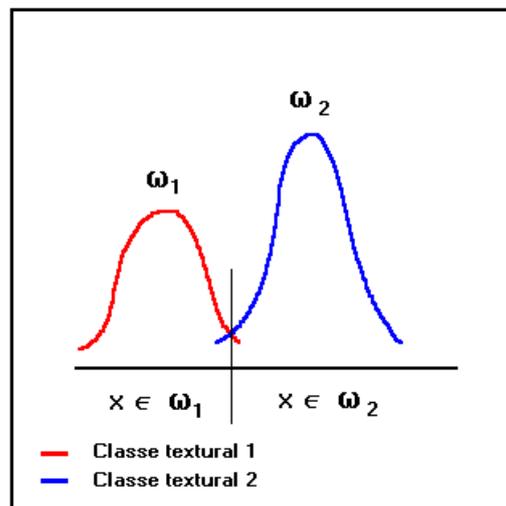


Figura 14. Funções de decisão para duas classes texturais

3.5.2. MÉTODO DA MÁXIMA-VEROSSIMILHANÇA

A função de decisão $p(\omega_i | x)$, também conhecida como "probabilidade a posteriori", tem um significado claro, mas geralmente não é conhecida. Esse problema pode ser superado com o auxílio do teorema de Bayes [15]:

$$D_i(x) = p(\omega_i | x) = \frac{p(x | \omega_i) \times p(\omega_i)}{p(x)} \quad (3.20)$$

sendo:

$p(\omega_i)$ probabilidade da ocorrência da classe ω_i (a priori)

$p(x|\omega_i)$ probabilidade da classe ω_i conter o *pixel* x

$p(x)$ probabilidade da ocorrência do *pixel* x

Havendo um número suficiente de padrões de treinamento para cada classe textural que se quer definir, estes padrões poderão ser utilizados para estimar a função de distribuição de probabilidade de se encontrar na classe ω_i um *pixel* localizado na posição x .

Assumindo que $p(\omega_i)$, a probabilidade de ocorrência das classes, é igual para todas as classes e considerando que $p(x)$ independe de ω_i , segue que $\frac{p(\omega_i)}{p(x)}$ é constante para todas as classes, podendo ser, portanto, eliminado da função decisão. Após estas considerações, a função decisão é a seguinte:

$$D_i(x) = p(x|\omega_i) \quad (3.21)$$

Resta definir a forma da função decisão $p(x|\omega_i)$ e estimar os parâmetros. Como em grande parte as variáveis são associadas a fenômenos naturais, pode-se fazer uso do Teorema Central do Limite para justificar a escolha da distribuição Normal. Essa suposição é igualmente confirmada na prática no problema de classificação de imagens.

Considerando-se que a função discriminante tem a forma da distribuição normal

multivariada, ela é dada por:

$$D_i(x) = p(x|\omega_i) = \frac{(2 \times \pi)^{\frac{-N}{2}}}{|\Sigma_i|^{\frac{1}{2}}} \times e^{\left\{-\frac{1}{2} \times (x - \mu_i)^t \times \Sigma_i^{-1} \times (x - \mu_i)\right\}} \quad (3.22)$$

A função decisão, após simplificações matemáticas, torna-se:

$$D_i(x) = -\lambda \ln |\Sigma_i| - (x - \mu_i)^t \times \Sigma_i^{-1} \times (x - \mu_i) \quad (3.23)$$

μ_i : média da amostra da classe ω_i ;

Σ_i : matriz de covariância dentro da classe textural i ;

x : padrão a ser classificado.

3.5.3. ESTIMAÇÃO DOS PARÂMETROS DA FUNÇÃO DISCRIMINANTE

Os parâmetros da função discriminante são estimados através de amostras das regiões texturais obtidas nas imagens. As bandas texturais são obtidas conforme os passos mostrados na figura 15, detalhados na seqüência:

- A imagem binária original é aberta por conjuntos de elementos estruturantes horizontais, verticais, diagonais esquerdos e diagonais direitos, cada conjunto apresentando elementos estruturantes com dimensões entre 2 e 7 *pixels*;
- São obtidas 24 imagens abertas, cada uma das quais definida por um tipo e por uma dimensão de elemento estruturante;

- As imagens abertas são exploradas por uma janela móvel. Para cada posição da janela móvel é calculado o número de *pixels* ativos no interior da mesma. O valor encontrado é atribuído à uma nova imagem na posição equivalente ao *pixel* central da janela na imagem aberta.

- A imagem binária original também é explorada pela janela móvel, originando uma imagem que servirá de base ao cálculo das distribuições de *pixels* ativos;

- Tomando-se o conjunto das 7 imagens de *pixels* ativos para cada tipo de elemento estruturante, obtém-se as distribuições de *pixels* ativos, uma para cada *pixel* das imagens de *pixels* ativos. Calcula-se a média e a variância de cada distribuição, obtendo-se duas novas imagens: uma imagem da média das distribuições de *pixels* ativos e outra das variâncias das distribuições de *pixels* ativos. São geradas, ao todo, 8 imagens, duas para cada tipo de elemento estruturante;

- Ao final do processo, são obtidas duas bandas texturais: a banda das médias e a banda das variâncias. A banda das médias resulta da média aritmética das quatro imagens das médias das distribuições de *pixels* ativos e a banda das variâncias, da média aritmética das quatro imagens das variâncias das distribuições de *pixels* ativos.

A utilização de elementos estruturantes com várias orientações faz com que o método proposto se adeque ao princípio da invariância frente à rotação da imagem (item 3.2.1).

