

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
CENTRO ESTADUAL DE PESQUISA EM SENSORIAMENTO REMOTO  
E METEOROLOGIA - CEPSRM  
CURSO DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**APLICAÇÃO DE FILTROS DE GABOR NO PROCESSO DE CLASSIFICAÇÃO DE  
IMAGENS DIGITAIS COM BASE EM ATRIBUTOS DE TEXTURA**

Por

**NEIDE PIZZOLATO ANGELO**

Porto Alegre, RS  
Janeiro de 2000

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
CENTRO ESTADUAL DE PESQUISA EM SENSORIAMENTO REMOTO  
E METEOROLOGIA - CEPSRM  
CURSO DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**APLICAÇÃO DE FILTROS DE GABOR NO PROCESSO DE CLASSIFICAÇÃO  
DE IMAGENS DIGITAIS COM BASE EM ATRIBUTOS DE TEXTURA**

**NEIDE PIZZOLATO ANGELO**

Bacharel em Matemática Aplicada e Computacional

Orientador : Prof. Dr. Vitor F. A. Haertel

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em Sensoriamento Remoto, área de concentração classificação digital de imagens.

Porto Alegre, RS  
Janeiro de 2000

Angelo, Neide Pizzolato

**Aplicação de Filtros de Gabor no  
Processo de Classificação de Imagens  
Digitais com Base em Atributos de Textura.**

Neide Pizzolato Angelo - Porto  
Alegre: UFRGS, 2000, 137 páginas.

Dissertação (Mestrado) - Universidade  
Federal do Rio Grande do Sul. Centro  
Estadual de Pesquisa em Sensoriamento  
Remoto e Meteorologia - Área de  
Classificação Digital de Imagens. Porto  
Alegre, 2000.

1. Textura
2. Filtro de Gabor
3. Sensoriamento Remoto

PÓSTUMAS

Ao meu querido avô Ernesto Pinheiro Angelo.

Ao Meu querido padrinho Zaluar Soares de Aquino.

## **AGRADECIMENTOS**

Gostaria de agradecer e dedicar este trabalho a todos que de alguma forma contribuíram para sua realização. Assim, agradeço:

Ao meu amigo e orientador Prof. Dr. Vitor Haertel pelo companheirismo, modelo de postura ética, profissional e pelo empréstimo de seu conhecimento técnico que possibilitou a confecção deste trabalho.

Aos Professores do Curso de Pós-Graduação do Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia, em especial aos professores Jorge Ducati, Robin T. Clark pelos ensinamentos, e pela constante disponibilidade em auxiliar, subsídios importantes na realização deste estudo.

Aos funcionários do CEP SRM: Laurindo, Madalena, Mônica, Rafael, Luciane, Fausta e Adriano, que sempre estiveram prontos a ajudar durante todo o tempo em que privei do seu convívio neste centro.

Aos meus vários colegas de Mestrado por sua amizade e carinho ao longo desse período de trabalho.

A Ana Gutierrez "Aninha" e Leonel Schardong pelo carinho, amizade e contribuição nas revisões do texto e da bibliografia.

A todos os amigos e amigas que de uma forma ou outra contribuíram para a conclusão deste trabalho.

A uma querida amiga e colega, Viviane Todt, pelo companheirismo durante o curso e amizade incondicional que

tem demonstrado sempre e da qual sou muito orgulhoso e grato.

A toda minha família, em especial aos meus pais, Ernesto e Nelly; minha avó, Ámalia; meus irmãos, Flavio e Moacir; que sempre me auxiliaram e apoiaram nesta jornada.

Aos familiares de minha esposa, especialmente, a meus sogros, Rui e Ivalina, com quem sempre contei com apoio irrestrito e carinho filial.

À minha querida esposa Dinara pelo amor, dedicação, apoio, carinho, paciência e abnegação durante a elaboração dessa dissertação.

Ao meu amado filho, William, pela alegria que sua presença trouxe a minha vida e que foi transferida a este trabalho.

E, finalmente, ao Grande Arquiteto do Universo (Deus), onde sempre me apoiei para executar mais esta obra em minha vida.

Também gostaria de Agradecer :

Ao CNPq pelo apoio financeiro durante a realização deste estudo.

# Application of Gabor Filters in the Digital Image Classification Process based in Texture Attributes<sup>2</sup>

Author: Neide Pizzolato Angelo

Advisor: Prof. Dr. Vitor F. A. Haertel

## ABSTRACT

Image texture can be an important source of data in the image classification processes. Although not as easily identifiable as the image spectral attributes, texture as proved in a number of cases to be a valuable source of data capable of increasing the accuracy of the resulting classified image.

The aim of this research work is to develop and test a supervised image classification method based on the image spatial texture attribute. The proposed methodology implements the image filtering procedure based on the Gabor filters concept. A set of Gabor filters is generated for any given image data. The filter parameters related to the spatial frequency are estimated from the available samples via the Fourier transform. Each filter then generates one filtered image, which characterizes the particular spatial frequency implemented on the filter. As a result of this procedure, a number of filtered images, sometimes referred to as "textural bands" are generated and the originally univariate problem is transformed into a multivariate one, every pixel being defined by a vector which dimensionality is identical to the number of filters used.

The multi-dimensional image data can then be classified by implementing any supervised classifier. In this work, the Gaussian Maximum Likelihood classifier is used.

The proposed methodology is tested using both synthetic and real image data. Results are presented and analyzed.

---

<sup>2</sup> Master of Science Thesis, Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia, Graduate Course in Remote Sensing and Meteorology, Universidade Federal do Rio Grande do Sul, Porto Alegre, (137 p.), January, 2000.

# **Aplicação de Filtros de Gabor no Processo de Classificação de Imagens Digitais com Base em Atributos de Textura <sup>1</sup>**

Autor : Neide Pizzolato Angelo  
Orientador : Prof. Dr. Vitor F. A. Haertel

## **SINOPSE**

No processo de classificação de uma imagem digital, o atributo textura pode ser uma fonte importante de informações. Embora o processo de caracterização da textura em uma imagem seja mais difícil, se comparado ao processo de caracterização de atributos espectrais, sabe-se que o emprego daquele atributo pode aumentar significativamente a exatidão na classificação da imagem.

O objetivo deste trabalho de pesquisa consiste em desenvolver e testar um método de classificação supervisionado em imagens digitais com base em atributos de textura. O método proposto implementa um processo de filtragem baseado nos filtros de Gabor. Inicialmente, é gerado um conjunto de filtros de Gabor adequados às frequências espaciais associadas às diferentes classes presentes na imagem a ser classificada. Em cada caso, os parâmetros utilizados por cada filtro são estimados a partir das amostras disponíveis, empregando-se a transformada de Fourier. Cada filtro gera, então, uma imagem filtrada que quantifica a frequência espacial definida no filtro. Este processo resulta em um certo número de imagens filtradas, as quais são denominadas de "bandas texturais". Desta forma, o problema que era originalmente unidimensional passa a ser multi-dimensional, em que cada pixel passa a ser definido por um vetor cuja dimensionalidade é idêntica ao número de filtros utilizados.

A imagem em várias "bandas texturais" pode ser classificada utilizando-se um método de classificação supervisionada. No presente trabalho foi utilizada a Máxima Verossimilhança Gaussiana.

A metodologia proposta é então testada, utilizando-se imagens sintéticas e real. Os resultados obtidos são apresentados e analisados.

---

<sup>1</sup> Dissertação de Mestrado em Sensoriamento Remoto, Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia, Curso de Pós-Graduação em Sensoriamento Remoto e Meteorologia da Universidade Federal do Rio Grande do Sul. Porto Alegre, (137 p.), janeiro de 2000.



## SUMÁRIO

LISTA DE TABELAS.....	x
LISTA DE FIGURAS.....	xii
LISTA DE APÊNDICES.....	xxiv
LISTA DE ABREVIATURAS.....	xxv
LISTA DE SÍMBOLO.....	xxvi
LISTA DE FÓRMULAS.....	xxvii
<b>1. INTRODUÇÃO.....</b>	<b>1</b>
<b>2. REVISÃO BIBLIOGRÁFICA.....</b>	<b>8</b>
2.1. INTRODUÇÃO.....	8
2.2. TÉCNICAS ESTATÍSTICAS.....	8
2.2.1. FUNÇÃO DE AUTO-CORRELAÇÃO .....	9
2.2.2. PROCESSAMENTO ÓTICO.....	10
2.2.3. MÉTODO DE TRANSFORMADA DIGITAL.....	11
2.2.4. MÉTODO DE DENSIDADE DE ARESTA.....	11
2.2.5. MORFOLOGIA MATEMÁTICA.....	12
2.2.6. MATRIZ DE CO-OCORRÊNCIA.....	13
2.2.7. COMPRIMENTO DAS CORRIDAS DE PIXEL COM IGUAL INTENSIDADE.....	14
2.3. TÉCNICAS DE REDES NEURAIS.....	14
2.4. TÉCNICAS DE FILTRAGEM EM MULTICANAIS TEXTURAS... ..	18
2.6. MÉTODO DE DIMENSÃO FRACTAL.....	23
<b>3. MATERIAL E MÉTODOS.....</b>	<b>25</b>
3.1. TEXTURA.....	26
3.2. TRANSFORMADA DE FOURIER.....	30
3.2.1. DEFINIÇÃO DA TRANSFORMADA DE FOURIER.....	30
3.2.2. TRANSFORMADA DISCRETA DE FOURIER.....	32
3.3. EXTRAÇÃO DE FEIÇÕES EM MULTICANAIS TEXTURAS E FILTROS DE GABOR.....	33
3.4. DEFINIÇÃO DOS FILTROS DE GABOR EM UMA IMAGEM DIGI- TAL.....	40
3.5. ESCOLHA DA FREQUÊNCIA ESPACIAL DO FILTRO.....	45
3.6. ESCOLHA DA DIMENSÃO E EXTENSÃO ESPACIAL DO FILTRO.....	47
3.7. CLASSIFICAÇÃO DE IMAGEM COM BANCO DE FILTROS DE GABOR NO DOMÍNIO ESPACIAL.....	52
<b>4. EXPERIMENTOS.....</b>	<b>54</b>
4.1-INTRODUÇÃO.....	54
4.2- EXPERIMENTOS ENVOLVENDO IMAGENS SINTÉTICAS.....	56
4.2.1 SINAL UNIDIMENSIONAL.....	56
4.2.1.1 EXPERIMENTO 1.....	56
4.2.1.2 EXPERIMENTO 2.....	59
4.2.2 IMAGEM SINTÉTICA DE FREQUÊNCIA ÚNICA POR CLASSE.....	63
4.2.2.1. EXPERIMENTO 1.....	63

4.2.2.2. EXPERIMENTO 2	65
4.2.2.3. EXPERIMENTO 3	67
4.2.3. IMAGEM SINTÉTICA FORMADA POR UM MOSAICO DE TEXTURA REAL.....	69
4.2.3.1. EXPERIMENTO 1	74
4.2.3.2. EXPERIMENTO 2	77
4.2.3.3. EXPERIMENTO 3	80
4.2.3.4. EXPERIMENTO 4	82
4.2.3.5. EXPERIMENTO 5	85
4.2.3.6. EXPERIMENTO 6	88
4.3. EXPERIMENTO ENVOLVENDO IMAGENS REAIS	92
4.3.1. EXPERIMENTO 1	102
4.3.2. EXPERIMENTO 2	105
<b>5. CONCLUSÕES E SUGESTÕES.....</b>	<b>110</b>
<b>APÊNDICES.....</b>	<b>116</b>
<b>BIBLIOGRAFIA.....</b>	<b>135</b>

## LISTA DE TABELAS

Tabela 4.1	Tabela da Matriz de Erro para classificação da imagem textural de frequência única no experimento 1.....	65
Tabela 4.2	Tabela da Matriz de Erro para classificação da imagem textural de frequência única no experimento 2.....	67
Tabela 4.3	Tabela da matriz de Erro para a classificação da imagem textural de frequência única no experimento 3.....	68
Tabela 4.4	Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.7, referente ao experimento 1.....	74
Tabela 4.5	Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 1, conforme os parâmetros definidos na tabela 4.4.....	77
Tabela 4.6	Parâmetros para o filtro de Gabor extraídos das amostras da figura 4.26, referente ao experimento 2.....	78
Tabela 4.7	Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 2, conforme os parâmetros definidos na tabela 4.6.....	80
Tabela 4.8	Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.26, referente ao experimento 3.....	80
Tabela 4.9	Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 3, conforme os parâmetros definidos na tabela 4.8.....	82
Tabela 4.10	Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.26, referente ao experimento 4.....	83
Tabela 4.11	Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 4, conforme os parâmetros	

	definidos na tabela 4.10.....	85
Tabela 4.12	Parâmetros para o filtro de Gabor extraídos das amostras da figura 4.26, referente ao experimento 5.....	86
Tabela 4.13	Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 5, conforme os parâmetros definidos na tabela 4.12.....	88
Tabela 4.14	Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.26, referente ao experimento 6.....	89
Tabela 4.15	Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 6, conforme os parâmetros definidos na tabela 4.14.....	91
Tabela 4.16	Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.39, referente ao experimento 1.....	103
Tabela 4.17	Tabela da Matriz de Erro para classificação da imagem real de parte de Porto Alegre e ilhas, referente ao experimento 1.....	105
Tabela 4.18	Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.39, referente ao experimento 2.....	106
Tabela 4.19	Tabela da Matriz de Erro para classificação da imagem real de parte de Porto Alegre e ilhas, referente ao experimento 2.....	108

## LISTA DE FIGURAS

Figura 1.1	Satélite espacial sondando a superfície da Terra .....	1
Figura 1.2	Aquisição de informações de alvos Terrestres através de sua reflectância.....	2
Figura 1.3	(a) Coleta de dados pelo sensor (sinal analógico) na superfície da Terra. (b) Amostragem deste sinal analógico, isto é , conversão dos dados de um formato analógico para o formato digital, SWAIN e DAVIS (1978). (c) Organização dos dados em formato digital para um formato raster padrão.....	3
Figura 3.1	(a) Uma função tridimensional, (b) Seu espectro de Fourier (c) O espectro de Fourier mostrado como uma função de intensidade. (adaptado de Gonzales & Woods, GONZALES e WOODS(1992)).....	31
Figura 3.2	Filtro de Gabor : (a) Componente Real do filtro para valores de $\sigma=1$ pixel e $k=0.5$ ciclos /pixel ; (b) Componente Imaginária do filtro, para valores de $\sigma =1$ pixel e $k=0.5$ ciclos/pixel.....	37
Figura 3.3	Ilustração da medida experimental em duas dimensões dos perfis de campos receptivos de três células simples do córtex de uma gato, obtido em laboratório por Jones e Palmer (linha superior) . Cada gráfico mostra o efeito excitatório e inibitório de um pequeno raio luminoso ou mancha escura na taxa de resposta da célula, como uma função de $(x,y)$ da localização do estímulo. A Segunda linha mostra a aproximação do perfil de campo receptivo pela função de Gabor com os parâmetros adequados. A Terceira linha mostra o resíduo entre a função de Gabor e o perfil de campo receptivo. (figura adaptada de Daugman, DAUGMAN(1985)).....	40

Figura 3.4	(a)Filtro de Gabor bidimensional apresentado em valores absolutos (b) Componente real do filtro de Gabor (c) Componente imaginária do filtro de Gabor, ambos para valores $\sigma=\sigma_x=\sigma_y=4$ , $k_x=-0.5$ e $k_y=0.5$ ciclos/pixel. O valor * em parêntese corresponde a $(\sigma_x, \sigma_y, k_x, k_y)$ .....	42
Figura 3.5	(a)Filtro de Gabor bidimensional (componente Real) no Domínio espacial (b) resposta de freqüência do filtro definido em (a). .....	44
Figura 3.6	(a)Imagem de padrão textural;(b) Transformada de Fourier da imagem em (a); (c) Imagem de padrão textural; (d) Transformada de Fourier da imagem em (a). A partir dos espectros de Fourier determinados em (b) e (d), onde o centro da figura corresponde à origem dos eixos u (eixo horizontal) e v(eixo vertical). Pode-se verificar que as freqüências com maior energia encontram-se no centro do espectro de Fourier e são bastante similares. Portanto, estas freqüências não são adequadas para discriminar estas texturas, contudo, freqüências menos energéticas afastadas do centro do Espectro de Fourier ao longo da orientação principal do espectro são mais eficientes no processo de discriminação entre as duas imagem em (a) e (c). .....	46
Figura 3.7	Ilustração do valor modular do Filtro de Gabor com $\sigma=1$ e dimensão do filtro =6, Cobrindo com esta extensão 99.73% da área coberta pelo filtro de Gabor. ....	50
Figura 3.8	Estrutura do processo de classificação com bancos de filtros de Gabor no domínio espacial. ....	53
Figura 4.1	Sinal formado pela função seno e composto por três classes.....	57

Figura 4.2	Resultado da convolução do sinal original (figura 4.1) com os três filtros de Gabor. O valor de $\sigma$ em cada caso é proporcional a frequência representativa da classe. Em vermelho o resultado da filtragem, utilizando o filtro apropriado para a frequência 1/128 Hertz, em verde o resultado da filtragem, utilizando o filtro apropriado para a frequência 10/128 Hertz e em azul o resultado da filtragem, utilizando o filtro apropriado para a frequência 4/128 Hertz.....	58
Figura 4.3	Dimensões dos filtros definidos por seus respectivos $\sigma$ . Nota-se que os filtros em verde e azul, quando centrados no filtro vermelho captam parte da feição por ele determinado....	58
Figura 4.4	Resultado da convolução do sinal original (figura 4.1) com os três filtros de Gabor. O valor de $\sigma$ para todos os filtros é constante e igual ao $\max(\sigma_i), i=1, \dots, \text{número de filtros}$ . Em vermelho, tem-se o resultado da filtragem utilizando o filtro apropriado para a frequência 1/128 Hertz, em verde, o resultado da filtragem utilizando o filtro apropriado para a frequência 10/128 Hertz e em azul, o resultado da filtragem utilizando o filtro apropriado para a frequência 4/128 Hertz.....	60
Figura 4.5	Dimensão dos filtros com $\sigma$ único utilizados para Segmentar o sinal unidimensional, ilustrado na figura 4.1.....	60
Figura 4.6	Sinal utilizando a função seno e formado por três classes com diferentes amplitudes e frequências.....	61

Figura 4.7	<p>Resultado da convolução do sinal unidimensional composto por diferentes amplitudes (figura 4.6) com os três filtros de Gabor. O valor de <math>\sigma</math> para todos os filtros é constante e igual ao <math>\max(\sigma_i)</math>, <math>i=1, \dots, \text{número de filtros}</math>. Em vermelho, o resultado da filtragem utilizando o filtro apropriado para a frequência 1/128 Hertz, em verde, o resultado da filtragem utilizando o filtro apropriado para a frequência 10/128 Hertz e em azul, o resultado da filtragem utilizando o filtro apropriado para a frequência 4/128 Hertz.....</p>	61
Figura 4.8	<p>Sinal utilizando a função seno, formado por três classes com diferentes amplitudes, tendo a primeira e terceira classes a mesma frequência, porém com amplitudes diferentes.....</p>	62
Figura 4.9	<p>Resultado da convolução do sinal unidimensional composto por diferentes amplitudes, com duas classes apresentando a mesma frequência espacial (figura 4.8), com os três filtros de Gabor. O valor de <math>\sigma</math> para todos os filtros é constante e igual ao <math>\max(\sigma_i)</math>, <math>i=1, \dots, \text{número de filtros}</math>. Em vermelho, tem-se o resultado da filtragem utilizando o filtro apropriado para a frequência 1/128 Hertz, em verde, o resultado da filtragem, utilizando o filtro apropriado para a frequência 10/128 Hertz e em azul, o resultado da filtragem utilizando o filtro apropriado para a frequência 4/128 Hertz. A curva em vermelho foi artificialmente deslocada para evidenciar o comportamento igual à curva em azul, pois, do contrário, ela seria sobreposta pela azul.....</p>	62
Figura 4.10	<p>Imagem sintética de frequência única por classe.....</p>	63



Figura 4.11	Imagens filtradas pelos filtros de Gabor para o experimento 1 na imagem sintética de frequência única.....	64
Figura 4.12	Imagem classificada referente ao experimento 1 da imagem sintética de frequência única.....	65
Figura 4.13	Imagens filtradas pelos filtros de Gabor para o experimento 2 na imagem sintética de frequência única.....	66
Figura 4.14	Imagem classificada referente ao experimento 2 da imagem sintética de frequência única.....	66
Figura 4.15	Imagens filtradas pelos filtros de Gabor para o experimento 3 na para imagem sintética de frequência única... ..	67
Figura 4.16	Imagem classificada referente ao experimento 3 da imagem sintética de frequência única.....	68
Figura 4.17	Imagem sintética formada por mosaico de texturas naturais.....	70
Figura 4.18	Amostras representativas de classes para seleção de feições.....	70
Figura 4.19	(a) Localização da amostra (b) Amostra 1 da classe 1 na imagem original (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos $u$ (eixo horizontal) e $v$ (eixo vertical).....	71