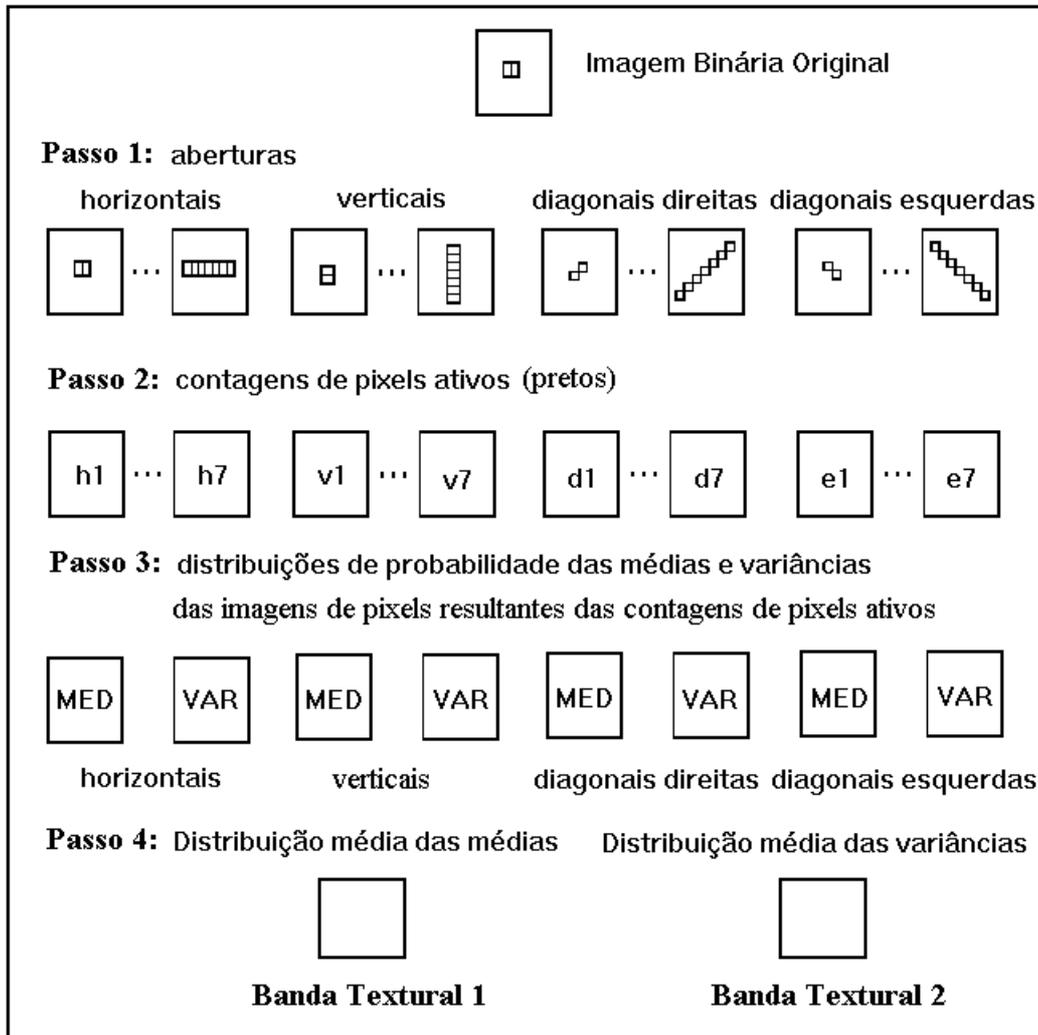


Figura 15. Obtenção das bandas texturais

Obtidas as bandas texturais, inicia-se a tomada de amostras nas mesmas. Segundo Swain e Davis [17], o tamanho das amostras não deve ser inferior a $10 \times N$, sendo N o número de bandas texturais. Um tamanho $100 \times N$ é considerado como ótimo para efeitos de classificação.

Os parâmetros são estimados da seguinte maneira:

- coletam-se amostras de uma determinada textura, com dimensão e localização idênticas, nas bandas texturais das médias e das variâncias;
- estima-se, para cada amostra, uma média amostral m_i e, para o conjunto das amostras, uma matriz de covariâncias:

$$m_i(x) = \begin{bmatrix} m_1 \\ m_2 \end{bmatrix} \text{ e } S_i;$$

- repete-se o processo para as outras classes texturais existentes na imagem.

Com a função discriminante devidamente treinada, ou seja, com os seus parâmetros estimados, inicia-se a etapa final de classificação. Nesta etapa, os *pixels* da banda textural das médias e das variâncias são tomados aos pares e substituídos em cada uma das funções discriminantes. O maior valor registrado pelas funções discriminantes indicará a qual classe textural o par de *pixels* pertence. O teste de todos os *pixels* das bandas texturais resultará em uma imagem temática das regiões texturais da imagem original.

3.6. BINARIZAÇÃO

A binarização é uma técnica utilizada para transformar uma imagem em cores, ou em tons de cinza, em uma imagem com apenas dois níveis de cinza: o preto e o branco. O processo de classificação textural de imagens, objeto desta dissertação, foi desenvolvido para ser aplicado em imagens binárias, tendo em vista que textura é uma característica associada à dimensão, forma e distribuição de primitivas texturais, e não pela resposta espectral (cor), que essas primitivas texturas apresentem. A utilização de imagens binarizadas também reduz o tempo computacional, pois simplifica a obtenção das

imagens na etapa de abertura morfológica.

Existem diversas técnicas de binarização, três das quais foram avaliadas neste trabalho: binarização pela média, binarização pela mediana e binarização pela análise de histograma. A escolha da técnica de binarização a ser utilizada em uma classificação textural é definida pelas características da imagem que se quer classificar. Se a imagem apresentar classes texturais com respostas espectrais semelhantes, a binarização pela média ou a binarização pela mediana devem ser empregadas para que as primitivas texturais sejam preservadas. A binarização pela análise de histograma deve ser empregada nos demais tipos de imagens.

3.6.1. BINARIZAÇÃO PELA MÉDIA

A binarização pela média, exemplificada na figura 16, é feita da seguinte maneira:

- Uma janela quadrada de binarização é aberta centrada em cada um dos *pixels* da imagem original;
- Calcula-se a média aritmética dos contadores digitais (níveis de cinza) no interior da janela de binarização;
- A média aritmética calculada no interior da janela de binarização irá determinar uma "região de aceitação". Essa região terá como limite inferior o valor da média calculada subtraída de um nível de limiar, e como limite superior, o valor da média acrescido do mesmo limiar;
- Se o valor do *pixel* central da janela situar-se no interior da região de aceitação, o *pixel* correspondente na imagem binária será "0", ou "preto";
- Se o valor do *pixel* central da janela cair fora da região de aceitação, o *pixel* correspondente na imagem binária terá um valor "255", ou "branco".

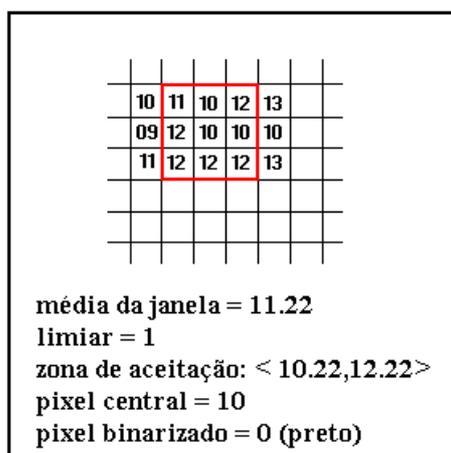


Figura 16. Exemplo de binarização pela média

3.6.2. BINARIZAÇÃO PELA MEDIANA

A técnica de binarização pela mediana tem as mesmas características da técnica de binarização pela média, sendo que o valor de comparação utilizado é a mediana do valor dos contadores digitais no interior da janela de binarização, e não a média aritmética dos mesmos.

3.6.3. BINARIZAÇÃO PELA ANÁLISE DE HISTOGRAMA

A binarização pela análise de histograma (figura 17), é feita da seguinte maneira:

- Gera-se um histograma da imagem original;
- A partir do histograma gerado, seleciona-se três valores de contadores digitais (CD1, CD2 e CD3), correspondentes a máximos locais no histograma, em torno dos quais haja um agrupamento de *pixels*. Os contadores digitais escolhidos devem apresentar a maior frequência dos contadores do agrupamento ao quais estiverem associados;
- Define-se, como na binarização pela média, três regiões de aceitação, cada uma

das quais centrada em um dos contadores digitais selecionados na etapa anterior. As regiões de aceitação serão definidas, em seus extremos inferiores, pela subtração de um valor de limiar de cada um dos contadores digitais selecionados, e em seus limites superiores, pela adição do valor de limiar aos contadores digitais;

- A binarização é feita pela comparação do contador digital de cada um dos *pixels* da imagem original com as regiões de aceitação definidas na etapa anterior. Se o contador digital estiver contido em uma das três regiões de aceitação, o *pixel* equivalente ao mesmo na imagem binária será levado a "0", ou "preto". Caindo fora das regiões de aceitação, ao *pixel* da imagem binária será atribuído o valor "255", ou "branco".

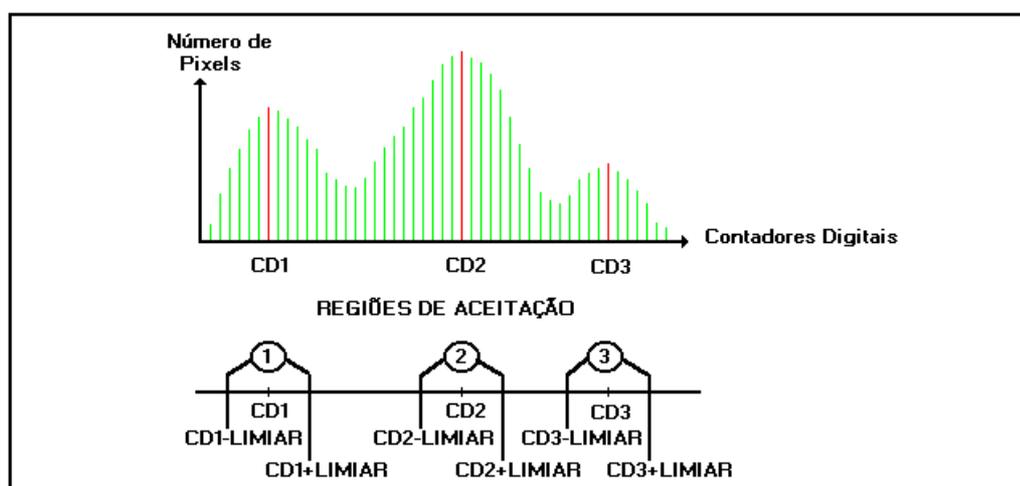


Figura 17. Binarização pela análise de histograma

CAPÍTULO 4

EXPERIMENTOS

O processo de classificação textural de imagens foi testado em imagens sintéticas e reais. O uso de imagens sintéticas permite determinar a exatidão do processo de classificação textural, tendo em vista que o resultado esperado da classificação é previamente conhecido. A aplicação do processo em imagens reais permite avaliar o comportamento da metodologia proposta quando aplicada a imagens de cenas materiais obtidas por sistemas de sensoriamento remoto.

4.1. IMAGEM SINTÉTICA

A imagem sintética foi idealizada com base nos experimentos de Dougherty [3], que utilizou imagens extraídas da coleção de Brodatz [1], uma coleção de padrões texturais digitalizados. Dougherty [5] limitou as imagens em 132 x 132 *pixels*, pois esta dimensão, além de ser suficiente para a obtenção das estatísticas necessárias ao processo de classificação textural, não exige um tempo de processamento muito elevado.

Seguindo os preceitos de Dougherty [5], gerou-se uma imagem sintética com as seguintes características:

- três regiões texturais diferenciadas (figura 18);
- textura 1: primitivas texturais em forma por retângulos com 3 *pixels* de largura e 6 *pixels* de altura;
- textura 2: primitivas texturais em forma de retângulos com 6 *pixels* de largura

por 5 *pixels* de altura;

- textura 3: primitivas com a forma de um "X", cada seção diagonal do "X" formada por um conjunto de 5 *pixels*;

- espaçamento entre primitivas inferior a 7 *pixels*;

- primitivas de uma região textural não são encontradas em nenhuma das outras regiões;

- imagem é binária (textura formada por primitivas em preto sobre um fundo branco);

- dimensão de 128 por 132 *pixels*.

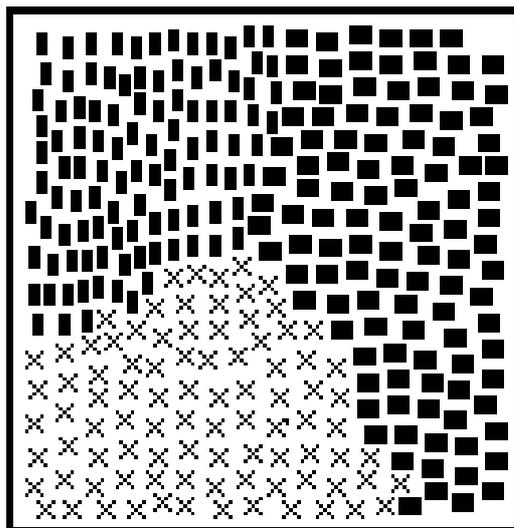


Figura 18. Imagem binária sintética

4.1.1. CLASSIFICAÇÃO TEXTURAL DA IMAGEM SINTÉTICA

O processo de classificação textural da imagem sintética da figura 18 foi desenvolvido conforme a seqüência mostrada no capítulo 3. A imagem binária é aberta por conjuntos de elementos estruturantes para a estimação da distribuição granulométrica da mesma. Após, é feita uma contagem dos *pixels* ativos nas imagens abertas, define-se uma função densidade de probabilidade em medida e, por fim,

classifica-se a imagem pelo método da máxima verossimilhança gaussiana.

4.1.1.1. GRANULOMETRIAS POR ABERTURAS

As imagens granulométricas são obtidas pelas aberturas da imagem sintética por quatro conjuntos de elementos estruturantes, cada um dos quais com uma dimensão variando entre 2 e 7 *pixels*. Assim, são geradas até 6 imagens para cada tipo de elemento estruturante, resultando em um máximo de 24 imagens granulométricas. Na figura 18 é mostrada a imagem sintética a ser classificada, na figura 19 os elementos estruturantes utilizados nas aberturas e nas figuras 20, 21, 22 e 23, as imagens granulométricas resultantes do processo.

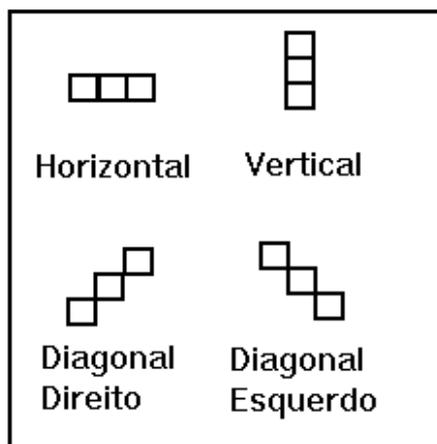


Figura 19. Elementos estruturantes utilizados na abertura da imagem real

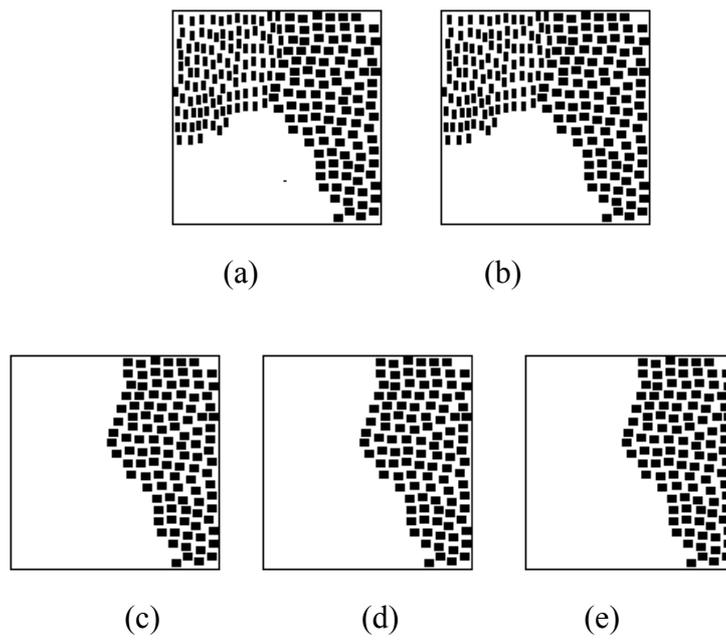


Figura 20. Granulometrias por abertura com elementos estruturantes horizontais de tamanhos (a) 2 (b) 3 (c) 4 (d) 5 e (e) 6