- Figura 4.20 (a) Localização da amostra (b) Amostra 1 da classe 2 na imagem original (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v(eixo vertical)..... 71
- ....
- Figura 4.21 (a) Localização da amostra (b) Amostra 2 da classe 2 na imagem original (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v(eixo vertical)..... 72
- Figura 4.22 (a) Localização da amostra (b) Amostra 1 da classe 3 na imagem original (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v(eixo vertical)..... 72
- Figura 4.23 (a) Localização da amostra (b) Amostra 1 da classe 4 na imagem original (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o

	preto para as mais baixas, sendo desconsiderada a frequência $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos $u$ (eixo horizontal) e $v$ (eixo vertical).....	73
	....	
Figura 4.24	Gráfico das frequências espaciais mais energéticas referentes às amostras da figura 4.18.....	73
Figura 4.25	Imagens filtradas pelo filtro de Gabor na imagem mosaico (Figura 4.17) para o experimento 1.....	75
Figura 4.26	Amostras da imagem mosaico utilizadas para o treinamento do classificador....	76
Figura 4.27	Classificação referente ao experimento 1 na imagem mosaico de textura natural ( figura 4.17) .....	76
Figura 4.28	Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 2.....	78
Figura 4.29	Classificação referente ao experimento 2 na imagem mosaico de textura natural (figura 4.17) .....	79
Figura 4.30	Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 3.....	81
Figura 4.31	Classificação referente ao experimento 3 na imagem mosaico de textura natural ( figura 4.17) .....	81
Figura 4.32	Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 4.....	84
Figura 4.33	Classificação referente ao experimento 4 na imagem mosaico de textura natural ( figura 4.17) .....	85
Figura 4.34	Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o	

	experimento 5.....	87
Figura 4.35	Classificação referente ao experimento 5 na imagem mosaico de textura natural ( figura 4.17) .....	88
Figura 4.36	Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 6.....	90
Figura 4.37	Classificação referente ao experimento 6 na imagem mosaico de textura natural ( figura 4.17) .....	91
Figura 4.38	Imagem digitalizada de uma fotografia aérea de parte da cidade de Porto Alegre e ilhas.....	93
Figura 4.39	Amostras representativas das classes utilizadas para seleção de feições....	94
Figura 4.40	(a) Localização da amostra 1 da classe urbana na imagem original (b) Amostra da classe (c) Espectro de Fourier da amostra (d) freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v(eixo vertical)....	95
Figura 4.41	(a) Localização da amostra 2 da classe urbana na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v(eixo vertical).....	95

- Figura 4.42 (a) Localização da amostra 3 da classe urbana na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v(eixo vertical)..... 96
- Figura 4.43 (a) Localização da amostra 1 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v(eixo vertical)... 96
- Figura 4.44 (a) Localização da amostra 2 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v(eixo vertical)... 97
- Figura 4.45 (a) Localização da amostra 3 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia,

com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo Figura desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical)..... 97

Figura 4.46 (a) Localização da amostra 4 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical)..... 98

Figura 4.47 (a) Localização da amostra 5 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical)..... 98

Figura 4.48 (a) Localização da amostra 6 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da

figura, onde está a origem dos eixos u (eixo horizontal) e v (eixo vertical)..... 99

Figura 4.49 (a) Localização da amostra 1 da classe água na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v (eixo vertical)..... 99

Figura 4.50 (a) Localização da amostra 2 da classe água na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v (eixo vertical)..... 100

Figura 4.51 (a) Localização da amostra 3 da classe água na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos u (eixo horizontal) e v (eixo vertical)..... 100

Figura 4.52 (a) Localização da amostra 4 da classe água na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d)

	Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos $u$ (eixo horizontal) e $v$ (eixo vertical).....	101
Figura 4.53	(a) Localização da amostra 5 da classe água na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Freqüências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a freqüência $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos $u$ (eixo horizontal) e $v$ (eixo vertical).....	101
Figura 4.54	Gráfico das freqüências espaciais mais energéticas para as amostras da figura (4.39).....	102
Figura 4.55	Imagens filtradas pelo filtro de Gabor na imagem de Porto Alegre( figura 4.38) para o experimento 1.....	104
Figura 4.56	Imagem classificada referente ao experimento 1 da imagem real de parte de Porto Alegre e ilhas .....	104
Figura 4.57	Imagens filtradas pelo filtro de Gabor na imagem de Porto Alegre( figura 4.38) para o experimento 2.....	107
Figura 4.58	Imagem classificada referente ao experimento 2 da imagem real de parte de Porto Alegre e ilhas.....	108



## LISTA DE APÊNDICES

Apêndice	01	Transformada de Fourier.....	117
Apêndice	02	Classificador de Maxima Verossi- milhança Gaussiana.....	125
Apêndice	03	Matriz de Erro ou de Confusão.....	130

## LISTA DE ABREVIATURAS

EDANN	→	<i>Entropy Driven Artificial Neural Network</i>
EPNSQ	→	<i>Edge Preserving Noise Smoothing Quadrants</i>
FFT	→	<i>Fast Fourier Transform</i>
IEEE	→	<i>Institute of Eletrical and Eletronics Engeneers</i>
MATLAB	→	<i>Matrix Laboratory</i>
MDBC	→	<i>Modified Differential Box Counting</i>
MLP	→	<i>Multilayer Percepton</i>
PIXEL	→	<i>Picture Element</i>
SOM	→	<i>Self Organizing Map</i>
TEXEL	→	<i>Texture Element</i>

## LISTA DE SÍMBOLOS

$\rho(x, y)$	→	Função de auto-correlação
$L_x$	→	Dimensão do retângulo para análise de auto-correlação ao longo do eixo x
$L_y$	→	Dimensão do retângulo para análise de auto-correlação ao longo do eixo y
$I(.)$	→	Transmissão de energia de uma imagem em transparência.
$  \cdot  $	→	Módulo ou valor absoluto
$I(i, j)$	→	Posição na Sub-imagem I
$\nabla(d)$	→	Gradiente de Roberts
$\Gamma$	→	Estatística Gamma de Hubert
$f(x, y)$	→	Função bidimensional em x, y
$F(u, v)$	→	Transformada de Fourier de uma função $f(x, y)$
$\mathfrak{F}(\cdot)$	→	Operador transformada de Fourier
$\mathfrak{F}^{-1}(\cdot)$	→	Operador transformada inversa de Fourier
$\sigma$	→	Extensão espacial do filtro de Gabor
$\sigma_x$	→	Extensão espacial do filtro de Gabor ao longo do eixo x
$\sigma_y$	→	Extensão espacial do filtro de Gabor ao longo do eixo y
$\Sigma$	→	Operador de somatório
$\Delta$	→	Símbolo de Variação
$k_x$	→	Frequência espacial do filtro de Gabor ao longo do eixo x
$K_y$	→	Frequência espacial do filtro de Gabor ao longo do eixo y
$\pi$	→	Número pi
$i$	→	unidade de número imaginário
$f^*$	→	Complexo conjugado de f
$F^*$	→	Complexo conjugado de F
$*$	→	Operador de convolução
<b>dim</b>	→	Dimensão do filtro de Gabor
<b>Dim</b>	→	Dimensão única do filtro de Gabor
<b>Max</b>	→	Operador de valor máximo
$\Sigma_i$	→	Matriz de covariância da classe i
<b>I</b>	→	Matriz identidade
$N_r$	→	Número de partições distintas (não sobrepostas) de A sobre si mesma
$W_i$	→	Classe i
$P(w_i)$	→	Probabilidade de ocorrência da classe i
$P(x)$	→	Probabilidade de encontrar um pixel de qualquer classe na posição x
$P(w_i/x)$	→	Probabilidade do pixel x pertencer a classe i
$P(x/w_i)$	→	Probabilidade interna da classe i
<b>exp</b>	→	Função exponencial
<b>Ln</b>	→	Logaritmo natural ou Neperiano

$\int_b^a$	→	Integral definida no intervalo a e b
$(. )^T$	→	Operador de transposição matricial
log	→	Logaritmo decimal
RE( .)	→	Componente real de um número imaginário
IM( .)	→	Componente imaginária de um número imaginário
$m_i$	→	Vetor média para a classe i
$\phi (u, v)$	→	Ângulo de fase da transformada de Fourier

## LISTA DE FÓRMULAS

Fórmula	2.1	Função de auto-correlação.....	9
Fórmula	2.2	Gradiente de Roberts.....	12
Fórmula	2.3	Dimensão Fractal.....	23
Fórmula	3.1	Transformada de Fourier contínua caso bidimensional.....	30
Fórmula	3.2	Transformada inversa de Fourier contínua caso bidimensional.....	30
Fórmula	3.3	Espectro de Fourier.....	30
Fórmula	3.4	Espectro de energia de Fourier.....	30
Fórmula	3.5	Definição discreta da função contínua $f(x,y)$ .....	32
Fórmula	3.6	Transformada de Fourier discreta caso bidimensional.....	32
Fórmula	3.7	Transformada inversa de Fourier discreta caso bidimensional.....	32
Fórmula	3.8	Incremento da amostra discretizada ao longo do eixo das abscissas no domínio das frequências.....	32
Fórmula	3.9	Incremento da amostra discretizada ao longo do eixo das ordenadas no domínio das frequências.....	33
Fórmula	3.10	Transformada de Fourier discreta bidimensional para imagem de mesmo número de linhas e colunas.....	33
Fórmula	3.11	Transformada inversa de Fourier discreta bidimensional para imagem de mesmo número de linhas e colunas .....	33
Fórmula	3.12	Limite teórico inferior de incerteza conjunta para o domínio temporal e das frequências.....	35
Fórmula	3.13	Filtro de Gabor para o caso unidimensional.....	36

Fórmula	3.14	Filtro de Gabor para o caso bidimensional.....	36
Fórmula	3.15	limite teórico inferior de incerteza conjunta para o domínio espacial e das frequências.....	37
Fórmula	3.16	Fator correspondente ao eixo das abscissas para o calculo da área no domínio espacial.....	38
Fórmula	3.17	Fator correspondente ao eixo das abscissas para o calculo da área no domínio das frequências.....	38
Fórmula	3.18	Fator correspondente ao eixo das ordenadas para o calculo da área no domínio espacial.....	38
Fórmula	3.19	Fator correspondente ao eixo das ordenadas para o calculo da área no domínio das frequências.....	38
Fórmula	3.20	Área ocupada pelo filtro no domínio espacial.....	39
Fórmula	3.21	Área ocupada pelo filtro no domínio das frequências.....	39
Fórmula	3.22	Incerteza conjunta para os domínios espacial e das frequências no caso do filtro de Gabor.....	39
Fórmula	3.23	Função de Gabor bidimensional.....	41
Fórmula	3.24	Componente real do filtro bidimensional de Gabor.....	41
Fórmula	3.25	Componente imaginária do filtro bidimensional de Gabor.....	41
Fórmula	3.26	Transformada de Fourier para o filtro bidimensional de Gabor.....	43
Fórmula	3.27	Transformada de Fourier para a componente real do filtro de Gabor bidimensional.....	43
Fórmula	3.28	Energia por pixel da imagem filtrada.....	44

Fórmula	3.29	Dimensão do filtro de Gabor ao longo dos eixos coordenados.....	48
Fórmula	3.30	Valor da dimensão única do filtro de Gabor em relação as dimensões ao longo dos eixos.....	49
Fórmula	3.31	Valor único da dimensão do filtro de Gabor segundo o máximo do recíproco das frequências espaciais .....	49
Fórmula	3.32	Valor da extensão espacial do filtro de Gabor em função de sua dimensão .....	50
Fórmula	3.33	Valor da extensão espacial única do filtro de Gabor .....	51

## CAPÍTULO I

### INTRODUÇÃO

Sensoriamento Remoto é a ciência que tem por objetivo obter informações a respeito de objetos, genericamente designados por "alvos", sem entrar em contato direto com eles, RICHARDS(1986). A figura 1 ilustra como um sensor capta uma imagem da superfície da Terra. A maneira mais freqüente de obtenção destas informações consiste na medida da quantidade de energia eletromagnética (radiância) refletida e/ou emitida pelos alvos de interesse em diversas regiões do espectro eletromagnético, SLATER(1980), conforme ilustra a figura 2.




Figura 1.1  
Satélite espacial sondando a superfície da Terra .






Figura 1.2  
Aquisição de informações de alvos terrestres através de sua reflectância.

Em um certo sentido, Sensoriamento Remoto não é uma tecnologia nova. Em épocas passadas, observações feitas a partir de balões e, mais tarde, de aeronaves permitiram a coleta de dados a respeito da superfície da Terra. A fotografia aérea, inicialmente obtida na porção visível do espectro eletromagnético e depois também na região do infravermelho próximo, tornou operacional um método eficiente de obtenção e posterior análise de dados da superfície da Terra a distância. Mais recentemente, dois novos desenvolvimentos permitiram um incremento considerável nestas atividades: os satélites artificiais equipados com sensores multiespectrais para a observação da superfície terrestre e a disponibilidade de computadores digitais para a análise de grandes quantidades de dados assim obtidos, de forma objetiva, eficiente e confiável. Ao contrário do processo de fotointerpretação tradicional, no qual as informações são extraídas a partir de fotografias

aéreas convencionais (analógicas), as técnicas de Sensoriamento Remoto, por desenvolverem os processos de análise em ambiente computacional, utilizam imagens em formato digital. A figura 3 ilustra a aquisição e posterior transformação das informações adquiridas para o formato digital.

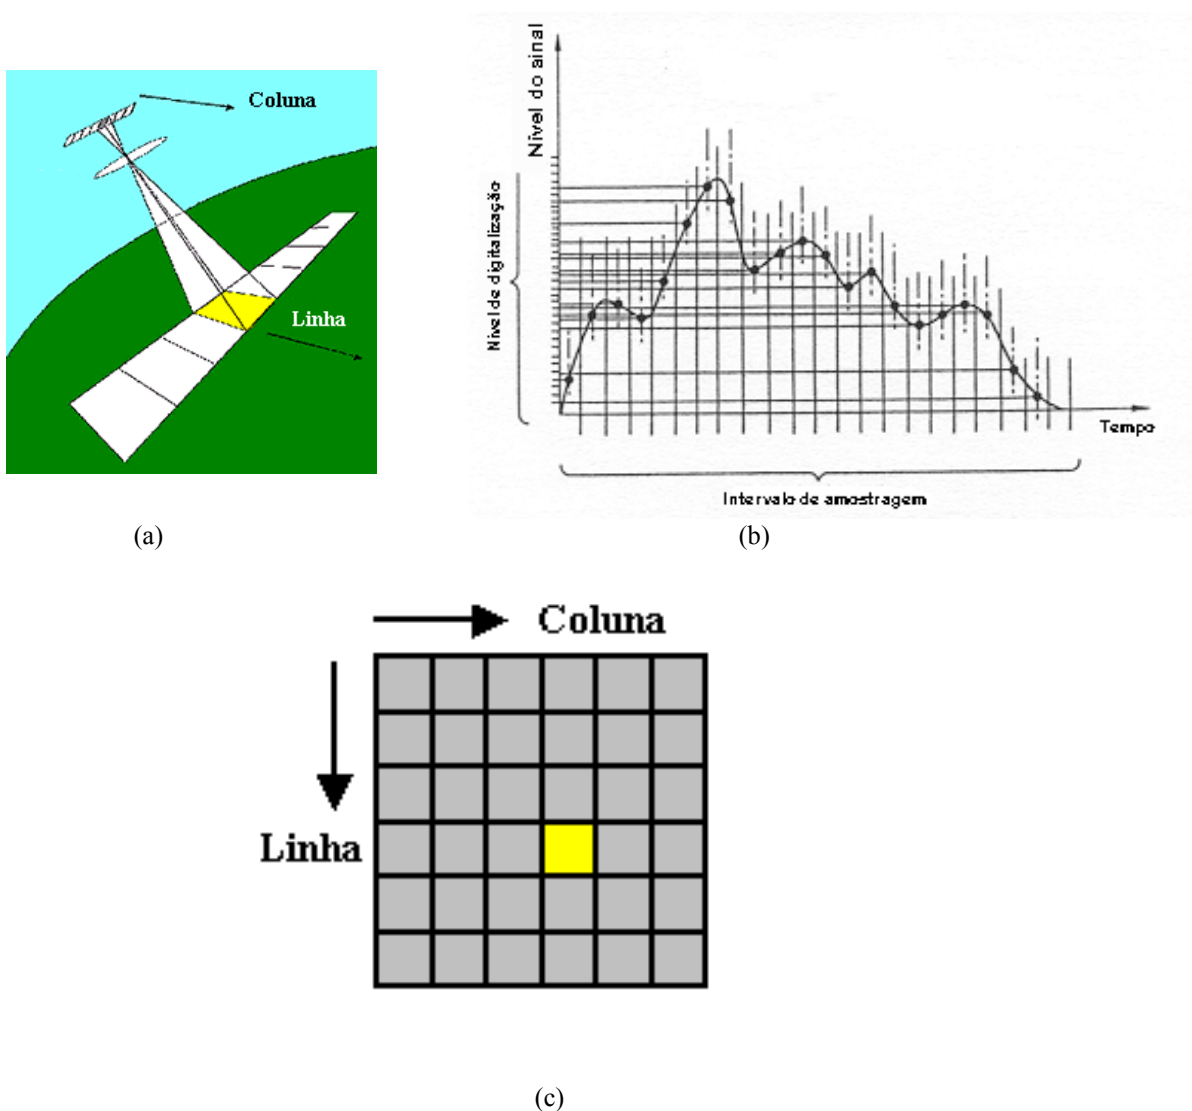


Figura 1.3

(a) Coleta de dados pelo sensor (sinal analógico) na superfície da Terra. (b) Amostragem deste sinal analógico, isto é, conversão dos dados de um formato analógico para o formato digital, SWAIN e DAVIS (1978). (c) Organização dos dados em formato digital para um formato raster padrão.

As informações armazenadas em uma imagem digital multiespectral são normalmente exploradas através de categorias de informações, denominadas de atributos da imagem. Estes atributos são de natureza distinta e podem ser agrupados genericamente em quatro categorias:

- espectrais;
- espaciais;
- de contexto;
- temporais;

Os atributos espectrais dizem respeito às características espectrais dos alvos de interesse, isto é, a maneira como a radiância (ou a reflectância) de um determinado alvo varia em função do comprimento de onda.

Já os atributos espaciais dizem respeito às características de regiões da imagem como textura, forma, dimensões.

Por outro lado os atributos de contexto fazem uso de informações oriundas de regiões vizinhas à área (ou pixel), que está sendo analisada. Estes atributos baseiam-se na correlação espacial que normalmente ocorre entre as classes presentes em uma imagem.

Finalmente, os atributos temporais exploram as variações ocorridas nas características de um pixel ou de uma região homogênea da imagem ao longo do tempo. As variações ocorridas ao longo do ciclo fenológico de uma determinada cultura agrícola e que servem, portanto, para

identificá-la, constituem-se em um exemplo de atributos temporais.

Esta dissertação propõem-se a desenvolver uma metodologia para classificação de imagens digitais com base nas características de textura (atributo espacial), apresentadas pelas diferentes classes presentes.

A utilização de atributos de textura no processo de classificação de imagens vem ocupando a atenção da comunidade científica, conforme demonstra a literatura. A importância da textura decorre essencialmente do fato de que certas classes que ocorrem em cenas naturais apresentam atributos ou características espectrais muito similares. Este fato resulta num processo de classificação com baixa exatidão, quando somente atributos espectrais são utilizados. Já é um fato bem conhecido que, em muitos casos, estas mesmas classes, que espectralmente são muito similares, apresentam características texturais bastante distintas. Desta forma, um algoritmo de classificação baseado em atributos de textura teria o potencial de separação de classes espectralmente similares com uma boa exatidão.