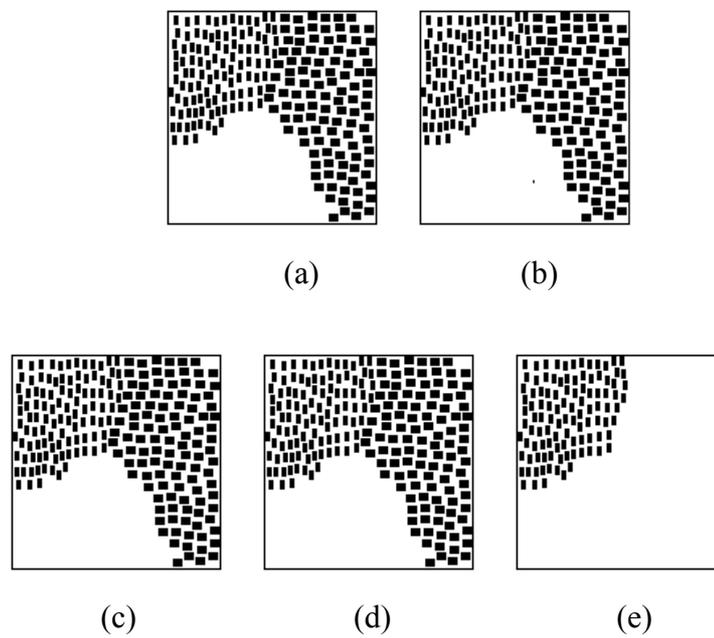


Figura 21. Granulometrias por abertura com elementos estruturantes verticais de tamanhos (a) 2 (b) 3 (c) 4 (d) 5 e (e) 6

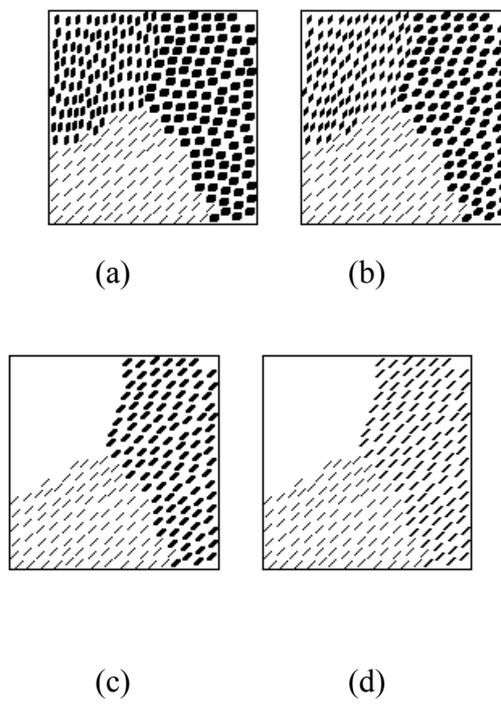


Figura 22. Granulometrias por abertura com elementos estruturantes diagonais direitos de tamanhos (a) 2 (b) 3 (c) 4 e (d) 5

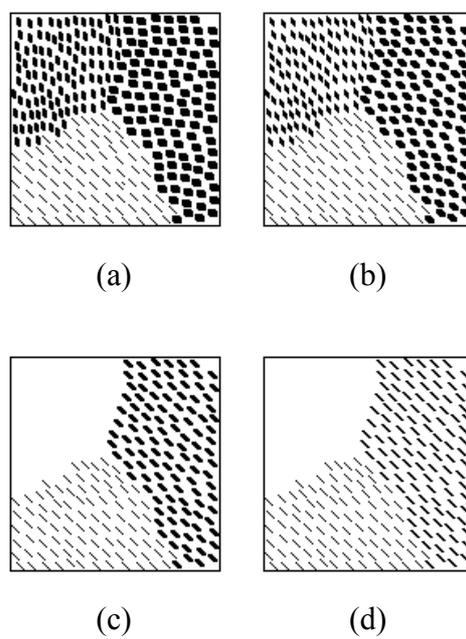


Figura 23. Granulometrias por abertura com elementos estruturantes diagonais esquerdos de tamanhos (a) 2 (b) 3 (c) 4 e (d) 5

4.1.1.2. ESTIMAÇÃO DOS PARÂMETROS NA DISTRIBUIÇÃO GRANULOMÉTRICA

A etapa seguinte consiste na organização dos dados relativos à distribuição granulométrica em cada região da imagem em formato *raster* semelhante ao das bandas espectrais convencionais. Como a distribuição granulométrica em uma imagem está relacionada com a textura, os dados assim obtidos passam a ser denominados de "bandas texturais". Como a textura é um atributo relativo à uma região da imagem, não a um ponto ou *pixel* individual, as características granulométricas são estimadas dentro da região compreendida por uma janela móvel e atribuídos ao *pixel* central. A medida que a janela móvel desloca-se sobre a imagem, assim vai sendo construída a banda textural.

Nesta pesquisa adotou-se uma janela de 7×7 *pixels*. Como parâmetros descritores da granulometria selecionou-se a média aritmética e a variância dos contadores digitais presentes no interior da janela. Esses valores estimados na região compreendida pela janela são atribuídos ao *pixel* central da mesma.

A figura 24 apresenta a banda textural das médias, resultante do cálculo da média das distribuições de *pixels* ativos e a figura 25, a banda textural das variâncias, resultante do cálculo da variância das distribuições de *pixels* ativos.

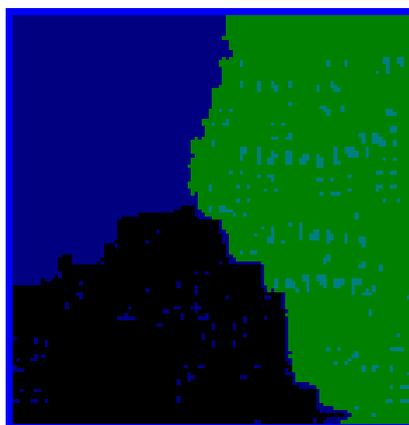


Figura 24. Banda textural das médias

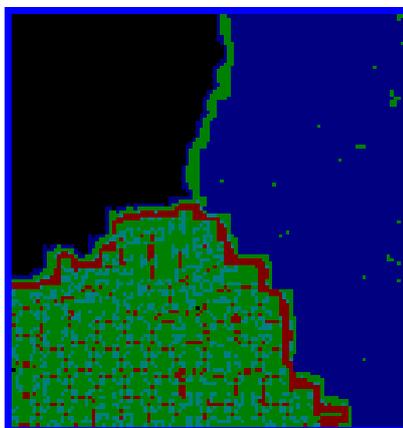


Figura 25. Banda textural das variâncias

4.1.1.3. CLASSIFICAÇÃO PELA MÁXIMA-VEROSSIMILHANÇA GAUSSIANA

A classificação textural pela máxima-verossimilhança gaussiana é feita com base nas duas bandas texturais geradas na etapa anterior. O método da máxima verossimilhança é utilizada nesta pesquisa no processo de classificação. Aqui é feita ainda a suposição da distribuição gaussiana em ambas as bandas texturais. Desta forma, a função decisão utilizada é a da máxima verossimilhança gaussiana. Nas bandas texturais são tomadas amostras com 169 elementos (janela amostral com 13 x 13 *pixels*). O resultado da classificação textural é mostrado na figura 26.