O ser humano possui uma habilidade extraordinária de reconhecer o mundo que o cerca, isto é, de classificar os diferentes objetos que o rodeiam. Em outras palavras, o cérebro humano possui uma capacidade excepcional de reconhecer padrões. Uma explicação para esta excepcional performance reside no fato de que o ser humano faz uso

simultâneo dos quatro atributos acima mencionados no processo de reconhecimento do mundo que o cerca. Um dos maiores objetivos da ciência de Reconhecimento de Padrões é desenvolver algoritmos implementáveis em computador e que reproduzam de alguma forma os processos realizados pelo ser humano. Tradicionalmente, os algoritmos para fins de classificação de imagens desenvolvidos e operacionais vem fazendo uso exclusivo dos atributos espectrais. Esta preferência é facilmente compreensível, pelo fato que estes atributos são mais facilmente quantificáveis, prestando-se desta forma a sua utilização em computador. Os demais atributos são de quantificação mais complexa e, portanto, muito menos utilizados até os dias atuais nos processos de classificação de imagem por computador. A textura é um atributo espacial, de fácil visualização e caracterizado por uma particular distribuição dos valores dos níveis de cinza ao longo de regiões da imagem. A textura não possui entretanto, uma definição formal ou modelo matemático geral para sua quantificação. E embora, a textura seja um atributo facilmente identificável pelo ser humano é porém, de difícil quantificação para fins de uso em computador.

O objetivo desta dissertação é, portanto, oferecer uma contribuição ao esforço de integrar o atributo de textura ao processo de classificação de uma imagem digital por computador. Através de um método de seleção de feições texturais, que utiliza as frequências espaciais de cada

classe textural e sua direção como fator de diferenciação entre as classes classificação da imagem.

Esta dissertação esta organizada da seguinte forma: o capítulo 2 apresenta uma revisão dos trabalhos mais relevantes desenvolvidos pelos pesquisadores nesta área. A metodologia proposta e desenvolvida nesta dissertação é apresentada no capítulo 3. O capítulo 4 relata os vários experimentos efetuados com a finalidade de verificar a validade da metodologia proposta. O capítulo 5 apresenta as conclusões e sugestões para futuros trabalhos nesta área a partir dos resultados obtidos pela metodologia proposta. E, finalmente, no apêndice são fornecidos maiores detalhes sobre tópicos apresentados ao longo da dissertação e que poderão ser mais exhaustivamente compreendidos.

## **CAPÍTULO II**

### **REVISÃO BIBLIOGRÁFICA**

#### **2.1. INTRODUÇÃO**

O desenvolvimento de metodologias implementando atributos de textura no processo de classificação de imagens digitais vem sendo objeto da atenção da comunidade científica. Abordagens diversas vem sendo relatadas na literatura (IEEE Transactions on Pattern Analysis and Machine Intelligence, IEEE Transactions on Image Processing, IEEE Transactions on Geoscience and Remote Sensing, Pattern Recognition, além de vários outros periódicos). A ênfase que se vem dando a esta área, serve para evidenciar a importância deste tópico. O objetivo deste capítulo é apresentar uma síntese das principais abordagens desenvolvidas, de modo a inserir a presente pesquisa dentro de um contexto mais geral. Possivelmente uma das melhores introduções aos vários métodos de caracterização de textura, pode ser encontrada em HARALICK (1979).

#### **2.2. TÉCNICAS ESTATÍSTICAS**

Metodologias de natureza estatística tem sido

propostas por vários autores. Entre as mais representativas pode-se mencionar as seguintes:

### 2.2.1. FUNÇÃO AUTO-CORRELAÇÃO

O conceito de função de auto-correlação foi utilizada por vários autores para caracterização de textura. A função de auto-correlação é definida por:

$$\rho(x,y) = \frac{L_x L_y}{(L_x - |x|)(L_y - |y|)} \frac{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} I(u,v)I(u+x,v+y) du dv}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} I^2(u,v) du dv}, \quad (2.1)$$

onde  $I(u,v)$  denota a transmissão de energia de uma imagem em transparência na posição  $(u,v)$  e  $(x,y)$  denota a translação em  $x$  e a translação em  $y$ , respectivamente. Para a equação acima supõe-se que  $|x| < L_x$  e  $|y| < L_y$ , e que a transmissão da imagem fora da região retangular dada por  $0 \leq u \leq L_x$  e  $0 \leq v \leq L_y$  é nula. A função de auto-correlação classifica uma imagem, baseando-se no tamanho das primitivas tonais. Primitivas tonais são regiões com características tonais bem definidas, isto é, regiões com pouca variação de brilho. Primitivas tonais, com dimensões grandes caracterizam texturas grosseiras, que são percebidas pela diminuição suave da função de auto-correlação na medida em que a distância entre os pixels aumenta. De maneira análoga, primitivas tonais de dimensão pequena caracterizam texturas finas, que na função de auto-correlação ocasionam uma diminuição rápida, na medida em



que a distância entre pixels aumenta. Similarmente, no caso de uma imagem com textura periódica, a função auto-correlação também resulta periódica, aumentando e diminuindo a intervalos regulares.

Uma propriedade que deve ser mencionada, refere-se a alta correlação, evidenciada em experimentos , envolvendo resultados originados da função de auto-correlação e aqueles obtidos por fotointérpretes. Em um experimento, H. Kaiser, (citado por HARALICK(1979)). utilizou sete imagens, cobrindo regiões do ártico. Este conjunto de imagens foi simultaneamente analisado , em termos de textura, por um grupo de fotointérpretes e pela aplicação da função de auto-correlação. O resultado dos processos evidenciou uma alta correlação entre os resultados de ambas as análises (coeficiente de correlação de 0.99). Este experimento apresenta um resultado encorajador, no sentido em que uma função matemática mostra-se capaz de reproduzir a percepção visual humana.

### **2.2.2. PROCESSAMENTO ÓTICO**

Este método baseia-se no fato de que a amplitude da distribuição de energia luminosa nos planos focais anterior e posterior de uma lente são Transformadas de Fourier, uma da outra, e que a distribuição de luz produzidas pelas lentes são conhecidas como padrões de difração de Fraunhofer. Desta forma, este método ótico facilita a

análise de frequências bidimensionais em imagens. Num experimento de Landaris e Stanley, HARALICK(1979), ilustra-se bem este método. Iluminando pequenas seções circulares de uma fotografia aérea obtida a baixa altitude e usando padrões de difração de Fraunhofer como feições para identificar as seções, obteve-se uma exatidão de 90% na classificação da imagem.

### **2.2.3. MÉTODO DE TRANSFORMADA DIGITAL**

No método de transformadas digitais, a imagem digital é subdividida em pequenas sub-imagens quadradas, não sobrepostas de  $n \times n$  pixels, que podem ser vistas como  $n^2$  componentes de um vetor de dimensão  $n^2$ . Na técnica de transformada digital, esses vetores ou sub-imagens são expressos em um novo sistema de coordenadas. A base do novo sistema de coordenadas tem uma interpretação diretamente ligada à frequência espacial, a qual, por sua vez, está intimamente ligada à textura. HARALICK(1979).

Vários trabalhos foram desenvolvidos usando esta técnica, como os desenvolvidos por Gramenopoulos, Kirvida e Johnson, Maurer, Bazcsy e Lieberman.(citados em HARALICK(1979)).

### **2.2.4. MÉTODO DE DENSIDADE DE ARESTA**

Esta técnica foi concebida por Rosenfeld, Troy e Thurston, não em termos de frequência, mas em termos do

número de arestas por unidade de área. Uma borda pode ser detectada pela comparação dos valores de propriedades locais obtidos a partir de dois pixels vizinhos. Estas propriedades locais são calculadas, usando-se o gradiente de Roberts, isto é, soma dos valores absolutos das diferenças entre pixels vizinhos diagonalmente opostos. Sulton e Hale, estenderam esta idéia, calculando o gradiente de distâncias entre pixels. Assim, para cada distância de uma sub-imagem  $I$  definida sobre uma vizinhança  $N$ , temos:

$$\nabla(d) = \sum_{i,j \in N} \left\{ |I(i,j) - I(i+d,j)| + |I(i,j) - I(i-d,j)| + |I(i,j) - I(i,j+d)| + |I(i,j) - I(i,j-d)| \right\} \quad (2.2)$$

Sulton e Hall, [HARALICK(1979)], em seu trabalho obtiveram a exatidão de 80%, utilizando este método. Outros pesquisadores como Trand e Hsu, também se utilizaram deste método em seus trabalhos.

#### 2.2.5. MORFOLOGIA MATEMÁTICA

Este processo foi, originalmente, proposto por Matheron, Serra e Verchery, [HARALICK(1979)]. A idéia básica é definir um elemento estrutural na forma de um conjunto de células de resolução com uma forma determinada como, por exemplo, linha ou quadrado, e gerar uma nova imagem binária

pela translação do elemento estruturante através da imagem original. Neste processo, o elemento estruturante ao passar pela imagem e encontrar uma região com a forma igual a sua, lhe atribui valor 1, em caso contrário, atribui o valor 0, criando assim, uma imagem binária. Esta imagem binária é então utilizada para efeito de classificação textural.

#### **2.2.6. MATRIZ DE CO-OCORRÊNCIA**

Neste método proposto por Haralick, HARALICK(1979), assume-se que as feições de textura de uma imagem podem ser representadas por um conjunto de matrizes de dependência espacial dos contadores digitais. Estas matrizes são baseadas nas frequências de ocorrência de pares de contadores digitais com determinada separação e segundo determinadas orientações.

A matriz de co-ocorrência é freqüentemente estimada dentro do conceito de uma "janela móvel" quadrada, com um número ímpar de linhas e colunas de modo a permitir a existência de um pixel central na matriz. Várias características podem ser extraídas desta matriz (entropia, uniformidade ou energia, probabilidade máxima, contraste, correlação, e outras). O valor destas estatísticas é então atribuído ao pixel central, gerando-se desta forma um número equivalente de "canais texturais" que, semelhantemente a bandas espectrais, podem ser implementadas em um classificador.

Utilizando-se matrizes de co-ocorrência para classificar fotografias áreas com oito classes obteve-se uma exatidão na classificação de 82%. O mesmo processo foi utilizado para imagens LANDSAT MSS com sete classes , chegando-se a uma exatidão na classificação de 84%, mostrando-se ser um bom método para extração de feições de textura.

#### **2.2.7. COMPRIMENTO DAS CORRIDAS DE PIXEL COM IGUAL INTENSIDADE**

Esta técnica é também conhecida por "RUN LENGTH", e procura caracterizar a textura por meio de uma seqüência de pixels linearmente adjacentes ao longo de uma determinada direção, com o mesmo valor de contador digital. Desta forma, texturas finas produzem um grande número de séries de comprimentos pequenos, enquanto texturas grosseiras são representadas por um grande número de séries de comprimento longo. A orientação da textura pode ser analisada somando-se os comprimentos das séries ao longo de diferentes direções, geralmente, 0°, 45°, 90° e 135°. , HARALICK(1979).

#### **2.3. TÉCNICAS DE REDES NEURAIS**

O processo mais comumente utilizado em problemas de classificação baseia-se no uso de amostras com a finalidade de se estimar certos parâmetros estatísticos que caracterizam cada classe (por exemplo, o vetor média e a

matriz covariância, no caso do classificador de Máxima Verossimilhança Gaussiana). Este processo é normalmente conhecido como o "treinamento do classificador".

Ocorre, entretanto, que em certos casos, os parâmetros das classes envolvidas são desconhecidas ou não podem ser estimadas. Uma alternativa para estes casos consiste no uso da técnica denominada de Redes Neurais, que é um processo não paramétrico. Esta técnica utiliza-se de elementos processadores (neurônios) que recebem informações (entrada de dados), as quais são ponderadas por pesos (pesos sinápticos) e produzem um resultado (saída). Estes neurônios são agrupados e se interconectam formando uma rede que pode apresentar várias topologias, adequadas às mais variadas tarefas. Estas redes, a partir de amostras de treinamento, ajustam os seus pesos sinápticos, que posteriormente farão com que ela possa proceder a classificação propriamente dita podendo, inclusive, classificar padrões não treinados.

Em MUHAMAD e DERAVID (1994), é feito um estudo amplo da eficiência de feições extraídas de matrizes co-ocorrência e de seu uso direto como dados de entrada em um classificador de rede neural. Numa primeira etapa as capacidades de classificação individual e várias combinações de feições extraídas de matrizes co-ocorrência são examinadas. Uma combinação adequada que consiste em quatro dessas feições é conseqüentemente estabelecida. Uma

rede neural artificial é usada como classificador. A performance de classificação desta rede como uma função do volume de dados de treinamento, seu tamanho e a estratégia de treinamento é examinada. A seguir é feita uma investigação sobre uso direto dos valores da matriz de ocorrência para classificação. Uma técnica simples, onde se agrupam os níveis cinzas nas imagens originais em um número pequeno de faixas iguais é empregado para reduzir o tamanho da matriz. Os resultados obtidos nesta etapa são similares com os obtidos usando uma combinação adequada de feições. Posteriormente, é demonstrada a eficiência desta última técnica por intermédio de uma aplicação prática que envolve a classificação superficial de textura de cinco tipos de partículas em suspensão encontradas no óleo lubrificante utilizados em máquinas. Para este experimento é mostrado que se pode alcançar taxas de exatidão altas, da ordem de 96%.

Em VAN HULLE e TOLENAERE(1993), é introduzido um novo modelo de rede para executar a eliminação de ruídos texturais. O modelo é iniciado a partir da filtragem da imagem original com um banco de filtros de Gabor com diferentes orientações e frequências espaciais. O filtro de Gabor é dado por:

$$g(x,y,x',y',\theta,w) = \exp\left\{-\frac{I}{2\sigma}\left[(x-x')^2 + (y-y')^2\right] + 2\pi w(y.\cos\theta - x.\sin\theta)\right\}$$

e são utilizados neste trabalho as componentes real e

imaginária deste filtro. Do resultado da filtragem é tomado o somatório do quadrado dos valores, que passa a ser chamado mapa de energia. A eliminação de ruídos texturais é procedida então, tomando por base este mapa de energia, a partir de uma sucessão de dois módulos de rede usados para cada canal de frequência espacial. Os módulos estão baseados na rede neural de entropia dirigida (EDANN), um módulo de rede neural adaptada previamente desenvolvido para detecção de linha e borda. O primeiro módulo de EDANN executa a extração de orientação espacial e o segundo executa o preenchimento de informações de orientação perdidas ao longo do processo. A utilidade de ambos os módulos é produzir uma fiel separação de textura baseada no aumento das diferenças de primeira ordem na média dos valores de energia, enquanto a variabilidade espacial é reduzida ou mantida baixa. A fronteira de textura é detectada usando um terceiro módulo de EDANN, posteriormente ao segundo módulo.

O modelo proposto neste trabalho, não tinha a intenção de modelar a percepção humana de textura, nem tornar-se um modelo biológico para processamento de textura. Ao invés disto, foi elaborado para ser um modelo de processamento de textura ,usando redes neurais.

Em AUGUSTEIJN e CLEMENS(1995), é feita uma comparação entre as performances de vários métodos para extração de feições utilizados para classificação de imagem



terrestres obtidas por satélite. Os métodos considerados foram: matrizes de co-ocorrência, diferenças de nível de cinza, análise de textura-tom, Transformada de Fourier e Filtros de Gabor. Foi mostrado que os métodos de Fourier e Filtragem de Gabor mostram-se mais eficientes, quando uma única banda de frequência espacial foi utilizada para classificação.

A textura foi medida a partir da variabilidade do nível de cinza dos pixels em uma faixa de frequência única e foi representada por um vetor de feição.

Para unir as informações de várias bandas de frequência, os vários vetores de feição puderam ser concatenados e o padrão resultante pode ser levado à uma rede neural, no caso uma rede neural de arquitetura de correlação em cascata ("The cascade-correlation learning architecture-FAHLMAN"), para classificação.

Uma proposta deste estudo foi explorar a viabilidade de se extrair um índice de uma imagem de satélite, que seria constituído por uma lista de tipos de terreno dominante em uma imagem. Os tipos dominantes seriam aqueles que cobrem uma porcentagem maior de área em uma imagem. E, portanto, este índice seria usado para o armazenamento de imagens em um banco de dados.

#### **2.4. TÉCNICAS DE FILTRAGEM EM MULTICANAIS TEXTURAIS**

Nesta técnica utiliza-se a filtragem com filtros de

Gabor para a extração de feições na imagem. Para tanto, são determinadas a priori os parâmetros determinantes do filtro de Gabor, isto é, extensão, frequência e orientações espaciais. A partir da extração destas feições procede-se à classificação da imagem, utilizando-se para tanto de algum classificador.

Em JAIN e FARROKHNI(1991), é apresentada a técnica de filtragem multi-canal para segmentação de textura que usa um banco de filtros simétricos de Gabor para caracterizar os canais. É proposto um esquema sistemático de seleção de filtros, o qual está baseado na reconstrução da imagem original a partir de suas imagens filtradas. Cada imagem filtrada (selecionada) é sujeita a uma transformação não-linear e, posteriormente, através de uma medida de "energia" em uma pequena janela ao redor de cada pixel na imagem para obter as feições texturais. Este processo gera uma imagem de feição que corresponde a cada imagem filtrada. O tamanho da janela para cada imagem filtrada é determinado usando-se uma fórmula simples que envolve a frequência radial para a qual o filtro correspondente é tomado. Um algoritmo de clusterização, baseado no algoritmo de "K-means", é então usado para identificar as classes texturais. Um procedimento simples para inclusão de informação espacial no processo de clusterização também é proposta. Uma modificação da estatística  $\Gamma$  de Hubert, DUBES(1987), que utiliza a

correlação entre a distância euclidiana de dois padrões  $i, j$  e a distância euclidiana entre o centro dos dois aglomerados ("clusters") que contém estes padrões. Esta estatística é usada como um índice relativo para calcular o número de classes texturais. O desempenho do algoritmo é avaliado em imagens com um número grande de texturas naturais. Os resultados alcançados não dependeram de um conhecimento prévio das frequências espaciais presentes nas classes texturais. Além disto, pode-se diminuir a quantidade de imagens filtradas para a classificação da imagem original. Entretanto, o processo de escolha do número de classes na fase de clusterização aumenta consideravelmente o custo computacional do processo como um todo, principalmente para um número elevado de classes efetivamente presentes na imagem. Outro problema consistiu em admitir uma não sobreposição entre os diferentes canais de frequência espacial quando parecem existir evidências fisiológicas e psico-físicas afirmando o contrário.

Em BOVIK[et alli](1990), é descrita uma aproximação computacional para analisar texturas visíveis.

As texturas, neste trabalho, são modeladas como padrões que contêm um intervalo limitado de frequências espaciais, onde as texturas mutuamente distintas diferem significativamente em suas frequências características dominantes. A imagem original de textura é codificada em

múltiplos canais de frequência espacial e orientação, onde envelopes de variação suave de canais( amplitude e fase) são usados para separar regiões de textura com diferentes frequências espaciais, orientação ou características de fase.

O filtro de canal de frequência usado para extrair feições texturais é conhecido como filtro de Gabor bidimensional e é utilizado para este propósito devido a suas características específicas. Através da comparação das respostas de amplitudes dos canais, podem ser descobertos fronteiras entre as texturas e, portanto, pode-se separá-las.

Os resultados encontrados sugerem que os filtros de Gabor podem ser utilizados para outras tarefas de seleção de feições simulando a percepção visual humana e incluindo, inclusive, localização temporal. Entretanto, um dos problemas ainda existentes é o alto custo computacional para compor um banco de filtros completos que representem a imagem original.

Em RAGHU[et ali](1995), é apresentada uma estrutura de rede neural que combina as características de duas redes neurais: rede neural SOM("self Organizing Map") e rede neural MLP("Multilayer Perceptron") para classificação de textura. As feições texturais são obtidas através do uso de um banco de filtros de Gabor que tem tamanhos, orientações, e frequências espaciais diferentes, e que vieram a

constituir um vetor de feições a N dimensões. A rede neural SOM age como um mecanismo de clusterização que projeta estes vetores de feições N-dimensionais sobre um espaço M-dimensional. O valor de M, neste estudo, foi tomado com o valor dois, reduzindo, desta forma, a dimensionalidade do espaço das imagens filtradas.

As feições geradas após o uso da rede neural SOM são utilizadas para alimentar uma rede neural MLP com a finalidade de treinamento e subsequente classificação. Este mecanismo aumenta, portanto, a distância inter-classe (distância comum entre os vetores de classes diferentes) e ao mesmo tempo diminui a distância intra-classe (distância comum entre os vetores da mesma classe) no espaço de feições, reduzindo a complexidade de classificação. RAGHU[et alli](1995).

Os resultados obtidos neste trabalho mostram que a utilização da rede neural SOM melhora o resultado final da classificação, tanto na exatidão obtida, como no tempo de treinamento da rede neural MLP, comparando-se à classificação direta sem esta etapa. Porém é ressaltada a necessidade de escolher corretamente o valor de M, pois caso seja tomado erradamente pode degradar o resultado final de classificação. Ademais, a exatidão da clusterização e da classificação propriamente dita depende do parâmetro extensão espacial do filtro de Gabor.

Em DUNN[et alli](1996), é proposto o uso de filtros

de Gabor, obtidos a partir de funções elementares de Gabor, com parâmetros eficientemente escolhidos através de modelagem. A partir destes filtros, faz-se uso de uma imagem com duas texturas distintas das quais são extraídas amostras representativas de cada classe textural, com a finalidade de se estimar os parâmetros a serem usados no filtro, para posterior classificação da imagem. Esta classificação é feita utilizando os filtros de Gabor para demarcar descontinuidades entre texturas, as quais delimitam suas fronteiras, separando, dessa forma, as duas texturas existentes.

## 2.6. MÉTODO DE DIMENSÃO FRACTAL

Este método foi proposto por Chaudhuri e Sarkar, CHAUDHURI e SARKAR(1995), baseando-se na geometria espacial da imagem e na alta correlação entre esta geometria e a classificação de rugosidade superficial feita pela percepção visual humana. Para a classificação de uma imagem, esta técnica utiliza seis feições baseadas em dimensões fractais, onde a dimensão fractal **D** de uma imagem A é determinado através da relação:

$$D = \frac{\log(N_r)}{\log(1/r)} \quad (2.3)$$

Onde  $N_r$  é o número de partições distintas (não sobrepostas) de A sobre si mesma e r é a razão que ajusta esta partição. Para estimar a dimensão fractal é utilizado o método de

MDBC ("Modified Differential Box Counting"). Maiores detalhes sobre este método são encontrados em SARKAR e CHAUDHURI(1992)).

Para a classificação da imagem é utilizado um processo de suavização de feições denominado de EPNSQ ("Edge Preserving Noise Smoothing Quadrants"). Após esta suavização das feições, um algoritmo de clusterização não-supervisionado, K-means, é implementado para a classificação da imagem.

Neste contexto, insere-se o presente estudo que utiliza-se de um banco de filtros de Gabor com parâmetros estimados a partir de amostras das classes presentes na imagem, com a utilização da Transformadas de Fourier. A classificação das texturas, propriamente dita é feita por intermédio de um processo supervisionado conhecido como classificador de Máxima Verossimilhança. Este processo usa amostras das classes contidas no espaço N-dimensional, gerado pelo conjunto das imagens filtradas para estimar os parâmetros média e matriz de covariância necessários a este classificador.

## **CAPÍTULO III**

### **MATERIAL E MÉTODOS**

A metodologia utilizada nesta dissertação , baseia-se parcialmente nos trabalhos desenvolvidos em RAGHU[et al](1995), JAIN e FARROUKHNIA(1991). Esses autores propõe a implementação da técnica de filtragem multicanal, utilizando o conceito desenvolvido pelos filtros de Gabor. Os filtros de Gabor são um conjunto de funções senoidais complexas, bidimensionais, moduladas por uma função Gaussiana também bidimensional e que apresentam certas propriedades extremamente úteis para fins de classificação de imagens. Neste processo, são criados bancos de filtro de Gabor com a finalidade de extrair as feições texturais presentes numa imagem. DAUGMANN(1985 e 1988) mostra que os filtros de Gabor são adequados à análise textural, no sentido em que minimizam a incerteza conjunta, nos domínios espacial e no domínio das frequências, permitindo, desta forma, selecionar feições cujas características ficam determinadas por frequências espaciais diretamente no domínio espacial, sem a necessidade de desenvolver operações no domínio de Fourier ou das frequências. Esta



característica do filtro de Gabor é mais extensamente estudada na seção 3.3.

### **3.1. TEXTURA**

O uso da textura em processamento e classificação de imagens tem sido de considerável interesse científico, oferecendo um grande potencial de aplicações em áreas como análise e interpretação de imagens em sensoriamento remoto, imagens médicas, análise de dados sísmicos, além de várias outras áreas.

A despeito da grande importância da textura no processo de análise de imagens, especialmente nos problemas de classificação e segmentação de imagens, não existe na literatura, até o momento, uma definição geral de textura nem uma abordagem matemática geral para sua quantificação. Existem, entretanto, algumas definições específicas. RAGHU[et al.](1995), definem textura como: "a repetição de alguns padrões primitivos no espaço". Esta definição, porém, aplica-se a padrões determinísticos, tais como padrões regulares que ocorrem na natureza (ondulações nas areias dos desertos, por exemplo) ou produzidos pelo homem (padrões de placa de circuitos impressos, parede de tijolos, etc.). Esta conceituação não se aplica, contudo a padrões com características estocásticas (imagens da superfície da Terra, de nuvens e das superfícies oceânicas, imagens médicas, além de inúmeras outras). Nestes casos, os

padrões primitivos não são constantes, mas apresentam as propriedades de uma variável aleatória espacial com características de isotropia ou não. Por esta razão, SKLANSKY(1979) propõe uma definição um pouco mais abrangente para textura: "uma região em uma imagem tem textura constante, se um conjunto de estatísticas locais ou outras propriedades locais da imagem são constantes, de variação suave ou aproximadamente periódica". Esta definição aplica-se bem às imagens naturais encontradas em sensoriamento remoto. Estas estatísticas locais ou propriedades que se mantêm constantes ao longo de uma região de textura uniforme, definem o TEXEL (elemento de textura). As imagens em sensoriamento remoto podem, sob o ponto de vista de atributos de textura, ser analisadas por meio da decomposição em duas componentes básicas:

(i) Primitivas tonais ou propriedades locais, que são regiões com características tonais bem definidas, isto é, regiões onde a característica de brilho possui pouca variação;

(ii) Dependência espacial ou interação, que ocorre entre as primitivas. Esta dependência serve para caracterizar a textura presente em uma imagem, através da organização ou dependência que ocorre entre as primitivas tonais.

A primitiva tonal pode ser descrita pelo contador digital médio, máximo ou mínimo da região abrangida. A região tonal é, portanto, um conjunto maximalmente

conectado de elementos de resolução (pixels), com uma dada propriedade tonal, podendo ser quantificada em termos de sua área e de sua forma. Assim, uma textura da imagem pode ser descrita pelo número e pelas características de suas primitivas tonais, bem como sua organização espacial ou sua forma. A organização espacial envolvendo as primitivas tonais pode apresentar características aleatórias ou, então, evidenciar dependência entre as primitivas tonais. Neste último caso, a dependência pode ser de natureza probabilística (obedecendo à uma função de probabilidade), estrutural (apresentando alguma similaridade entre os TEXELS de cada primitiva ou, então, uma regra para a localização dos mesmos) ou ainda funcional (como, por exemplo, uma dependência linear entre as primitivas). A organização das primitivas tonais e sua distribuição espacial determinam o tipo de textura (fina, grossa, suave, granulada, aleatória, irregular, etc.). Portanto, os conceitos de feições texturais e feições tonais estão intimamente relacionados, mantendo entre si uma alta dependência, não sendo possível falar isoladamente num em detrimento do outro. Pode-se, entretanto, aceitar a preponderância de um sobre o outro em determinadas situações. Desta forma, pode-se usar uma só feição, textural ou tonal, para caracterizar uma região da imagem. Assim, ao se considerar uma pequena área de imagem onde as variações tonais sejam pequenas, a propriedade dominante é a tonal, isto é, o brilho, definido pelo contador digital. Por outro lado, se esta mesma área

apresenta uma grande variação de primitivas tonais, a característica predominante passa a ser a textura. Essencial nesta distinção entre um tipo e outro de feições é o tamanho da região da imagem, o número, as dimensões relativas e as características das primitivas tonais, que decidem qual dos dois conceitos ( tonal ou textural) é o mais importante na caracterização desta região. É fácil verificar também que, na medida em que o número de primitivas tonais diminuem, mais importante se torna a propriedade tonal. Em contrapartida, com o aumento do número de primitivas tonais, a textura passa a ser a característica dominante. Quando o padrão espacial das primitivas tonais é aleatório, as dimensões das primitivas tonais é pequena e as variações nos contadores digitais são grandes, temos uma textura fina. Na medida em que os padrões espaciais ficam melhor definidos e as dimensões das primitivas tonais se tornam maiores, teremos uma textura grosseira.

Desta forma, para efetivamente caracterizar textura deve-se definir claramente as propriedades das primitivas tonais, bem como a sua inter-relação espacial. Por conseguinte, qualquer processo de análise textural de uma imagem deve levar em conta esses dois aspectos.

### 3.2. TRANSFORMADA DE FOURIER

A transformada bidimensional de Fourier tem sido amplamente utilizada em processos de análise e descrição de imagens, além de outras aplicações. Maiores detalhes a respeito da transformada de Fourier são fornecidos no apêndice. Neste trabalho, explora-se a sua capacidade de identificar frequências espaciais mais representativas presentes na imagem. Estas frequências são, então, utilizadas como parâmetros na confecção dos filtros de Gabor. Estes, por sua vez, são utilizados posteriormente para a seleção de feições utilizadas para fins de classificação da imagem. Esta técnica encontra-se detalhada neste capítulo, na seção 3.4.

#### 3.2.1 DEFINIÇÃO DA TRANSFORMADA DE FOURIER

O par da transformada de Fourier para o caso bidimensional é definido da seguinte forma. Seja  $f(x,y)$  uma função contínua e integrável e  $F(u,v)$  um função integrável. A transformada de Fourier de  $f(x,y)$  é definida por

$$\mathfrak{F}\{f(x,y)\} = F(u,v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x,y) \exp(-2\pi i(ux + vy)) \, dx dy \quad (3.1)$$

e a sua inversa por;

$$\mathfrak{F}^{-1}\{F(u,v)\} = f(x,y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u,v) \exp(2\pi i(ux + vy)) \, du dv \quad (3.2)$$

onde  $u$  e  $v$  representam as frequências espaciais, medidas respectivamente, ao longo das direções  $x$  e  $y$  na imagem. Ademais, o espectro e o espectro de energia de Fourier, são definidos respectivamente por:

$$|F(u, v)| = [\mathbf{Re}^2(u, v) + \mathbf{Im}^2(u, v)]^{1/2} \quad (3.3)$$

e

$$E(u, v) = |F(u, v)|^2 = \mathbf{Re}^2(u, v) + \mathbf{Im}^2(u, v) \quad (3.4)$$

A figura 3.1 ilustra a transformada de Fourier de uma função definida em um espaço tridimensional.

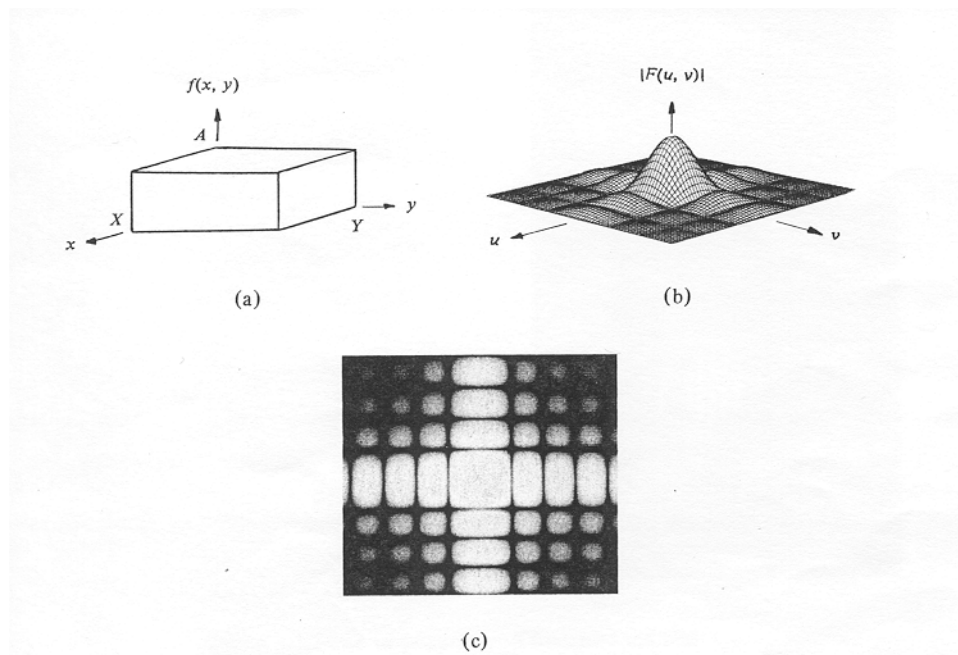


Figura 3.1  
 (a) Uma função tridimensional, (b) Seu espectro de Fourier (c) O espectro de Fourier mostrado como uma função de intensidade. (adaptado de Gonzales & Woods, GONZALES e WOODS (1992)).

### 3.2.2. TRANSFORMADA DISCRETA DE FOURIER

As definições acima são válidas para as funções de variáveis contínuas. Para o caso de imagens digitais, esta definição deve ser estendida para funções de variáveis discretas. Com esta finalidade, a função  $f(x,y)$  pode ser redefinida da seguinte forma:

$$f(x,y) = f(x_0 + x \Delta x, y_0 + y \Delta y), \quad (3.5)$$

onde  $x$  e  $y$  assumem valores discretos de  $0, \dots, M-1$  e  $0, \dots, N-1$ , respectivamente. Dessa forma o par transformada discreta de Fourier é dado por:

$$F(u,v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \exp \left[ -2\pi i \left( \frac{ux}{M} + \frac{vy}{N} \right) \right], \quad (3.6)$$

com  $u = 0, \dots, M-1$  e  $v = 0, \dots, N-1$ .

e sua transformada inversa é dada por:

$$f(x,y) = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u,v) \exp \left[ 2\pi i \left( \frac{ux}{M} + \frac{vy}{N} \right) \right], \quad (3.7)$$

com  $x = 0, \dots, M-1$  e  $y = 0, \dots, N-1$ .

Neste caso, o incremento na amostra discretizada, no domínio espacial e no domínio de frequência são relacionados respectivamente, por:

$$\Delta u = \frac{1}{M\Delta x} \quad (3.8)$$

e

$$\Delta v = \frac{1}{N\Delta y} \quad (3.9)$$

Se as imagens tiverem o mesmo número de linhas e de colunas as transformadas podem ser simplificadas, pois  $M=N$  e portanto:

$$F(u,v) = \frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x,y) \exp \left[ -2\pi i \left( \frac{ux + vy}{N} \right) \right] , \quad (3.10)$$

com  $u, v = 0, \dots, N-1$

e

$$f(x,y) = \frac{1}{N} \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} F(u,v) \exp \left[ 2\pi i \left( \frac{ux + vy}{N} \right) \right] , \quad (3.11)$$

com  $x, y = 0, \dots, N-1$ .

Assim como no caso contínuo, o espectro de energia tem a mesma formulação. A única diferença é que as variáveis  $x, y, u$  e  $v$  são discretas.

### **3.3. EXTRAÇÃO DE FEIÇÕES EM MULTICANAIS TEXTURAIS E FILTROS DE GABOR.**

A textura em uma imagem, pode ser caracterizada por variáveis como orientação, frequência e dimensão do elemento de textura. No processo de classificação de uma imagem, utilizando características ou atributos de textura, torna-se necessário, então, levar em consideração estas variáveis. Investigações feitas em POLLEN e RONNER(1983), relativas à maneira como o ser humano percebe e identifica



características texturais no mundo real, apontam para um método de extração de feições baseado nestas variáveis. Estudos em sistemas de visão biológicos, mostram que a habilidade para reconhecer objetos no mundo real depende parcialmente da percepção de consistência e diferença textural. Certos experimentos mostram que texturas distintas podem ser reconhecidas rapidamente sem necessidade de uma observação mais detalhada. Desta forma, um par de texturas diferentes, apresentado repetidamente e em um intervalo de tempo muito curto, da ordem de milissegundos, podem ser reconhecido e diferenciado, TURNER(1986). Pesquisadores nesta área acreditam que certas áreas do córtex cerebral de mamíferos, responsáveis pela visão, apresentam um número grande de neurônios, alguns agrupados linearmente e vários outros agrupados de forma não-linear. Esta estrutura permite a recepção de uma gama variada de estímulos, tais como a localização em um espaço visual bidimensional, orientação, frequência espacial e profundidade estereoscópica, entre outros, sendo a análise da imagem no córtex semelhante a feita por um tipo de analisador de Fourier no domínio espacial, TURNER(1986). É sabido que representações por meio de transformadas de Fourier são completas, isto é, nenhuma informação da imagem original é perdida durante sua transformação. A transformada de Fourier, entretanto, não deixa explícitas as informações necessárias para uma rápida discriminação de diferentes regiões de textura, pois apenas apresenta as

frequências espaciais presentes na imagem original, não identificando sua posição na mesma. Assim, a representação de uma imagem pela transformada de Fourier não mostra a variação na distribuição do brilho ao longo de uma região na imagem. Por conseguinte, a análise por técnicas de Fourier não revela distribuições locais de brilho ou combinações no brilho da imagem, não sendo então, apropriadas para análise de feições locais ou de TEXELS que caracterizam texturas, TURNER(1986). Portanto, torna-se necessário o uso de outro tipo de filtro que obtenha um desempenho ótimo simultaneamente nos domínios espacial e das frequências. Utilizando a desigualdade de Schwarz, Dennis Gabor, GABOR(1946), demonstrou que, de uma forma análoga à relação de incerteza de Heisenberg, a caracterização de um sinal simultaneamente no domínio temporal e no domínio das frequências espaciais apresenta um limite inferior definido pelo produto de sua extensão pela sua duração.

$$\Delta t \Delta w \geq \frac{1}{4\pi} \quad (3.12)$$


Utilizando os trabalhos de Heisenberg e Weyl, Gabor derivou uma relação de incerteza, encontrando uma família de sinais que alcançavam o limite teórico inferior de incerteza conjunta nos domínios temporal e das frequências. Esta função passou a ser conhecida como função de Gabor e tem a seguinte formulação

$$g(x, \sigma, k) = \exp \left\{ -\frac{1}{2} \left( \frac{x}{\sigma} \right)^2 + 2\pi i k x \right\} \quad (3.13)$$


onde,  $\sigma$  é a extensão do envelope Gaussiano que limita espacialmente o filtro de Gabor e  $k$  a frequência da onda senoidal associada ao filtro MEHROTRA[et al.](1992). A figura 3.2 ilustra as partes real e imaginária deste filtro unidimensional.

Posteriormente, Daugman ampliou o trabalho de Gabor para problemas envolvendo duas dimensões, DAUGMAN(1985). Uma funções de Gabor simula muito bem o comportamento dos perfis de campos receptivos encontrados nas células do córtex cerebral de mamíferos. Estas são as células que capturam propriedades de localização espacial, orientação, frequência espacial, entre outras. Estes filtros são definidos por:

$$g(x, y, \sigma_x, \sigma_y, k_x, k_y) = \exp \left\{ -\frac{1}{2} \left[ \left( \frac{x}{\sigma_x} \right)^2 + \left( \frac{y}{\sigma_y} \right)^2 \right] + (2\pi i (k_x x + k_y y)) \right\} \quad (3.14)$$



(a)



(b)

Figura 3.2

Filtro de Gabor : (a) Componente Real do filtro para valores de  $\sigma = 1$  pixel e  $k = 0.5$  ciclos / pixel ;  
 (b) Componente Imaginária do filtro, para valores de  $\sigma = 1$  e  $k = 0.5$  ciclos / pixel

Uma propriedade importante da abordagem bidimensional dos filtros de Gabor, DAUGMAN(1985), é o fato desses filtros alcançarem o limite teórico inferior de incerteza conjunta nos domínios espacial e das frequências, que é de  $1/16\pi^2$ . Para as variáveis  $(x,y)$ , centradas em  $x_0$  e  $y_0$  no domínio espacial e  $(u,v)$  centradas em  $u_0$  e  $v_0$ , no domínio das frequências, obtém-se, a partir do princípio de incerteza conjunta que

$$(\Delta x) (\Delta y) (\Delta u) (\Delta v) \geq 1/16\pi^2. \quad (3.15)$$

Este princípio afirma que ao se tomar uma área de filtragem no domínio espacial e a aumentarmos, a respectiva área de filtragem no domínio de frequências será diminuída, de forma que o produtos de suas áreas nos dois domínios é

limitado por um valor, conhecido por limite inferior de incerteza conjunta. Pode-se mostrar que para os filtros de Gabor este produto é exatamente igual ao limite mínimo  $1/16\pi^2$ . Os valores de  $(\Delta x)$ ,  $(\Delta y)$ ,  $(\Delta u)$  e  $(\Delta v)$  são dados por:

$$(\Delta x) = \left[ \frac{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x - x_0)^2 f(x, y) f^*(x, y) dx dy}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) f^*(x, y) dx dy} \right]^{1/2}; \quad (3.16)$$

$$(\Delta u) = \left[ \frac{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (u - u_0)^2 F(u, v) F^*(u, v) du dv}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} F(u, v) F^*(u, v) du dv} \right]^{1/2}; \quad (3.17)$$

$$(\Delta y) = \left[ \frac{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (y - y_0)^2 f(x, y) f^*(x, y) dx dy}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) f^*(x, y) dx dy} \right]^{1/2}; \quad (3.18)$$

$$(\Delta v) = \left[ \frac{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (v - v_0)^2 F(u, v) F^*(u, v) du dv}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} F(u, v) F^*(u, v) du dv} \right]^{1/2}; \quad (3.19)$$

sendo  $f^*(x, y)$  e  $F^*(u, v)$ , respectivamente o complexo conjugado de  $f(x, y)$  e  $F(u, v)$ , de tal forma que o produto  $f(x, y) f^*(x, y)$  e  $F(u, v) F^*(u, v)$ , corresponde à distribuição de energia nos respectivos domínios. Ademais, o produto de  $(\Delta x) (\Delta y)$ , determina a área ocupada pelo filtro no domínio espacial e  $(\Delta u) (\Delta v)$  determina a área ocupada pelo filtro no domínio das frequências. Substituindo as equações (3.16), (3.17), (3.18) e (3.19), na expressão (3.14) que

define o filtro bidimensional de Gabor, obtém-se

$$(\Delta x) (\Delta y) = \frac{\sigma_x \sigma_y}{2} \quad (3.20)$$

e

$$(\Delta u) (\Delta v) = \frac{1}{8\pi^2 \sigma_x \sigma_y} \quad (3.21)$$

e, portanto,

$$(\Delta x) (\Delta y) (\Delta u) (\Delta v) = 1/16\pi^2, \quad (3.22)$$

igual ao valor mínimo de incerteza conjunta.