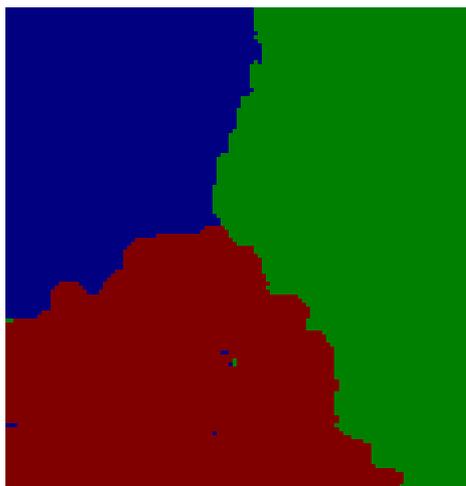


Figura 26. Imagem sintética classificada texturalmente

4.2. IMAGEM REAL

O procedimento final dos experimentos é a classificação textural de uma imagem real. A imagem real foi extraída de uma fotografia aérea de uma região pertencente à província de Córdoba, República Argentina, e apresenta as seguintes características:

- três regiões com textura fina, média e grosseira;
- duas regiões texturais com respostas espectrais semelhantes;
- dimensão de 108 *pixels* verticais por 198 *pixels* horizontais;
- 256 níveis de cinza;
- 1 *pixel* na imagem representa uma área de 10 x 10 m no solo.

A figura 27 apresenta a imagem original, a figura 28 os diferentes tipos de alvos presentes na imagem e a figura 29 a localização geográfica da área em estudo.



Figura 27. Imagem textural real

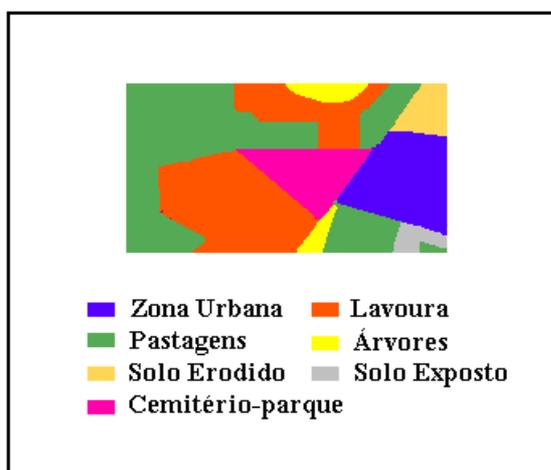


Figura 28. Alvos presentes na imagem real



Figura 29. Localização geográfica da região em estudo

4.2.1. CLASSIFICAÇÃO TEXTURAL DA IMAGEM REAL

A classificação da imagem real com base em seus atributos texturais apresenta uma única diferença em relação à classificação da imagem sintética: a imagem real deve ser binarizada, já que o processo morfológico foi desenvolvido para ser aplicado em imagens binárias.

4.2.1.1. BINARIZAÇÃO

A imagem real, por apresentar regiões texturais com respostas espectrais semelhantes, foi binarizada pela técnica de binarização pela média aritmética. Foi utilizada uma janela de binarização de 7×7 pixels e um valor de limiar de 7 pixels em torno da média, resultando na imagem da figura 30



Figura 30. Imagem real binarizada

4.2.1.2. GRANULOMETRIAS POR ABERTURAS DA IMAGEM REAL

As granulometrias da imagem real foram obtidas, como na imagem sintética, através de aberturas morfológicas sucessivas com elementos estruturantes horizontais, verticais, diagonais direitos e diagonais esquerdos. O resultado das granulometrias da imagem real são mostradas nas figuras 31, 32, 33 e 34.

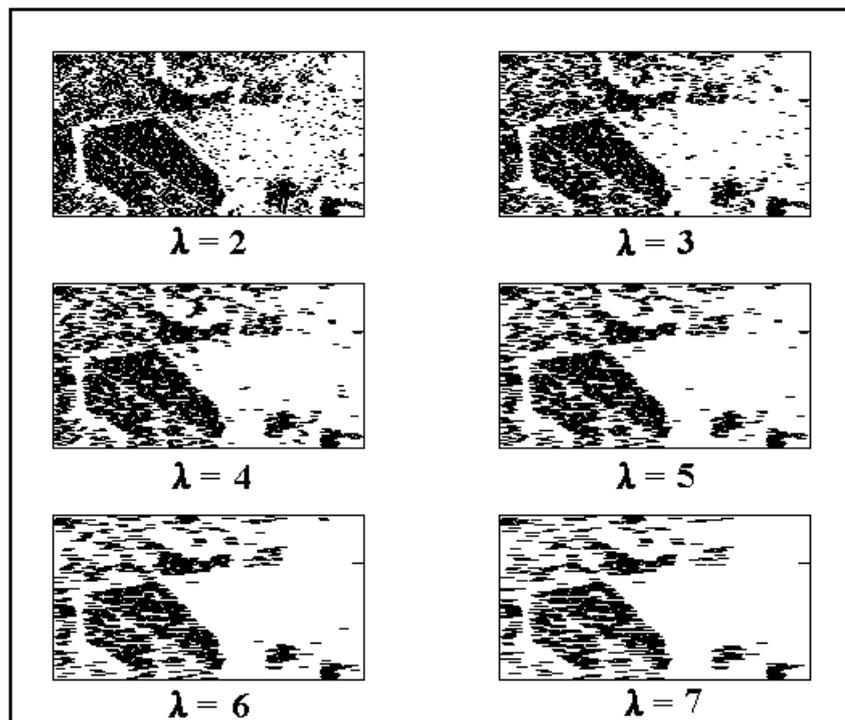


Figura 31. Granulometrias com elementos estruturantes horizontais

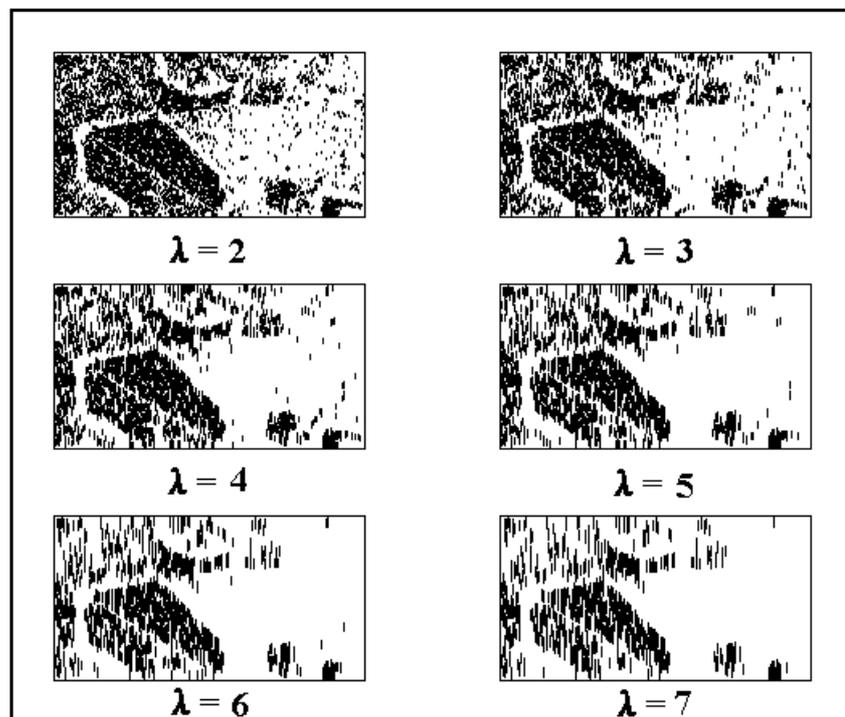


Figura 32. Granulometrias com elementos estruturantes verticais

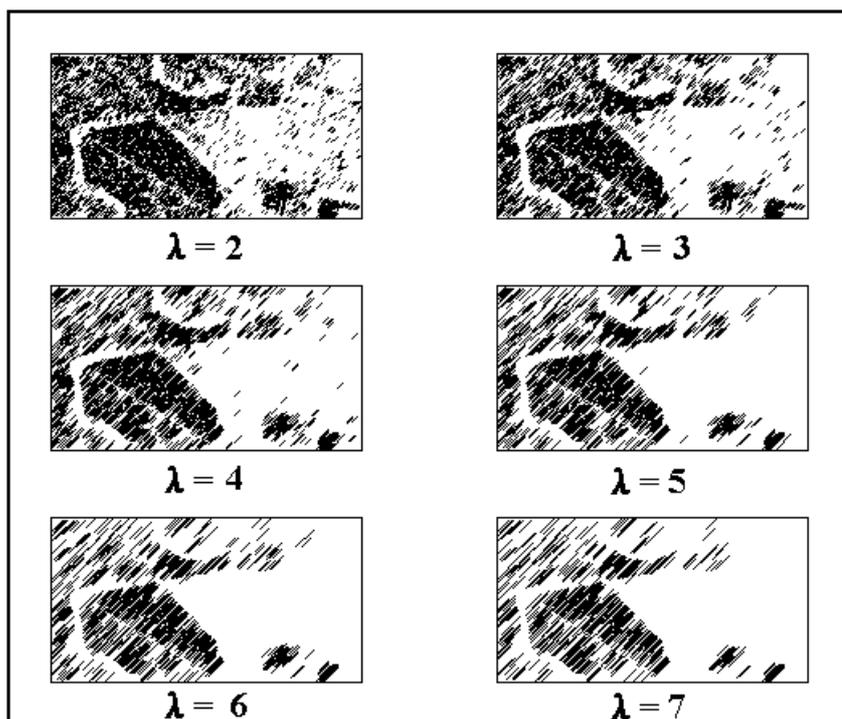


Figura 33. Granulometrias com elementos estruturantes diagonais direitos

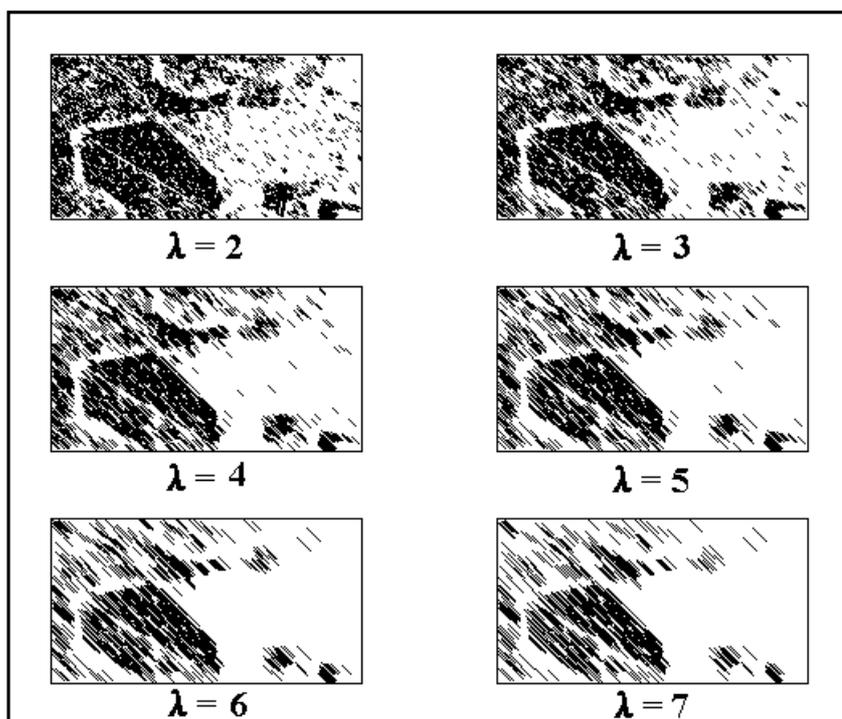


Figura 34. Granulometrias com elementos estruturantes diagonais esquerdos

4.2.1.3. CLASSIFICAÇÃO TEXTURAL DA IMAGEM REAL

A classificação da imagem real é feita com a utilização das bandas texturais das figuras 35 e 36 resultantes do processo. As bandas texturais foram obtidas com a contagem de *pixels* ativos nas imagens granulométricas em janelas de 9×9 *pixels*.

A figura 37 mostra a classificação textural da imagem real. Para tal, foram colhidas amostras nas bandas texturais cada uma das quais com 169 elementos. Para um nível de significância de 5 % não houve incidência de não-classe na classificação.

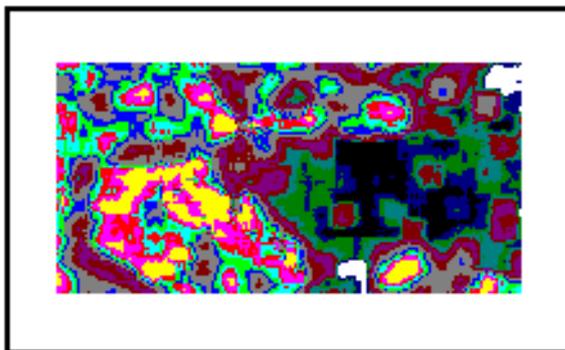


Figura 35. Banda textural das médias

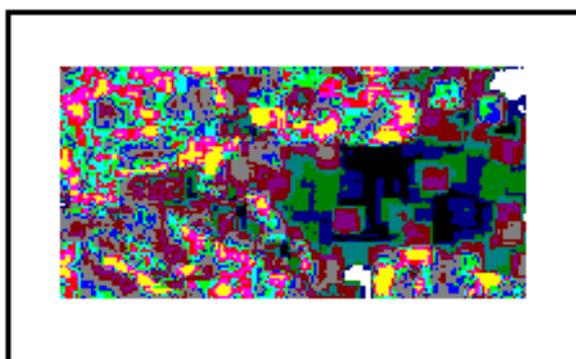


Figura 36. Banda textural das variâncias

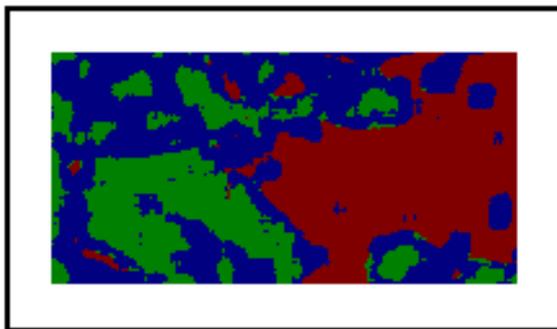


Figura 37. Imagem real classificada

CAPÍTULO 5

RESULTADOS E CONCLUSÕES

Os resultados do processo de classificação textural são obtidos tomando-se como base os seguintes itens:

- classificação visual da imagem real;
- análise das classes texturais;
- análise do processo de binarização;
- análise das bandas texturais;
- influência da resolução espacial no processo de classificação;
- comparação entre classificação visual e classificação pelo processo textural.

5.1. CLASSIFICAÇÃO VISUAL DA IMAGEM REAL

A imagem real foi inicialmente submetida a um processo de classificação visual, para ser utilizada como referência. Esta classificação foi desenvolvida por um especialista em fotointerpretação e conhecedor da área compreendida na imagem.

A classificação visual da imagem real é mostrada na figura 38.

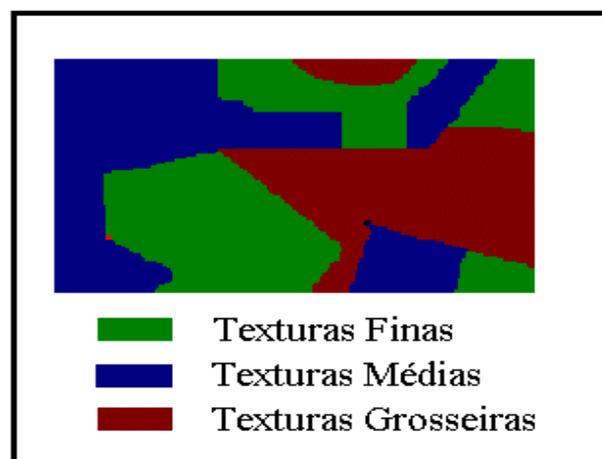


Figura 38. Classificação visual da imagem real

5.2. ANÁLISE VISUAL DAS CLASSES TEXTURAIS

A classificação visual de uma imagem baseia-se em dois fatores: o conhecimento de campo do fotointérprete e a maneira como a resposta espectral varia na região estudada. Com estes pressupostos, a imagem real foi classificada em três classes texturais: na classe 1, a de texturas finas, foram incluídos os alvos lavoura, solo exposto e solo erodido, na classe 2, a de texturas médias, o alvo pastagem, e na classe 3, a de texturas grosseiras, os alvos cemitério-parque, árvores e zona urbana.

Os alvos classificados como textura fina têm um comportamento espectral homogêneo, sendo inexpressiva a variação nos níveis dos contadores digitais nestas regiões. O alvo solo exposto tipifica a textura fina, pois a presença de uma única espécie de componente, o próprio tipo de solo, faz com que não ocorram variações espectrais significativas.

Os alvos da classe de textura grosseira têm características espectrais heterogêneas. Esta característica espectral é marcante no alvo cidade, pelo contraste entre as áreas edificadas e as vias públicas, no alvo cemitério-parque, entre as lápides e a área verde que as envolve, e no alvo árvores, entre a copa das mesmas e o solo onde elas se encontram.

O alvo pastagem, incluído na classe de textura média, foi assim classificado por apresentar uma variação espectral intermediária entre os alvos de textura fina e de textura grosseira.

5.3. ANÁLISE DO PROCESSO DE BINARIZAÇÃO

O processo de binarização é muito importante para o sucesso da classificação de uma imagem pelos seus atributos texturais. Para analisar a eficiência da binarização é feito um confronto entre a imagem real e a imagem binarizada, verificando se a textura de cada uma das regiões foi capturada corretamente. Regiões com textura fina devem

apresentar primitivas texturais grandes e pouco espaçadas, enquanto que nas regiões de textura grosseira as primitivas deverão ser pequenas e espaçadas. Espaçamento grande ou pequeno é sempre em relação ao tamanho dos elementos estruturantes utilizados na etapa seguinte do processo, a abertura morfológica.

A figura 39 apresenta uma análise comparativa entre a imagem real e a imagem binarizada para os tipos de textura fina, média e grosseira. Pela análise, verifica-se que o processo de binarização empregado é adequado, pois captura eficientemente as primitivas da imagem original.

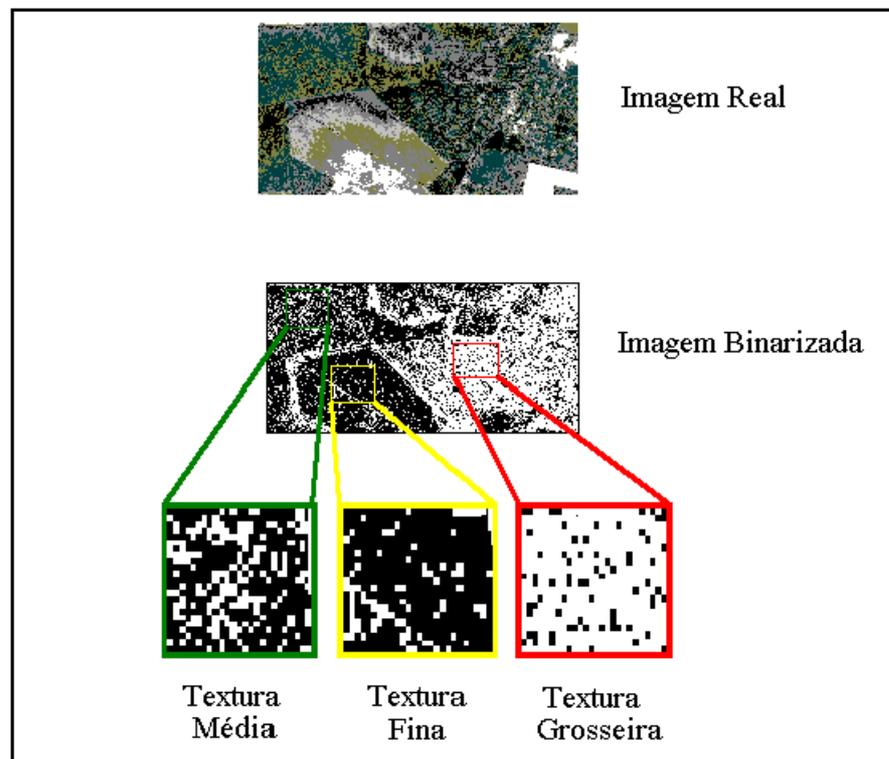


Figura 39. Análise do processo de binarização

5.4. ANÁLISE DAS BANDAS TEXTURAIS

O processo de classificação textural gera duas bandas texturais, médias e variâncias, que servirão de base à classificação final pela máxima-verossimilhança gaussiana. A análise a ser feita nesta etapa é o valor da média aritmética dos contadores digitais contidos em uma determinada janela, para cada tipo de textura e banda textural. A textura fina será indicada como "textura 1", a textura média, como "textura 2", e a textura grosseira, como "textura 3".