Baseando-se na minimalidade do limite de incerteza conjunta para os filtros de Gabor, a extração de textura, escala e eixos de modulação podem ser efetuadas sem prejudicar extração de informações sobre: localização espacial e relações métricas. Maiores detalhes a respeito desta propriedade dos filtros de Gabor é discutido em DAUGMAN(1985, 1988). Outra importante característica dos filtros de Gabor é que em 97% dos experimentos realizados por pesquisadores, esses filtros forneceram uma aproximação muito boa dos perfis de campos receptivos de células corticais de mamíferos DAUGMAN(1988). A figura 3.3, ilustra a boa aproximação do filtro de Gabor para os perfis de campos receptivos

Os filtros de Gabor vem sendo utilizados com bastante sucesso por vários pesquisadores como BOVIK[et al.](1990), JAIN e FARROKHNIA(1991), entre outros.

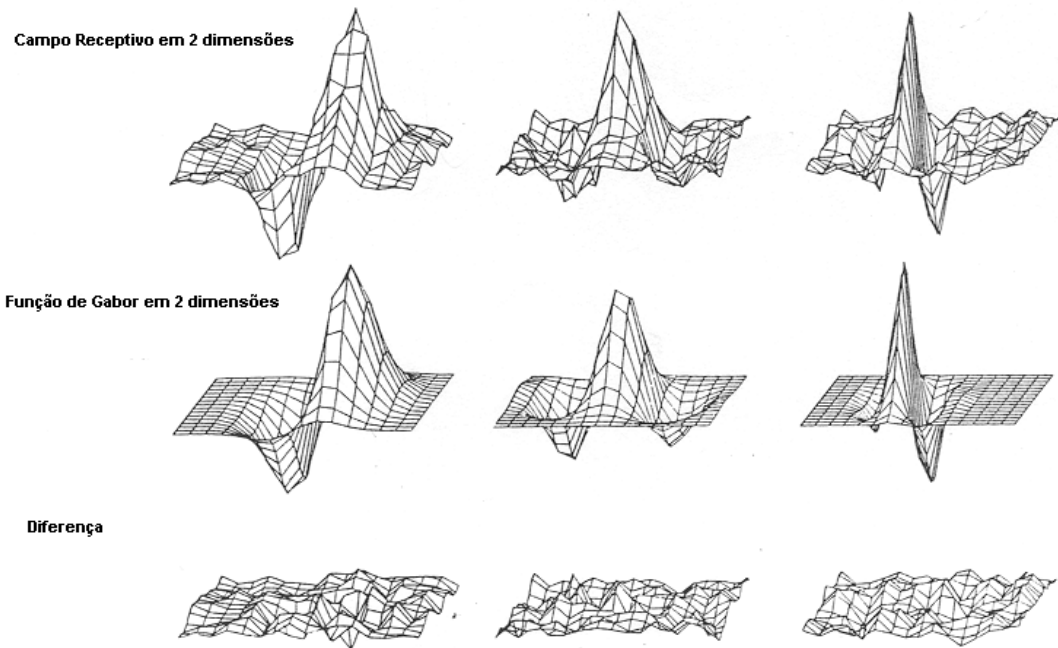


Figura 3.3

Ilustração da medida experimental em duas dimensões dos perfis de campos receptivos de três células simples do córtex de uma gato, obtido em laboratório por Jones e Palmer (linha superior) . Cada gráfico mostra o efeito excitatório e inibitório de um pequeno raio luminoso ou mancha escura na taxa de resposta da célula, como uma função de  $(x,y)$  da localização do estímulo. A segunda linha mostra a aproximação do perfil de campo receptivo pela função de Gabor com os parâmetros adequados. A terceira linha mostra o resíduo entre a função de Gabor e o perfil de campo receptivo. (figura adaptada de Daugman, DAUGMAN(1985))

### 3.4 DEFINIÇÃO DOS FILTROS DE GABOR EM UMA IMAGEM

#### DIGITAL

Os filtros bidimensionais de Gabor são grades senoidais complexas, moduladas por uma função Gaussiana bidimensional, formando funções de valor complexo em  $\mathbb{R}^2$ . A frequência e orientação, definidas pela função senoidal no filtro de Gabor, nos vários canais utilizados, descrevem a estrutura local da textura. O envelope Gaussiano define as resoluções espaciais com que as estruturas de textura são

caracterizadas. A forma geral da Função de Gabor bidimensional é:

$$g(x, y, \sigma_x, \sigma_y, k_x, k_y) = A \exp \left\{ -\frac{1}{2} \left[ \left( \frac{x}{\sigma_x} \right)^2 + \left( \frac{y}{\sigma_y} \right)^2 \right] + 2\pi i (k_x x + k_y y) \right\} \quad (3.23)$$

onde, A é um fator de escala e neste trabalho, A=1 e  $(\sigma_x, \sigma_y)$  definem a extensão espacial da função de Gabor. A orientação da grade senoidal é fornecida por  $\text{tg}^{-1}(k_y/k_x)$ . A frequência da onda senoidal é dada por  $k=(k_x, k_y)$ , onde  $k_x, k_y$  são suas componentes ao longo dos eixos x e y, respectivamente. O módulo de k é dado por  $|k| = \sqrt{k_x^2 + k_y^2}$ . Tomando-se as partes reais e imaginárias de (3.23), tem-se as componentes par e ímpar da função de Gabor, isto é:

$$\text{Re}[g(x, y, \sigma_x, \sigma_y, k_x, k_y)] = \exp \left\{ -\frac{1}{2} \left[ \left( \frac{x}{\sigma_x} \right)^2 + \left( \frac{y}{\sigma_y} \right)^2 \right] \right\} \cos(2\pi (k_x x + k_y y)) \quad (3.24)$$

$$\text{Im}[g(x, y, \sigma_x, \sigma_y, k_x, k_y)] = \exp \left\{ -\frac{1}{2} \left[ \left( \frac{x}{\sigma_x} \right)^2 + \left( \frac{y}{\sigma_y} \right)^2 \right] \right\} \text{sen}(2\pi (k_x x + k_y y)) \quad (3.25)$$



Todas as três formas dos filtros de Gabor são usadas em aplicações de visão de máquina, NAMURIDI[et al.](1994). A figura 3.4, ilustra um típico filtro de Gabor.

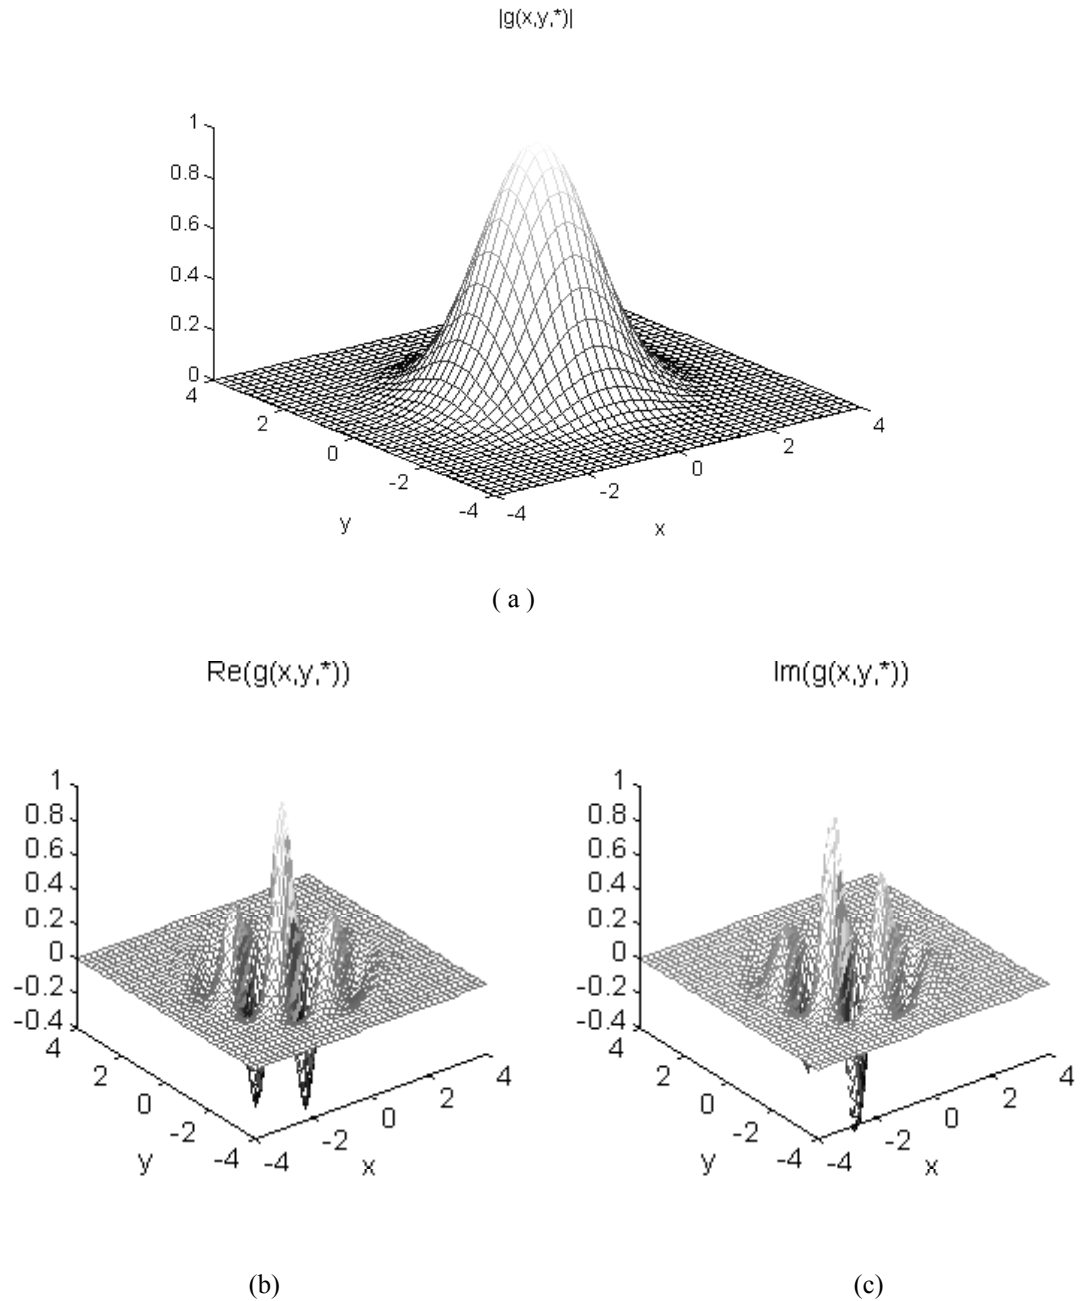


figura 3.4

(a) Filtro de Gabor bidimensional apresentado em valores absolutos (b) Componente real do filtro de Gabor (c) Componente imaginária do filtro de Gabor, ambos para valores  $\sigma_x = \sigma_y = 4$ ,  $k_x = -0.5$  e  $k_y = 0.5$  ciclos / pixel. O valor \* em parêntese corresponde a  $(\sigma_x, \sigma_y, k_x, k_y)$ .

A transformada de Fourier da função de Gabor (3.23) é dada por :

$$G(u, v, \sigma_x, \sigma_y, k_x, k_y) = \sigma_x \sigma_y \exp\left\{-\frac{1}{2}\left[(u - k_x)^2 \sigma_x^2 + (v - k_y)^2 \sigma_y^2\right]\right\} \quad (3.26)$$

No domínio das frequências, o filtro de Gabor pode ser obtido, aplicando-se a transformada de Fourier à expressão (3.24)

$$G(u, v, *) = \sigma_x \sigma_y \left[ \exp\left\{-\frac{\sigma_x^2}{2}\left[(u - k_x)^2 + (v - k_y)^2\right]\right\} + \exp\left\{-\frac{\sigma_y^2}{2}\left[(u + k_x)^2 + (v + k_y)^2\right]\right\} \right] \quad (3.27)$$

Observa-se que no domínio das frequências espaciais, essa função, através das propriedades da transformada de Fourier, torna-se duas funções Gaussianas centradas em  $-(k_x, k_y)$  e  $+(k_x, k_y)$ , respectivamente. (figura 3.5). Pelo princípio de incerteza anteriormente mencionado, tem-se que as áreas efetivamente ocupadas pelo filtro definido em (3), podem ser obtidas a partir das equações (3.16), (3.17), (3.18) e (3.19).

$$\text{Área no domínio espacial} = (\Delta x) (\Delta y) = \frac{\sigma_x \sigma_y}{2}$$

e

$$\text{Área no domínio das frequências} = (\Delta u) (\Delta v) = \frac{1}{8\pi^2 \sigma_x \sigma_y}.$$

Tem-se, portanto,  $(\Delta x) (\Delta y) (\Delta u) (\Delta v) = 1/16\pi^2$ , limite mínimo de incerteza conjunta, conforme exposto anteriormente.




Figura 3.5  
 (a) Filtro de Gabor bidimensional (componente Real) no Domínio espacial  
 (b) resposta de frequência do filtro definido em (a)

A imagem processada por um filtro de Gabor é obtida através da convolução da imagem com a função de Gabor, que pode ser implementada tanto no domínio das frequências como diretamente no domínio espacial, usando-se para isso (3.26) ou (3.23), respectivamente. Após o processo de convolução obtém-se uma imagem filtrada formada por valores imaginários. A imagem assim formada, por conter uma componente imaginária, não pode ser diretamente representada. Uma alternativa, neste caso, consiste na representação através de valores absolutos (módulo) ou o quadrado deste, conhecido como energia. A energia de cada pixel é dada por:

$$f(x,y) = |I(x,y) * g(x,y)|^2 \quad (3.28)$$

onde, \* significa convolução,  $I(x,y)$  representa a imagem original e  $g(x,y)$  o filtro de Gabor, tomado com os parâmetros  $k_x$ ,  $k_y$ ,  $\sigma_x$ ,  $\sigma_y$ , previamente escolhidos, conforme definido acima.

### 3.5. ESCOLHA DA FREQUÊNCIA ESPACIAL DO FILTRO

A caracterização rigorosa de uma textura exige um número muito grande de frequências espaciais. Na prática, torna-se inviável o emprego de todas as frequências espaciais presentes devido ao excessivo custo computacional que representa. Neste estudo, optou-se por representar cada textura por um número reduzido de frequências espaciais que melhor preservassem as características da textura original, mantendo o nível de informação necessário à caracterização das diferentes regiões da imagem. Na seleção das frequências espaciais a serem mantidas, para efeitos de classificação, dois principais critérios são adotados: (1) mais alto nível de energia da frequência espacial e (2) orientações destas frequências. Na realidade, o critério (2) torna-se necessário somente nos casos em que as frequências obtidas em (1) para duas texturas distintas forem muito próximas entre si, caso em que o poder discriminatório ficaria bastante reduzido. Estas propriedades são facilmente ilustradas na análise do espectro de Fourier da amostra representativa de uma determinada classe componente da imagem, conforme a figura 3.6. Assim, o uso de certas frequências espaciais presentes em mais de uma classe de textura apenas contribui para o aumento do custo computacional do processo de classificação, contribuindo muito pouco para o poder

discriminatório do método. Desta forma, estas frequências devem ser eliminadas, mantendo-se somente aquelas que são características de uma única classe.

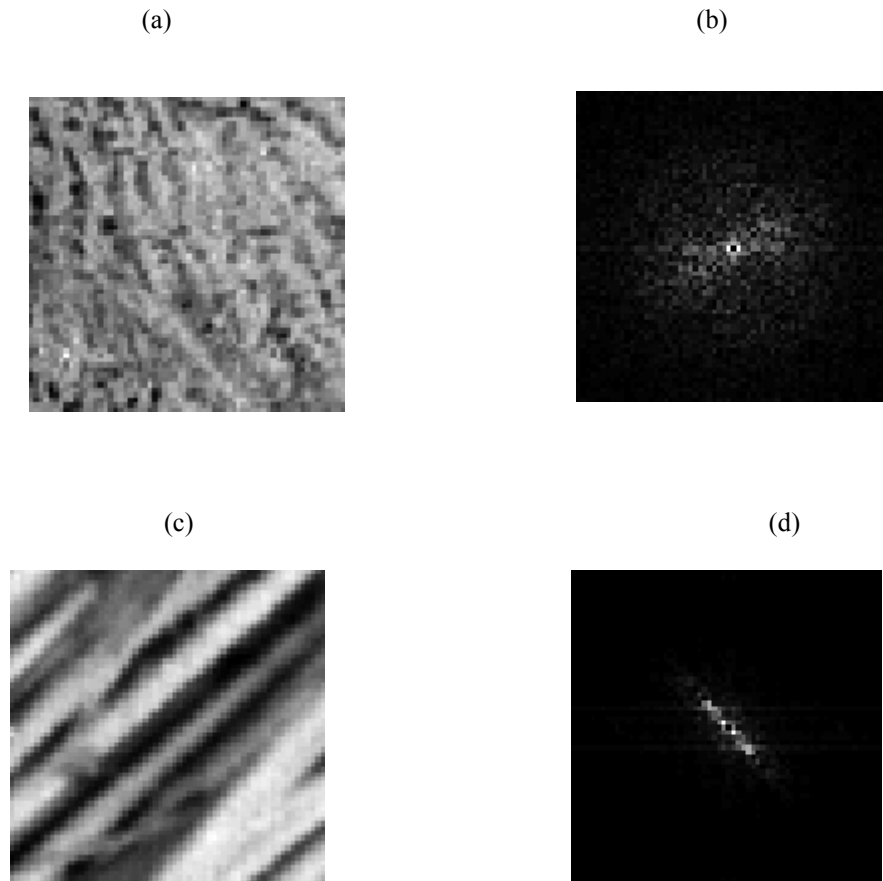


Figura 3.6

(a) Imagem de padrão textural (b) Transformada de Fourier da imagem em (a)  
 (c) Imagem de padrão textural (d) Transformada de Fourier da imagem em (a)

A partir dos espectros de Fourier determinados em (b) e (d), onde o centro da figura corresponde à origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical). Pode-se verificar que as frequências com maior energia encontram-se no centro do espectro de Fourier e são bastante similares. Portanto, estas frequências não são adequadas para discriminar estas texturas, contudo, frequências menos energéticas afastadas do centro do Espectro de Fourier ao longo da orientação principal do espectro são mais eficientes no processo de discriminação entre as duas imagens em (a) e (c)

### 3.6. ESCOLHA DA DIMENSÃO E EXTENSÃO ESPACIAL DO FILTRO

O valor do contador digital assim como a localização espacial de pixels numa imagem são considerados como feições de 1º ordem. Estas feições não estão relacionadas com o contexto, segundo Coleman e Andrews, RAGHU[et al.](1995). As feições de ordem mais alta estimam as características ou propriedades ao longo de uma região. Logo, em análise textural, as feições de 1º ordem não têm um papel preponderante, pois a textura é uma propriedade de contexto só podendo ser interpretada através da análise conjunta de um grupo de pixels numa determinada região da imagem. Esse grupo de pixels que carrega uma determinada propriedade ou estatística local e que se repete ao longo da região textural caracteriza o que já foi definido como TEXEL. Uma etapa indispensável para uma boa análise de textura é a identificação e a extração de algumas feições de textura capazes de caracterizar eficientemente as diferentes classes presentes na imagem. É razoável supor que cada classe presente na imagem apresenta dimensões de TEXEL próprias. Surge, portanto, a necessidade de se encontrar uma resolução ótima de TEXEL, cujas dimensões sejam suficientemente grandes a fim de capturar as características de cada uma das texturas envolvidas. A proposta apresentada neste trabalho consiste em:

(1) escolher para cada amostra de classe as frequências espaciais mais representativas de suas características texturais, utilizando a transformada de Fourier;

(2) Determinar os valores para  $\mathbf{dim}_x$  e  $\mathbf{dim}_y$  que definem as dimensões do filtro de Gabor, de forma a abranger, no mínimo, um período completo da frequência espacial implementada no filtro de Gabor. Como o período é igual ao inverso da frequência, os valores de  $\mathbf{dim}_x$  e  $\mathbf{dim}_y$ , que correspondem às dimensões do filtro de Gabor, podem, em princípio, ser tomados como o inverso da frequência que descreve o padrão que está sendo analisado:

$$\mathbf{dim}_x = 1/k_x \text{ e } \mathbf{dim}_y = 1/k_y \quad (3.29)$$

Na prática, podem ocorrer frequências muito baixas ou muito altas. Estas frequências podem gerar filtros degenerados quando uma das dimensões  $x$  ou  $y$  deste filtro tende ao infinito, o que ocorre quando uma das frequências tende a 0 (zero). Outro filtro degenerado ocorre quando apenas um único pixel é tomado para uma de suas dimensões. Isto ocorre quando uma das frequências é igual  $N-1/N$  (onde  $N$  representa a dimensão da amostra tomada, tanto ao longo do eixo  $x$  quanto do eixo  $y$ ). O maior problema reside nos filtros de dimensões infinitas.

Optou-se neste estudo, para contornar este problema, pela adoção de um único valor para a dimensão do filtro, isto é:

$$\mathbf{Dim} = \mathbf{dim}_x = \mathbf{dim}_y. \quad (3.30)$$

tal que

$$\mathbf{Dim} = \max( 1/k_x , 1/k_y ) \quad (3.31)$$

No caso de filtros em que uma das frequências envolvidas  $k_x$  ou  $k_y$  tende ao valor 0(zero) e que, gera no filtro uma dimensão tendendo ao infinito, atribui-se como dimensão correspondente a esta frequência no filtro, a maior dimensão da amostra (obtida da imagem) que gerou esta frequência. Desta forma, fica assegurado que a dimensão do filtro é suficiente para capturar a frequência em questão.

A expressão (3.31) irá gerar um filtro com dimensões constantes. Este fato, entretanto, não afetará a seleção de feições texturais, uma vez que as dimensões do filtro serão sempre maiores que a dimensão mínima necessária para caracterizar as frequências utilizadas.

Convém aqui recordar que o filtro de Gabor é ponderado por um envelope Gaussiano (3.23). A forma da função que define este envelope é definida pelo parâmetro  $\sigma$ , denominado neste contexto de "extensão espacial" do filtro. Dessa forma é aconselhável para cobrir 99.73% da



dimensão do filtro, utilizar-se de uma extensão espacial tal que

$$\sigma = \text{Dim}/6, \quad (3.32)$$

conforme ilustra a figura 3.7




Figura 3.7  
Ilustração do valor modular do Filtro de Gabor com  $\sigma=1$  e dimensão do filtro =6,  
Cobrindo com esta extensão 99.73% da área coberta pelo filtro de Gabor

Todavia neste processo pode ocorrer um problema. Considere dois filtros distintos projetados para frequências distintas e por conseguinte com extensões espaciais diferentes. Pode ocorrer, neste caso, que no processo de filtragem da imagem o filtro com extensão espacial menor, isto é, desenhado para capturar uma frequência mais alta, acabe por capturar, frequências mais baixas em outra região textural, de uma forma parcial e incompleta. Dessa forma, podem ser geradas informações errôneas que irão degradar o resultado do classificador. Neste estudo adotou-se o seguinte procedimento, para evitar este problema: toma-se como extensão espacial para todos os

filtros de Gabor, um valor único é igual a máxima extensão espacial,

$$\sigma = \text{máximo } (\sigma_i), \quad (3.33)$$

onde  $\sigma_i$  = extensão espacial de cada filtro e  $i=(1, \dots, \text{número de filtros})$ . O aumento da extensão espacial ( $\sigma$ ) no domínio espacial aumenta a área de filtragem e conseqüentemente, através do princípio de incerteza reduzir-se-á a área de filtragem no domínio das frequências, o que ocasiona uma diminuição das frequências capturadas pela filtro e dessa forma é minimizado o efeito de sobreposição de frequência o que melhora classificação, mas exige um número maior de filtros.

Embora o uso de extensão espacial relacionada a cada par de frequência espacial ( $k_x$  e  $k_y$ ) de cada filtro também ofereça um bom resultado, na maioria dos casos, o uso de extensão espacial única minimiza as possíveis distorções acima mencionadas, apresentando dessa forma um resultado mais homogêneo. Entretanto para imagens texturais formadas por um número elevado de frequências espaciais este bom resultado somente ocorre se for utilizado um número muito grande de filtros de Gabor, como ficará evidenciado em alguns experimentos do capítulo 4.

### **3.7. CLASSIFICAÇÃO DE IMAGEM COM BANCO DE FILTROS DE GABOR NO DOMÍNIO ESPACIAL**

Embora o filtro de Gabor possa ser usado para o processo de filtragem tanto no domínio espacial quanto no

domínio das frequências, a filtragem no domínio espacial diminui o custo computacional, pois neste caso não se torna necessário nem a transformação da imagem original, nem do filtro para o domínio das frequências e posterior retorno do resultado ao domínio espacial.

O processo de classificação proposto neste estudo é do tipo supervisionado. Assim, o passo inicial consiste na seleção de amostras representativas das classes texturais presentes na imagem. Por meio da transformada de Fourier aplicada a estas amostras, selecionam-se as frequências representativas das classes presentes na imagem. Esta seleção é feita através da análise do espectro de energia no domínio de frequências, conforme descrito em seção anterior. Após, com base nestas frequências, determinam-se os parâmetros restantes  $\sigma_x$  e  $\sigma_y$  necessários à confecção do filtro de Gabor, obtidos a partir da relação entre a frequência dominante e a dimensão do filtro já descrita anteriormente, de tal modo que  $\sigma = \sigma_x = \sigma_y$ . São, dessa forma, definidos os vários filtros de Gabor que serão utilizados num passo posterior, no processo de convolução com a imagem original. O processo de convolução da imagem com um dos filtros de Gabor gera uma seqüência de imagens filtradas, normalizadas segundo os valores dos contadores digitais obtidos pela filtragem, de forma a que cada imagem filtrada tenha o mesmo intervalo de brilho, padronizado entre 0 e 255, afim de que o fator de brilho de cada classe textural na imagem original não interfira na classificação das

classes texturais. Estas imagens filtradas individualmente identificam uma determinada frequência espacial. Como cada frequência espacial está associada, ou é representativa de uma classe textural, as imagens filtradas podem ser entendidas como "bandas texturais", à semelhança de uma imagem multiespectral que é formada por um certo número de "bandas espectrais". O processo de classificação pode então ser efetivado, utilizando classificadores paramétricos como, por exemplo, a Máxima Verossimilhança Gaussiana. Maiores detalhes sobre este classificador pode ser encontrado no apêndice. Na figura 3.8 é ilustrado o processo acima descrito

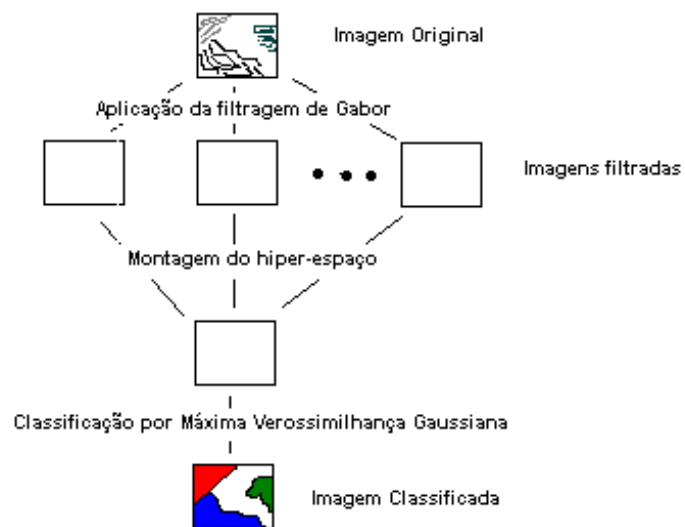


figura 3.8

Estrutura do processo de classificação com bancos de filtros de Gabor no domínio espacial

## **CAPÍTULO IV**

### **EXPERIMENTOS**

#### **4.1-INTRODUÇÃO**

O objetivo deste capítulo consiste em testar a eficiência e a exatidão dos algoritmos propostos no capítulo III.

Inicialmente, a metodologia proposta é testada utilizando um sinal unidimensional. A simplicidade e a facilidade de visualização o torna ideal para fins de um melhor entendimento da metodologia. O algoritmo proposto foi testado também em imagens sintéticas e reais. Enquanto as imagens reais, como as utilizadas em sensoriamento remoto, permitem uma avaliação da metodologia proposta nas condições encontradas em situações reais, as imagens sintéticas, por terem uma estrutura perfeitamente conhecida pelo analista, permitem uma compreensão melhor do funcionamento da metodologia proposta.

Experimentos diversos foram realizados utilizando-se de ambas as categorias de imagem. Neste capítulo, estes experimentos são descritos e analisados de forma a permitir uma avaliação da metodologia proposta e apresentada no capítulo III.

Cada experimento desenvolve-se segundo as seguintes etapas:

- identificação visual das classes presentes na imagem utilizando-se atributos de textura.
- extração de frequências que caracterizam cada classe textural particular.

- formação dos correspondentes filtros de Gabor para cada uma das frequências espaciais selecionadas.
- convolução da imagem com cada um dos filtros de Gabor.

Esta etapa gera um número de imagens filtradas igual ao número de filtros de Gabor construídos. Estas imagens filtradas respondem por características de textura e podem ser entendidas como "canais ou bandas texturais", à semelhança de bandas espectrais, que evidenciam as características espectrais de cada classe.

- treinamento do classificador. Nesta etapa são estimados, para cada classe textural individualmente, os parâmetros necessários ao classificador adotado. No caso do classificador de Máxima Verossimilhança Gaussiana, estes parâmetros são o vetor média e a matriz covariância de cada classe. A dimensionalidade do espaço no qual a classificação será efetuada é igual ao número de "canais de textura " ou do número de filtros de Gabor utilizados.

- classificação da imagem propriamente dita.

Para a realização dos experimentos , são utilizadas as seguintes imagens:

a- imagens sintéticas:

- imagens formadas utilizando-se de funções matemáticas (função seno)
- imagens de textura reais extraídas do "álbum de Brodatz".

b- Imagem Real

- imagem digitalizada (formato raster) a partir de uma fotografia aérea, cobrindo áreas da região metropolitana de Porto Alegre - RS, apresentando classes de textura distintas.

Todas estas imagens, sintéticas e real, apresentam classes distintas que podem ser identificadas pelo atributo de textura permitindo, desta forma, uma avaliação bastante completa da metodologia proposta no capítulo III.

O primeiro conjunto de experimentos foi desenvolvido utilizando uma imagem sintética (figura 4.1). O segundo conjunto de experimentos foi realizado a partir de uma imagem-mosaico de texturas reais (figura 4.10), obtidas do álbum de Brodatz, BRODATZ(1966). Finalmente, o terceiro conjunto de experimentos fez uso de uma imagem real (figura 4.17).

Todos os experimentos mostrados neste capítulo foram realizados com uso dos seguintes recursos de *hardware* e *software*:

- PC pentium, 166 Mhz, 256Mb de RAM, monitor SVGA colorido (800 x 600) e 2.0 Gb de disco rígido;
- Scanner Hewlett Packard HP Scanjet 6200 c;
- Sistema Operacional *Windows 95*;
- software MATLAB for Windows, desenvolvido pela Math Works, Inc., versão 5.3.
- MULTISPEC APPLICATION, desenvolvido pela *Purdue Research Foudation*, versão 1.2.

## **4.2- EXPERIMENTOS ENVOLVENDO IMAGENS SINTÉTICAS**

### **4.2.1 SINAL UNIDIMENSIONAL**

#### **4.2.1.1 EXPERIMENTO 1**

O primeiro teste é desenvolvido a partir de um sinal (unidimensional) sinteticamente formado, utilizando uma função seno. Este sinal é formado por três intervalos com frequências distintas de 1/128, 10/128 e 4/128 Hertz, para cada intervalo como ilustra a figura 4.1. A partir deste momento passam a ser chamadas de classes, ao longo deste experimento, os referidos intervalos mencionados acima.

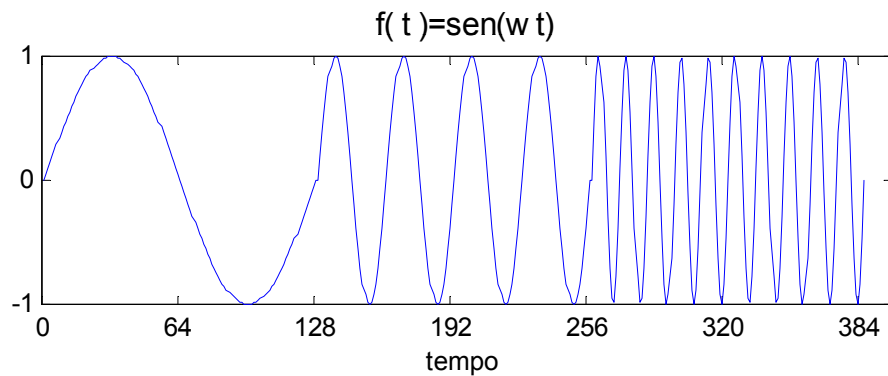


Figura 4.1  
Sinal formado pela função seno e composto por três classes

Os filtros de Gabor unidimensionais foram confeccionados com os seguintes parâmetros: frequências idênticas às acima descrita e utilizando-se como parâmetro  $\sigma$  (extensão espacial) os valores:  $128/6$ ,  $128/60$  e  $128/24$  segundos, respectivamente, conforme descrito na metodologia do capítulo III, de forma que os filtros gerados por estes parâmetros possam cobrir no mínimo um período completo da frequência implementada neste filtro.

Os resultados obtidos são ilustrados na figura 4.2, onde cada filtro específico para detecção de uma feição pertencente a uma determinada classe é representado pelas cores vermelho, verde e azul.

Nota-se que alguns filtros salientam tanto as características de uma classe como as de outra. Isto pode ser observado na filtragem da classe de frequência  $1/128$  Hertz e na filtragem da classe de frequência  $4/128$  Hertz, o mesmo ocorrendo entre a filtragem da classe de frequência  $10/128$  Hertz e a filtragem da classe de frequência  $4/128$  Hertz. Esse efeito existente entre as classes é devido a certa similaridade entre suas frequências. Assim, ao se tomar um filtro com extensão espacial  $\sigma$ , que cobre um período completo de determinada frequência pertencente a uma classe, pode ocorrer que este filtro não cubra um período completo de outra frequência determinante de uma






Figura 4.2

Resultado da convolução do sinal original (figura 4.1) com os três filtros de Gabor. O valor de  $\sigma$  em cada caso é proporcional a frequência representativa da classe. Em vermelho o resultado da filtragem, utilizando o filtro apropriado para a frequência 1/128 Hertz, em verde o resultado da filtragem, utilizando o filtro apropriado para a frequência 10/128 Hertz e em azul o resultado da filtragem, utilizando o filtro apropriado para a frequência 4/128 Hertz.

feição pertencente à outra classe. Desta forma, este filtro captaria parcialmente características de uma outra frequência, gerando assim uma má interpretação desta feição. As dimensões dos filtros neste exemplo são ilustrado na figura 4.3.

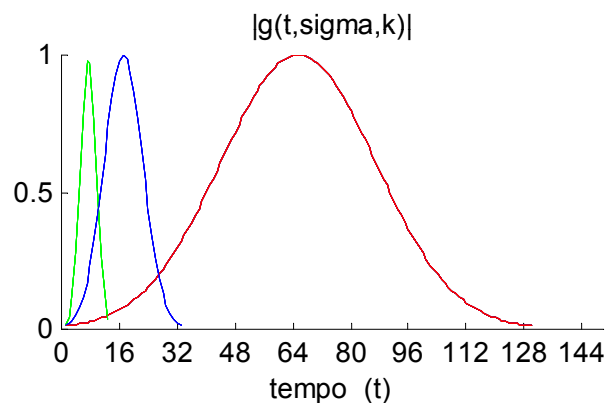


Figura 4.3

Dimensões dos filtros definidos por seus respectivos  $\sigma$ . Nota-se que os filtros em verde e azul, quando centrados no filtro vermelho captam parte da feição por ele determinado.

Conforme descrito no capítulo III, para minimizar o problema acima mencionado toma-se um único  $\sigma = \max(\sigma_i)$ , com  $i=1, \dots, n$  ( $n$ =número de filtros). Desta forma, cobre-se, no mínimo, um período completo e nunca menos de um período completo, para qualquer classe componente da imagem ou sinal a ser classificado.

#### 4.2.1.2 EXPERIMENTO 2

Um outro experimento foi então realizado, convoluindo o sinal ilustrado na figura 4.1 com filtros de Gabor que utilizam as mesmas frequências do experimento anterior, porém, com um valor uniforme para a extensão espacial  $\sigma$  igual a  $\sigma = \max(\sigma_i)$ ,  $i=1, \dots, \text{número de filtros}$ . Os resultados deste processo estão ilustrados na figura 4.4 e as dimensões dos filtros usados são ilustrados na figura 4.5. Cabe ressaltar aqui que quanto maior for o valor de  $\sigma$  adotado, melhor será a separabilidade das classes no processo de classificação.

Neste experimento o sinal analisado é constituído por uma única frequência para cada classe. Em situações reais, cada classe é constituída por várias frequências. Este fato é verdadeiro no caso de imagens reais. Para estas imagens, a captura e posterior classificação das características texturais de cada classe exige o emprego de uma número maior de frequências espaciais por classe e, portanto, um número correspondentemente maior de filtros de Gabor. Esta particularidade será analisada em maior detalhe nos experimentos envolvendo imagens reais.




Figura 4.4

Resultado da convolução do sinal original (figura 4.1) com os três filtros de Gabor. O valor de  $\sigma$  para todos os filtros é constante e igual ao  $\max(\sigma_i)$ ,  $i=1,\dots,$ número de filtros. Em vermelho, tem-se o resultado da filtragem utilizando o filtro apropriado para a frequência 1/128 Hertz, em verde, o resultado da filtragem utilizando o filtro apropriado para a frequência 10/128 Hertz e em azul, o resultado da filtragem utilizando o filtro apropriado para a frequência 4/128 Hertz.

Um outro fato importante a ser destacado aqui é que a amplitude do sinal não interfere na classificação das classes, conforme ilustrado na figuras 4.6 e 4.7.

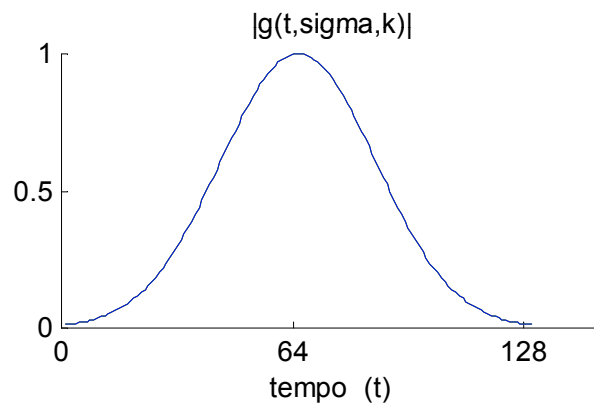


Figura 4.5

Dimensão dos filtros com  $\sigma$  único utilizados para segmentar o sinal unidimensional, ilustrado na figura 4.1




Figura 4.6

Sinal utilizando a função seno e formado por três classes com diferentes amplitudes e frequências.