Janela: 5 x 5 *pixels*

Textura 1 / Banda 1 : 158,04

Textura 2 / Banda 1 : 175,24

Textura 3 / Banda 1 : 94,68

Textura 1 / Banda 2 : 146,68

Textura 2 / Banda 2 : 167,68

Textura 3 / Banda 2 : 84,44

Analisando os resultados, verifica-se que há uma separação estatística suficiente entre as médias aritméticas calculadas, permitindo, desta forma, a utilização do classificador de máxima-verossimilhança para determinar os tipos de textura existentes na imagem.

5.5. INFLUÊNCIA DA RESOLUÇÃO ESPACIAL NO PROCESSO DE CLASSIFICAÇÃO

A resolução espacial é outro fator importante a ser considerado na análise dos resultados da classificação textural. A textura é uma sensação visual causada por uma variação tonal associada a uma certa região do espaço. Se os intervalos em que esta variação tonal ocorrer forem inferiores a resolução dos sensores do satélite, ou do

sistema que estiver colhendo as informações, o resultado é que o processo de classificação textural classificará em uma mesma classe todas as texturas inferiores à resolução espacial que se estiver trabalhando, ou seja, texturas distintas receberão a mesma avaliação pelo processo.

Os sistemas sensores orbitais apresentam uma resolução espacial, na atual etapa de desenvolvimento, na ordem de 10 m, e as fotografias aéreas permitem resoluções espaciais de 1 m. Com estas limitações, certas classes que ocorrem em cenas naturais e são de interesse prático, como algumas culturas agrícolas, por exemplo, não podem ser identificadas pelo processo de classificação textural.

5.6. COMPARAÇÃO ENTRE CLASSIFICAÇÃO VISUAL E PROCESSO DE CLASSIFICAÇÃO TEXTURAL

O resultado final do processo de classificação textural é obtido pela comparação entre a classificação textural e a classificação visual, admitindo-se que a classificação visual encontra-se isenta de erros. Com este procedimento, pode-se definir a matriz de contingência da figura 40, a qual apresenta, na diagonal principal, o número e o percentual de *pixels* classificados corretamente em cada classe, e nas demais posições, o número e o percentual de *pixels* incorretamente classificados. A matriz de contingência também indica o tipos de erros ocorridos na classificação. Assim, analisando a primeira linha da matriz constata-se que a imagem classificada pelo processo textural apresenta, na classe azul, 4052 *pixels* coincidentes com a classificação visual, 22 *pixels* da classe azul classificados na classe verde e 628 *pixels* da classe azul classificados na classe vermelha. Os percentuais sob os números da matriz indicam o acerto ou erro na classificação em relação ao número de *pixels* de cada classe.

		Processo Textural		
		1 Azul	2 Verde	3 Vermelho
Interpretação Visual	1 Azul	4052 86.17%	22 0.47%	628 13.36%
	2 Verde	766 12.59%	2662 43.75%	2656 43.66%
	3 Vermelho	613 11.33%	1259 23.25%	3542 65.42%

Figura 40. Matriz de contingência da classificação visual x classificação computacional

5.7. CONCLUSÕES

Analisando os resultados obtidos com o processo de classificação textural apresentado neste trabalho, conclui-se que a classificação não alcançou índices elevados de acerto em todas as classes em face dos seguintes motivos :

- o processo textural limitou o número de classes em três, agregando outras possíveis classes texturais existentes na imagem, em uma das classes trabalhadas;
- a classificação visual, considerada como padrão de comparação para avaliar os resultados da metodologia proposta, pode não ter distinguido pequenas variações texturais comuns a uma cena natural. Ainda o fotointérprete utiliza, no processo de classificação visual, outros atributos além de textura, o que resulta em uma classificação distinta daquela que se obtém somente utilizando a textura;
- o processo de classificação permite classificar, em função da resolução espacial da imagem e da dimensão dos elementos estruturantes, padrões texturais com primitivas cujas dimensões sejam superiores a 2 m e inferiores a 14 m. Quaisquer primitivas com dimensões fora desses intervalos são irrelevantes à classificação;

- a binarização determina a perda de algumas primitivas texturais da imagem;
- os atributos espectrais não foram utilizados na classificação, prejudicando a classificação nas classes aonde esse atributo era dominante.

A presente dissertação não visa a esgotar o assunto sobre classificação textural utilizando conceitos de morfologia matemática, mas sim, a dar uma referência inicial a futuros pesquisadores que venham a ingressar neste interessante tema. Para estes, algumas sugestões:

- estudar diferentes tipos de binarização e os seus efeitos nas imagens classificadas;
- empregar outros tipos de elementos estruturantes;
- adicionar bandas espectrais na classificação;
- fazer um detalhado estudo de campo da região a ser classificada.

BIBLIOGRAFIA

- [1] Brodatz, P., "Texture: A Photographic Album for Artists and Designers," Dover, New York, 1966.
- [2] Coster, M., Chermant, J. L., "Précis D'Analyse D'Images," Edições do CNRS, França, 1989.
- [3] Dougherty, E., "An Introduction to Morphological Image Processing," SPIE, 1992.
- [4] Dougherty, E., e Giardina, C., "Image Processing--Continuous to Discrete," Prentice-Hall, New Jersey, 1987.
- [5] Dougherty, E., Pelz, J., and Newell, J., "Morphological Texture-Based Maximum-Likelihood Pixel Classification Based on Local Granulometric Moments," Pattern Recognition, Vol. 25, 1992.
- [6] Gramenopoulos, N., "Terrain Type Recognition Using ERTS-1 MSS Images," NASA, 1973.
- [7] Haralick, R., Bosley, R., "Texture Features for Image Classification," Third ERTS Symp., NASA, 1973.
- [8] Haralick, R., "Statistical and Structural Approaches to Texture," Proceedings of the IEEE, Vol. 67, 1979.
- [9] Kaizer, H., "A Quantification of Aerial Photographs," Boston University Research Laboratories, Boston University, Note 121, 1955.
- [10] Kirvidä, L., e Johnson, G., "Automatic Interpretation of ERTS Data for Forest Management", NASA, 1973.
- [11] Lendaris, G., e Stanley, G., "Diffraction Pattern Sampling for Automatic Pattern Recognition," SPIE Pattern Recognition Studies Seminar Proc, 1969.

- [12] Matheron, G., "Elements pour Une Theorie des Milieux Poreux," Masson, 1967.
- [13] Matheron, G., "Random Sets and Integral Geometry," Wiley, New York, 1983.
- [14] O'Neil, E., "Spatial Filtering in Optics," IRE, Vol2, 1956.
- [15] Richards, J., "Remote Sensing Digital Image Analysis," London, 1986.
- [16] Serra, J., "Image Analysis and Mathematical Morphology," Academic Press, New York, 1983.
- [17] Swain, P., e Davis, S., "Remote Sensing: The Quantitative Approach," McGraw-Hill.

TEXTURAS DE IMAGENS UTILIZANDO CONCEITOS DE MORFOLOGIA
MATEMÁTICA

LUÍS OTÁVIO THOMPSON CLARO