Entretanto, a figura 4.8 que ilustra duas classes com idêntica frequência, mas amplitudes diferentes e uma terceira classe com frequência distinta das duas primeiras é utilizada para mostrar que a amplitude do sinal somente afeta sinais de mesma frequência pois, nesse caso, o sinal de maior amplitude será evidenciado em relação ao seu similar de menor amplitude, conforme ilustra a figura 4.9.

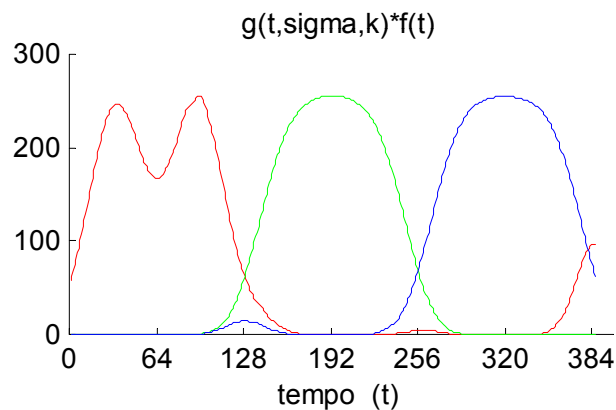


Figura 4.7

Resultado da convolução do sinal unidimensional composto por diferentes amplitudes (figura 4.6) com os três filtros de Gabor. O valor de  $\sigma$  para todos os filtros é constante e igual ao  $\max(\sigma_i)$ ,  $i=1, \dots, \text{número de filtros}$ . Em vermelho, o resultado da filtragem utilizando o filtro apropriado para a frequência 1/128 Hertz, em verde, o resultado da filtragem utilizando o filtro apropriado para a frequência 10/128 Hertz e em azul, o resultado da filtragem utilizando o filtro apropriado para a frequência 4/128 Hertz.




Figura 4.8

Sinal utilizando a função seno, formado por três classes com diferentes amplitudes, tendo a primeira e terceira classes a mesma frequência, porém com amplitudes diferentes

Nota-se que as duas classes de mesma frequência, mas de amplitudes diferentes foram bem discriminadas em relação à terceira classe. A classe que possui maior amplitude obteve, entretanto, um realce maior após o processo de filtragem. Este experimento é ilustrativo da dificuldade em analisar sinais com frequências idênticas, mas diferentes amplitudes.

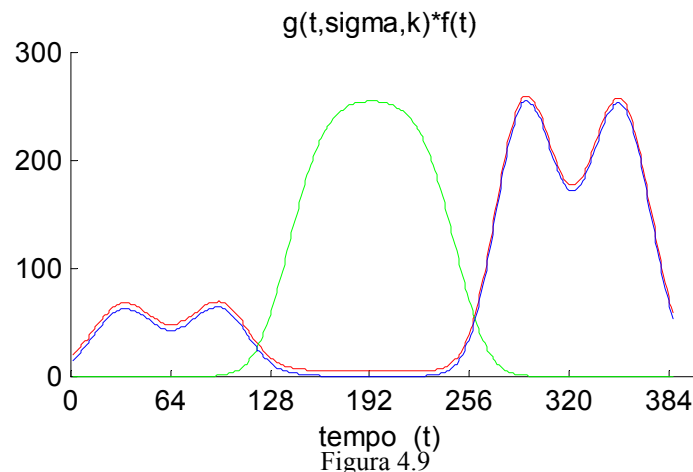


Figura 4.9

Resultado da convolução do sinal unidimensional composto por diferentes amplitudes, com duas classes apresentando a mesma frequência espacial (figura 4.8), com os três filtros de Gabor. O valor de  $\sigma$  para todos os filtros é constante e igual ao  $\max(\sigma_i)$ ,  $i=1, \dots, \text{número de filtros}$ . Em vermelho, tem-se o resultado da filtragem utilizando o filtro apropriado para a frequência 1/128 Hertz, em verde, o resultado da filtragem, utilizando o filtro apropriado para a frequência 10/128 Hertz e em azul, o resultado da filtragem utilizando o filtro apropriado para a frequência 4/128 Hertz. A curva em vermelho foi artificialmente deslocada para evidenciar o comportamento igual à curva em azul, pois, do contrário, ela seria sobreposta pela azul.

#### 4.2.2 IMAGEM SINTÉTICA DE FREQUÊNCIA ÚNICA POR CLASSE

Nesta seção são apresentados alguns experimentos envolvendo duas imagens sintéticas e uma imagem real.

A primeira imagem sintética é composta por quatro classes, cada classe formada por uma frequência. Esta imagem foi gerada por meio de um conjunto de funções trigonométricas, mais especificamente de funções seno bidimensional. A dimensão da imagem é de 256 x 256 pixels e a origem (0,0) de seus eixos encontra-se no canto superior esquerdo, conforme ilustra a figura 4.10. Ressalta-se que a posição da origem dos eixos bem como as respectivas orientações de abscissas e ordenadas serão utilizadas em todas as imagens neste trabalho. As quatro classes foram criadas utilizando-se as seguintes frequências: 4/128 e 8/128 ciclos/pixel na direção do eixo y e 12/128 e 20/128 ciclos/pixel na direção do eixo x.




Figura 4.10  
Imagem sintética de frequência única por classe

##### 4.2.2.1. EXPERIMENTO 1

Para classificar a imagem sintética de frequência única por classe (figura 4.10), os quatro filtros de Gabor necessários tem como parâmetros as mesmas frequências mencionadas acima e para extensão espacial são tomados os

valores de 128/24, 128/48, 128/72 e 128/120 pixels, correspondentes a cada frequência. Cada filtro gera respectivamente uma imagem filtrada, conforme ilustra a figura 4.11. A numeração nessa figura, como nas demais ao longo da dissertação não representam as classes texturais, mas a ordem das filtragens.




Figura 4.11

Imagens filtradas pelos filtros de Gabor para o experimento 1 na imagem sintética de frequência única

A partir do hiperespaço gerado pelos filtros de Gabor, conforme descrito no capítulo anterior, procede-se então à classificação da imagem, sabendo-se que o classificador de Distância Mínima resulta de uma simplificação do classificador de Máxima Verossimilhança Gaussiana, no qual são assumidas três condições:

- 1- todas as probabilidades de ocorrência das classes são iguais, isto é,  $P(w_i) = P(w_j), \forall i, j$ .
- 2- as matrizes de covariância das classes são iguais entre si. ( $\Sigma_1 = \Sigma_2 = \dots = \Sigma_n = \Sigma$ );
- 3- a matriz de covariância ( $\Sigma_i$ ) é igual a  $\sigma^2 \mathbf{I}$ , onde  $\sigma^2$  é a variância e  $\mathbf{I}$  é a matriz identidade, tal que  $|\Sigma_i| = \sigma^2$ .

Como no presente experimento estas condições, embora não rigorosamente observadas, não são grosseiramente violadas optou-se pelo classificador de Distância Mínima por razão de simplicidade computacional. (Maiores detalhes

sobre este classificador pode ser encontrado no apêndice). Este resultado é ilustrado na figura 4.12.




Figura 4.12

Imagem classificada referente ao experimento 1 da imagem sintética de frequência única

A exatidão obtida para esta classificação é apresentada na tabela 4.1.

TABELA DA MATRIZ DE ERRO

Imagem Referência	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	96.78	3.22	<b>16384</b>	15856	38	490	0
Classe 2	97.52	2.48	<b>16384</b>	65	15978	96	245
Classe 3	96.59	3.41	<b>16384</b>	113	445	15826	0
Classe 4	98.29	1.71	<b>16384</b>	0	253	27	16104
<i>Número de Pixels da Imagem Classificada</i>			<b>65536</b>	<b>16034</b>	<b>16714</b>	<b>16439</b>	<b>16349</b>
Erro de Comissão (%)				1.09	4.49	3.74	1.50
<b>EXATIDÃO GERAL (%)*</b>			<b>97.30</b>				

\* exatidão com relação à imagem de Referência

Tabela 4.1

Tabela da Matriz de Erro para classificação da imagem textural de frequência única no experimento 1

#### 4.2.2.2. EXPERIMENTO 2

Com a finalidade de testar o efeito de extensão espacial dos filtros de Gabor no processo de classificação,



desenvolveu-se um segundo experimento utilizando-se as mesmas frequências do experimento anterior, porém com extensão espacial única igual ao maior valor das extensões espaciais tomadas, isto é, 128/24. São obtidas quatro novas imagens filtradas, conforme ilustrado na figura 4.13




Figura 4.13

Imagens filtradas pelos filtros de Gabor para o experimento 2 na imagem sintética de frequência única

Como no caso do experimento anterior, os parâmetros vetor média de cada de cada uma das quatro classes foram estimados a partir de amostras de igual tamanho e centradas em cada classe, neste espaço de dimensão quatro e então o classificador de Distância Mínima foi implementado. A imagem classificada está ilustrada na figura 4.14.




Figura 4.14

Imagem classificada referente ao experimento 2 da imagem sintética de frequência única

A exatidão obtida para esta classificação é apresentada na tabela 4.2.

TABELA DA MATRIZ DE ERRO

	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
Imagem Referência				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	99.75	0.25	<b>16384</b>	16343	41	0	0
Classe 2	99.02	0.98	<b>16384</b>	160	16224	0	0
Classe 3	96.88	3.13	<b>16384</b>	512	0	15872	0
Classe 4	99.52	0.48	<b>16384</b>	79	0	0	16305
<i>Número de Pixels da Imagem Classificada</i>			<b>65536</b>	<b>16034</b>	<b>16714</b>	<b>16439</b>	<b>16349</b>
Erro de Comissão (%)				4.58	0.25	0.00	0.00
<b>EXATIDÃO GERAL (%)*</b>			<b>98.79</b>				

\* exatidão com relação a imagem de Referência

Tabela 4.2

Tabela da Matriz de Erro para classificação da imagem textural de frequência única no experimento 2

#### 4.2.2.3. EXPERIMENTO 3

Com a finalidade de testar a influência da extensão espacial dos filtros de Gabor, o experimento anterior foi repetido, alterando-se somente o valor comum adotado para extensão espacial dos quatro filtros de Gabor. Neste experimento utilizou-se um valor duas vezes maior do que o valor comum adotado no segundo experimento: 128/12. Os quatro novos filtros de Gabor assim gerados originam quatro novas imagens filtradas ou "canais texturais", ilustradas na figura 4.15.




Figura 4.15

Imagens filtradas pelos filtros de Gabor para o experimento 3 na para imagem sintética de frequência única

E a partir do hiperespaço gerado pelas quatro imagens filtradas, através do classificador Distância Mínima, obtêm-se o resultado da classificação ilustrado na figura 4.16.




Figura 4.16  
Imagem classificada referente ao experimento 3 da imagem sintética de frequência única

A exatidão obtida para esta classificação é apresentada na tabela 4.3.

TABELA DA MATRIZ DE ERRO

	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
Imagem Referência				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	100.00	0.00	<b>16384</b>	16384	0	0	0
Classe 2	99.65	0.35	<b>16384</b>	58	16326	0	0
Classe 3	99.92	0.08	<b>16384</b>	6	0	16371	7
Classe 4	99.99	0.01	<b>16384</b>	1	0	0	16383
<i>Número de Pixels da Imagem Classificada</i>			<b>65536</b>	<b>16449</b>	<b>16326</b>	<b>16371</b>	<b>16390</b>
Erro de Comissão (%)				0.40	0.00	0.00	0.04
<b>EXATIDÃO GERAL (%)*</b>				<b>99.89</b>			

\* exatidão com relação à imagem de Referência

Tabela 4.3

Tabela da matriz de Erro para a classificação da imagem textural de frequência única no experimento 3

A partir dos experimentos realizados nesta seção pode-se verificar que a extensão espacial tem caráter decisivo para a melhor separabilidade das classes presentes na imagem, eliminando ainda certas distorções nas bordas.

#### **4.2.3. IMAGEM SINTÉTICA FORMADA POR UM MOSAICO DE TEXTURA REAL**

Um segundo conjunto de experimentos foi desenvolvido utilizando-se, desta vez, uma imagem formada por texturas reais organizadas em um mosaico regular, a partir de imagens retiradas do álbum de Brodatz, BRODATZ(1966). A imagem mosaico tem a dimensão de 512 x 512 pixels, devido a conveniência de se trabalhar com uma imagem no formato de  $2^N \times 2^N$  pixels, onde N é um número inteiro, para utilizar as vantagens computacionais da Transformada Rápida de Fourier (FFT). Este algoritmo (FFT) é extremamente eficiente para fins de implementação da transformada de Fourier, minimizando o tempo de processamento e o espaço de memória exigido pela máquina. Nota-se, entretanto, que dimensões distintas para a imagem também podem ser utilizadas resultando apenas na perda das vantagens acima mencionadas. A imagem sintética formada a partir de algumas imagens do álbum de Brodatz está ilustrada na figura 4.17.

Esta imagem sintética foi então utilizada para testar o algoritmo proposto. Em se tratando de uma abordagem supervisionada, o processo requer a obtenção de amostras de cada classe. Um total de 5 amostras contendo as frequências representativas de cada classe foram utilizadas, conforme ilustra a figura 4.18. A classe 2 por apresentar duas sub-classes com orientações diferentes necessitou duas amostras, uma amostra de cada uma destas sub-classes para ter-se um conjunto de amostra mais representativo para esta classe.




Figura 4.17  
Imagem sintética formada por mosaico de texturas naturais




Figura 4.18  
Amostras representativas de classes para seleção de feições

As frequências mais representativas das amostras e seus respectivos espectros de Fourier são ilustradas nas figuras 4.19 a 4.23. Sendo os respectivos valores  $u$  e  $v$  para as frequências espaciais apresentados nas seguintes unidades de medida:  $u$ (ciclos/dimensão  $x$  da amostra ) e  $v$ (ciclos/dimensão  $y$  da amostra). A figura 4.24 ilustra, de forma geral, as frequências espaciais mais energéticas.




Figura 4.19

(a) Localização da amostra (b) Amostra 1 da classe 1 na imagem original  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.20

(a) Localização da amostra (b) Amostra 1 da classe 2 na imagem original  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.21

(a) Localização da amostra (b) Amostra 2 da classe 2 na imagem original  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.22

(a) Localização da amostra (b) Amostra 1 da classe 3 na imagem original  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.23

(a) Localização da amostra (b) Amostra 1 da classe 4 na imagem original  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u, v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.24

Gráfico das frequências espaciais mais energéticas referentes às amostras da figura 4.18



#### 4.2.3.1. EXPERIMENTO 1

Um primeiro experimento utilizando a imagem com texturas extraídas do álbum de Brodatz, BRODATZ(1966) é desenvolvido.

A partir das amostras definidas na figura 4.18, foram obtidos os parâmetros para os filtros de Gabor utilizados no processo de classificação, conforme a tabela 4.4.

TABELA DE PARÂMETROS DOS FILTROS DE GABOR

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espacial ( $\sigma$ ) *
1	85	0.0118	0.0133	14.1667
2	38	0.0353	0.0267	6.3333
3	43	0.0235	0.0267	7.1667
4	40	0.0253	-0.0282	6.6667
5	79	0	0.0423	13.1667
6	79	0.0127	0	13.1667
7	34	0.0330	0.0299	5.6667
8	46	0.0220	0.0299	7.6667
9	67	0.0549	0	11.1667
10	28	0.0360	0.0440	4.6667
11	31	0.0360	0.0330	5.1667
12	35	0.0288	0.0330	5.8333
13	103	0.0442	0	17.1667
14	113	0.0088	0.0194	18.8333
15	113	0	0.0291	18.8333

\* Correspondente a cada par de frequência espacial

Tabela 4.4

Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.7, referente ao experimento 1.

Os 15 filtros de Gabor com os parâmetros definidos na tabela 4.4 geram então 15 imagens filtradas ou "canais texturais", conforme ilustra a figura 4.25.




Figura 4.25  
Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 1.

A aplicação dos filtros de Gabor sobre a imagem original gera um número de imagens filtradas igual ao número de filtros utilizados. Desta forma, o problema, originalmente unidimensional, transforma-se em um problema multidimensional, no qual cada pixel passa a ser descrito por um vetor cuja dimensionalidade é igual ao número de filtros utilizados. À semelhança das imagens multi-espectrais, estas imagens resultantes do processo de filtragem poderiam ser denominadas de "canais ou bandas texturais". Uma vez obtidas as "bandas texturais" por meio da aplicação dos filtros de Gabor na imagem original, passa-se à etapa seguinte que consiste no treinamento do classificador (Máxima Verossimilhança Gaussiana) - o mais adequado a esta imagem.

Nesta etapa devem ser coletadas amostras para estimação do vetor média e da matriz de covariância de cada classe. Obviamente, a dimensão destes parâmetros é igual ao número de filtros de Gabor utilizados. A figura 4.26

ilustra a localização das amostras. O resultado da classificação propriamente dita está representada na figura 4.27.




Figura 4.26  
Amostras da imagem mosaico utilizadas para o treinamento do classificador.

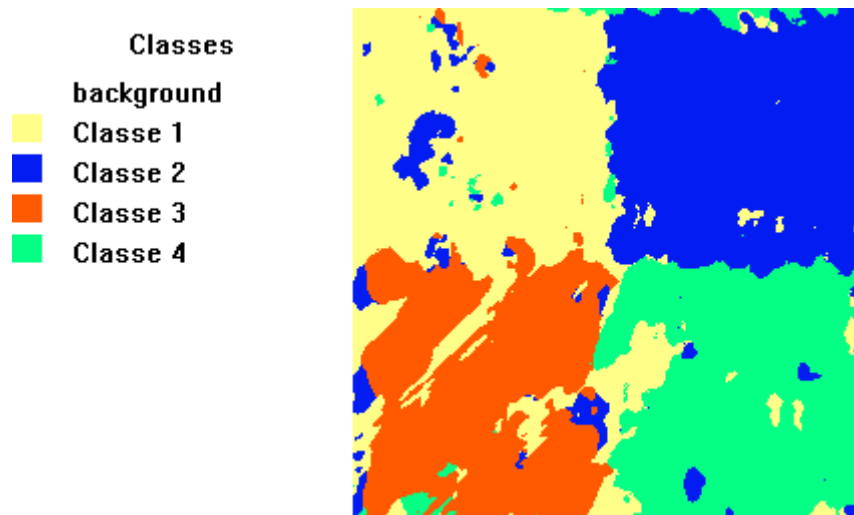


Figura 4.27  
Classificação referente ao experimento 1 na imagem mosaico de textura natural ( figura 4.17) .

A exatidão da classificação é estimada através de uma tabela da Matriz de Erro, conforme tabela 4.5.

TABELA DA MATRIZ DE ERRO

	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
Imagem Referência				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	83.23	16.77	<b>65536</b>	54547	885	2303	7801
Classe 2	91.02	8.98	<b>65536</b>	5342	59650	0	544
Classe 3	81.56	18.44	<b>65536</b>	7187	1224	53452	3673
Classe 4	88.61	11.39	<b>65536</b>	6847	606	9	58074
<i>Número de Pixels da Imagem Classificada</i>			<b>262144</b>	<b>73923</b>	<b>62365</b>	<b>55764</b>	<b>70092</b>
Erro de Comissão (%)				29.57	4.14	3.53	18.34
<b>EXATIDÃO GERAL (%)*</b>	<b>86.11</b>						

\* exatidão com relação a imagem de Referência

Tabela 4.5

Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento I, conforme os parâmetros definidos na tabela 4.4

#### 4.2.3.2. EXPERIMENTO 2

Este processo de classificação foi implementado novamente utilizando-se as mesmas frequências anteriores, alterando-se apenas a extensão espacial dos filtros de Gabor que passa agora a ter o mesmo valor, igual ao maior valor das extensões espaciais existentes, conforme ilustrado na tabela 4.6.

TABELA DE PARÂMETROS DOS FILTROS DE GABOR

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espacial ( $\sigma$ ) *
1	113	0.0118	0.0133	18.8333
2	113	0.0353	0.0267	18.8333
3	113	0.0235	0.0267	18.8333
4	113	0.0253	-0.0282	18.8333
5	113	0	0.0423	18.8333
6	113	0.0127	0	18.8333
7	113	0.033	0.0299	18.8333

\* Correspondente a cada par de frequência espacial

TABELA DE PARÂMETROS DOS FILTROS DE GABOR (CONTINUAÇÃO)

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espacial ( $\sigma$ ) *
8	113	0.022	0.0299	18.8333
9	113	0.0549	0	18.8333
10	113	0.036	0.044	18.8333
11	113	0.036	0.033	18.8333
12	113	0.0288	0.033	18.8333
13	113	0.0442	0	18.8333
14	113	0.0088	0.0194	18.8333
15	113	0	0.0291	18.8333

\* Correspondente a cada par de frequência espacial

Tabela 4.6 (continuação)

Parâmetros para o filtro de Gabor extraídos das amostras da figura 4.26, referente ao experimento 2.

Os parâmetros relacionados na tabela 4.6 geram, portanto, outras 15 imagens filtradas ou "canais texturais" ilustradas na figura 4.28. Da mesma maneira que no experimento anterior, o classificador utilizado foi o de Máxima Verossimilhança Gaussiana. O treinamento do classificador foi efetivado utilizando as mesmas amostras ilustradas na figura 4.26 e o resultado da classificação é ilustrado na figura 4.29.




Figura 4.28

Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 2.




Figura 4.28 (continuação)  
Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 2.

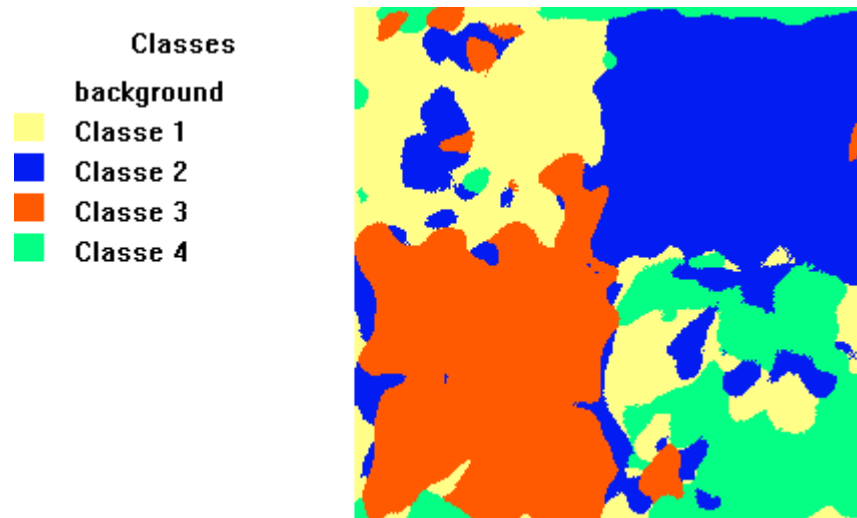


Figura 4.29  
Classificação referente ao experimento 2 na imagem mosaico de textura natural ( figura 4.17) .

A exatidão obtida nesse processo é ilustrada na tabela 4.7.

TABELA DA MATRIZ DE ERRO

Imagem Referência	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	60.29	39.71	<b>65536</b>	39509	10604	12662	2761
Classe 2	93.41	6.59	<b>65536</b>	913	61215	538	2870
Classe 3	87.73	12.27	<b>65536</b>	2648	4033	57493	1362
Classe 4	55.26	44.74	<b>65536</b>	15473	11630	2218	36215

\* exatidão com relação a imagem de Referência

Tabela 4.7

Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 2, conforme os parâmetros definidos na tabela 4.6.

TABELA DA MATRIZ DE ERRO (continuação)

<i>Número de Pixels da Imagem Classificada</i>	<b>262144</b>	<b>58543</b>	<b>87482</b>	<b>72911</b>	<b>43208</b>
Erro de Comissão (%)		29.04	40.08	23.53	10.67
<b>EXATIDÃO GERAL (%)*</b>	<b>74.17</b>				

Tabela 4.7 (continuação)

Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 2, conforme os parâmetros definidos na tabela 4.6.

#### 4.2.3.3. EXPERIMENTO 3

Um terceiro experimento foi ainda desenvolvido utilizando-se os mesmos dados, alterando-se novamente apenas a extensão espacial dos filtros de Gabor. Neste processo de classificação, a extensão espacial passa a ter um valor superior ao valor máximo utilizado no experimento anterior. Os valores utilizados encontram-se relacionados na tabela 4.8.

TABELA DE PARÂMETROS DOS FILTROS DE GABOR

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espacial ( $\sigma$ ) *
1	200	0.0118	0.0133	33.3333
2	200	0.0353	0.0267	33.3333
3	200	0.0235	0.0267	33.3333
4	200	0.0253	-0.0282	33.3333
5	200	0	0.0423	33.3333
6	200	0.0127	0	33.3333
7	200	0.0330	0.0299	33.3333
8	200	0.0220	0.0299	33.3333
9	200	0.0549	0	33.3333
10	200	0.0360	0.0440	33.3333
11	200	0.0360	0.0330	33.3333
12	200	0.0288	0.0330	33.3333
13	200	0.0442	0	33.3333
14	200	0.0088	0.0194	33.3333
15	200	0	0.0291	33.3333

\* Correspondente a cada par de frequência espacial

Tabela 4.8.

Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.26, referente ao experimento 3.

A partir destes parâmetros foram geradas 15 imagens filtradas, ilustradas na figura 4.30. Utilizando-se das mesmas amostras do experimento anterior e do mesmo classificador gerou-se a classificação ilustrada na figura 4.31.




Figura 4.30

Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 3.




Figura 4.31

Classificação referente ao experimento 3 na imagem mosaico de textura natural ( figura 4.17) .



A exatidão obtida nesse processo é ilustrada pela tabela 4.9.

TABELA DA MATRIZ DE ERRO

	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
Imagem Referência				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	31.79	68.21	<b>65536</b>	20835	10503	34079	119
Classe 2	86.89	13.11	<b>65536</b>	2086	56946	6470	34
Classe 3	95.70	4.30	<b>65536</b>	126	1969	62721	720
Classe 4	60.72	39.28	<b>65536</b>	2882	18479	4381	39794
<i>Número de Pixels da Imagem Classificada</i>			<b>262144</b>	<b>25929</b>	<b>87897</b>	<b>107651</b>	<b>40667</b>
Erro de Comissão (%)				7.77	47.23	68.56	1.33
<b>EXATIDÃO GERAL (%)*</b>			<b>68.78</b>				

\* exatidão com relação à imagem de Referência

Tabela 4.9

Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 3, conforme os parâmetros definidos na tabela 4.8.

#### 4.2.3.4. EXPERIMENTO 4

Um quarto experimento foi ainda realizado com a finalidade de verificar o efeito resultante da introdução de frequências espaciais e, portanto, de filtros de Gabor adicionais. Foram utilizadas, portanto, as mesmas amostras ilustradas na figura 4.26 para extração de frequências, porém, o número de frequências espaciais foi aumentado. As características dos filtros de Gabor utilizadas neste experimento estão relacionadas na tabela 4.10.

TABELA DE PARÂMETROS DOS FILTROS DE GABOR

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espacial ( $\sigma$ ) *
1	85	0.0118	0.0133	14.1667
2	38	0.0353	0.0267	6.3333
3	43	0.0235	0.0267	7.1667
4	29	0.0353	-0.0133	4.8333
5	85	0	0.0133	14.1667
6	40	0.0253	-0.0282	6.6667
7	79	0	0.0423	13.1667
8	79	0.0127	0	13.1667
9	71	0.0506	0	11.8333
10	40	0.0253	-0.0423	6.6667
11	34	0.0330	0.0299	5.6667
12	46	0.0220	0.0299	7.6667
13	67	0.0549	0	11.1667
14	91	0	0.0597	15.1667
15	91	0.0110	0	15.1667
16	28	0.0360	0.0440	4.6667
17	31	0.0360	0.0330	5.1667
18	35	0.0288	0.0330	5.8333
19	46	0.0288	0.0220	7.6667
20	139	0.0072	0.0110	23.1667
21	103	0.0442	0	17.1667
22	113	0.0088	0.0194	18.8333
23	113	0	0.0291	18.8333
24	57	0.0177	0.0291	9.5000
25	113	0.0088	0.0388	18.8333

\* Correspondente a cada par de frequência espacial

Tabela 4.10

Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.26, referente ao experimento 4.

Os parâmetros definidos na tabela 4.10 geraram 25 imagens filtradas ou "canais texturais", ilustradas na figura 4.32. O vetor média e a matriz de covariância de cada classe foram então estimados utilizando-se as mesmas

amostras (figura 4.26, desta vez em dimensionalidade mais alta). A partir das imagens filtradas, utilizando-se o mesmo classificador dos experimentos anteriores, obteve-se a classificação ilustrada na figura 4.33.




Figura 4.32  
Imagens filtradas pelo filtro de Gabor na imagem mosaico (Figura 4.17) para o experimento 4.

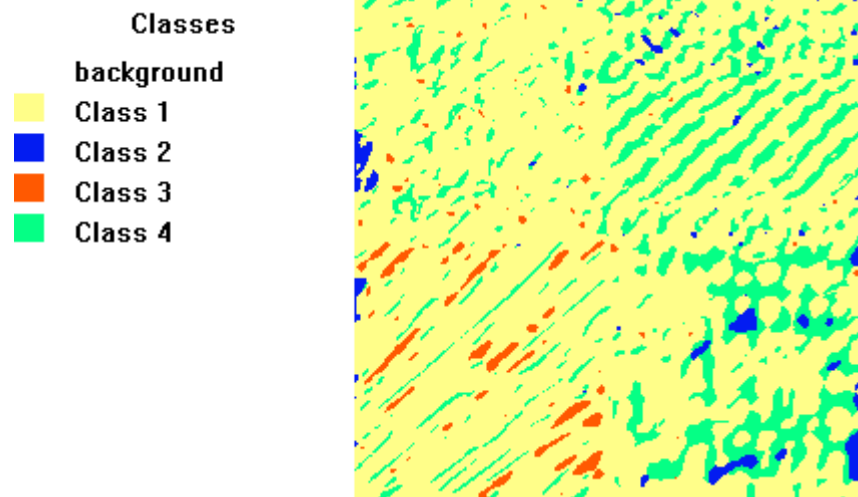


Figura 4.33

Classificação referente ao experimento 4 na imagem mosaico de textura natural ( figura 4.17) .

A exatidão obtida nesse processo é ilustrada na tabela 4.11.

TABELA DA MATRIZ DE ERRO

	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
Imagem Referência				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	88.46	11.54	<b>65536</b>	57972	920	665	5979
Classe 2	1.10	98.90	<b>65536</b>	49305	721	43	15467
Classe 3	6.93	93.07	<b>65536</b>	56518	346	4542	4130
Classe 4	26.96	73.04	<b>65536</b>	44577	3152	136	17671
<i>Número de Pixels da Imagem Classificada</i>			<b>262144</b>	<b>208372</b>	<b>5139</b>	<b>5386</b>	<b>43247</b>
Erro de Comissão (%)				229.49	6.74	1.29	39.03
<b>EXATIDÃO GERAL (%)*</b>			<b>30.86</b>				

\* exatidão com relação à imagem de Referência

Tabela 4.11

Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 4, conforme os parâmetros definidos na tabela 4.10.

#### 4.2.3.5. EXPERIMENTO 5

Um quinto experimento foi desenvolvido, com a finalidade de testar a influência da extensão espacial dos filtros de Gabor no processo de classificação, utilizando-se as mesmas frequências espaciais como no experimento anterior. À semelhança do segundo experimento, a extensão

espaçial passou a ter, neste caso, o mesmo valor para todos os 25 filtros de Gabor. Este valor comum adotado é igual a maior extensão espaçial encontrada entre os 25 filtros utilizados no experimento anterior. Os dados relativos a este experimentos são apresentados na tabela 4.12.

TABELA DE PARÂMETROS DOS FILTROS DE GABOR

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espaçial ( $\sigma$ ) *
1	139	0.0118	0.0133	23.1667
2	139	0.0353	0.0267	23.1667
3	139	0.0235	0.0267	23.1667
4	139	0.0353	-0.0133	23.1667
5	139	0	0.0133	23.1667
6	139	0.0253	-0.0282	23.1667
7	139	0	0.0423	23.1667
8	139	0.0127	0	23.1667
9	139	0.0506	0	23.1667
10	139	0.0253	-0.0423	23.1667
11	139	0.0330	0.0299	23.1667
12	139	0.0220	0.0299	23.1667
13	139	0.0549	0	23.1667
14	139	0	0.0597	23.1667
15	139	0.0110	0	23.1667
16	139	0.0360	0.0440	23.1667
17	139	0.0360	0.0330	23.1667
18	139	0.0288	0.0330	23.1667
19	139	0.0288	0.0220	23.1667
20	139	0.0072	0.0110	23.1667
21	139	0.0442	0	23.1667
22	139	0.0088	0.0194	23.1667
23	139	0	0.0291	23.1667
24	139	0.0177	0.0291	23.1667
25	139	0.0088	0.0388	23.1667

\* Correspondente a cada par de frequência espaçial

Tabela 4.12

Parâmetros para o filtro de Gabor extraídos das amostras da figura 4.26, referente ao experimento 5.

Estes parâmetros geraram, então, 25 novos filtros de Gabor e conseqüentemente 25 novas imagens filtradas ou

"canais texturais", conforme ilustra a figura 4.34. Identicamente aos experimentos anteriores, os parâmetros vetor média e matriz de covariância utilizados no classificador Máxima Verossimilhança Gaussiana foram estimados para cada classe textural. Os resultados desta classificação estão ilustrados na figura 4.35.




Figura 4.34  
Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 5.

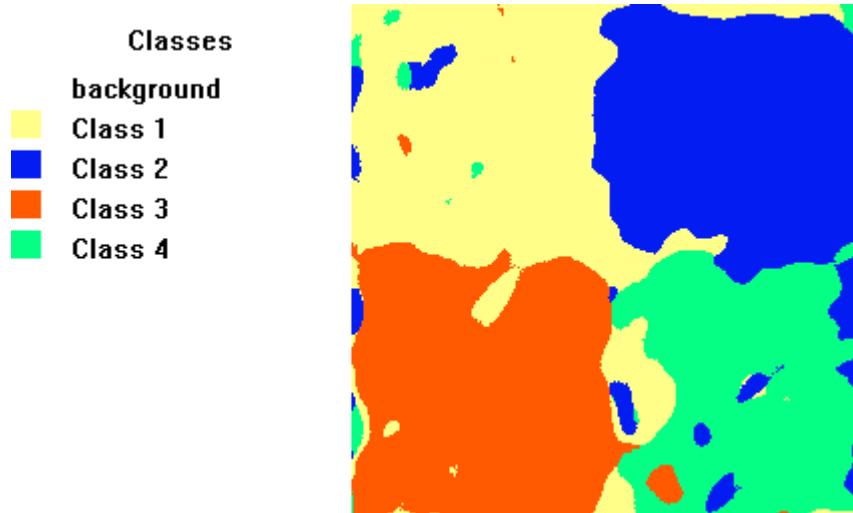


Figura 4.35  
Classificação referente ao experimento 5 na imagem mosaico de textura natural ( figura 4.17) .

A exatidão obtida nesse processo é ilustrada pela tabela 4.13.

TABELA DA MATRIZ DE ERRO

	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
Imagem Referência				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	91.26	8.74	<b>65536</b>	59805	3244	1507	980
Classe 2	90.94	9.06	<b>65536</b>	4659	59597	0	1280
Classe 3	92.33	7.67	<b>65536</b>	3934	575	60511	516
Classe 4	74.00	26.00	<b>65536</b>	8067	6937	2036	48496
<i>Número de Pixels da Imagem Classificada</i>			<b>262144</b>	<b>76465</b>	<b>70353</b>	<b>64054</b>	<b>51272</b>
Erro de Comissão (%)				25.42	16.41	5.41	4.24
<b>EXATIDÃO GERAL (%)*</b>				<b>87.13</b>			

\* exatidão com relação à imagem de Referência

Tabela 4.13

Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 5, conforme os parâmetros definidos na tabela 4.12.

#### 4.2.3.6. EXPERIMENTO 6

Um último experimento utilizando a imagem mosaico de texturas extraídas do álbum de Brodatz (figura 4.10) foi desenvolvido, novamente, com a finalidade de testar a influência da extensão espacial dos filtros de Gabor. Neste

experimento, o valor da extensão espacial foi incrementado a aproximadamente 1.5 vezes o valor máximo adotado no quinto experimento. Os valores utilizados, neste caso, para a confecção dos filtros de Gabor estão apresentados na tabela 4.14.

TABELA DE PARÂMETROS DOS FILTROS DE GABOR

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espacial ( $\sigma$ ) *
1	200	0.0118	0.0133	33.3333
2	200	0.0353	0.0267	33.3333
3	200	0.0235	0.0267	33.3333
4	200	0.0353	-0.0133	33.3333
5	200	0	0.0133	33.3333
6	200	0.0253	-0.0282	33.3333
7	200	0	0.0423	33.3333
8	200	0.0127	0	33.3333
9	200	0.0506	0	33.3333
10	200	0.0253	-0.0423	33.3333
11	200	0.0330	0.0299	33.3333
12	200	0.0220	0.0299	33.3333
13	200	0.0549	0	33.3333
14	200	0	0.0597	33.3333
15	200	0.0110	0	33.3333
16	200	0.0360	0.0440	33.3333
17	200	0.0360	0.0330	33.3333
18	200	0.0288	0.0330	33.3333
19	200	0.0288	0.0220	33.3333
20	200	0.0072	0.0110	33.3333
21	200	0.0442	0	33.3333
22	200	0.0088	0.0194	33.3333
23	200	0	0.0291	33.3333
24	200	0.0177	0.0291	33.3333
25	200	0.0088	0.0388	33.3333

- Correspondente a cada par de frequência espacial

Tabela 4.14  
Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.26, referente ao experimento 6.



A partir dos parâmetros apresentados na tabela 4.14 foram geradas 25 imagens filtradas ou "canais texturais", que estão ilustradas na figura 4.36.




Figura 4.36  
Imagens filtradas pelo filtro de Gabor na imagem mosaico(Figura 4.17) para o experimento 6.

Como nos experimentos anteriores, foram novamente estimados os parâmetros de cada uma das classes (treinamento do classificador) e efetivada a classificação da imagem pelo método da Máxima Verosimilhança Gaussiana. A

imagem classificada está apresentada na figura 4.37 e os resultados desta classificação são apresentadas na tabela 4.15.

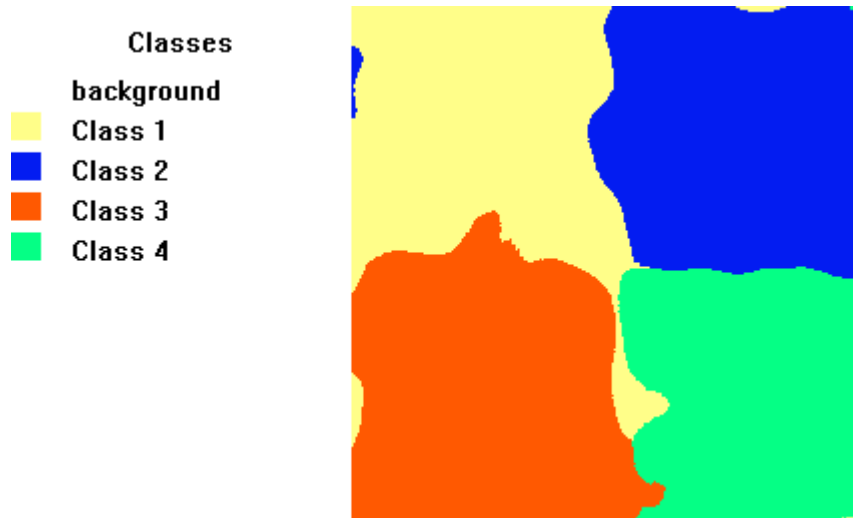


Figura 4.37  
Classificação referente ao experimento 6 na imagem mosaico de textura natural ( figura 4.17) .

A exatidão obtida nesse processo é ilustrada pela tabela 4.15.

TABELA DA MATRIZ DE ERRO

	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada			
Imagem Referência				Classe 1	Classe 2	Classe 3	Classe 4
Classe 1	93.03	6.97	<b>65536</b>	60967	1629	2940	0
Classe 2	97.06	2.94	<b>65536</b>	1813	63606	0	117
Classe 3	97.80	2.20	<b>65536</b>	1442	0	64094	0
Classe 4	85.26	14.74	<b>65536</b>	3584	2019	4055	55878
<i>Número de Pixels da Imagem Classificada</i>			<b>262144</b>	<b>67806</b>	<b>67254</b>	<b>71089</b>	<b>55995</b>
Erro de Comissão (%)				10.44	5.57	10.67	0.18
<b>EXATIDÃO GERAL (%)*</b>				<b>93.29</b>			

\* exatidão com relação à imagem de Referência

Tabela 4.15

Tabela da Matriz de Erro para classificação da imagem mosaico de textura natural referente ao experimento 6, conforme os parâmetros definidos na tabela 4.14.

A partir dos seis experimentos realizados com imagens sintéticas, nesta seção, pode-se perceber o efeito

do parâmetro  $\sigma$  único, para extração e posterior classificação, utilizando um número de frequências espaciais variado (15 e 25 para estes experimentos). Para os três primeiros experimentos fica evidenciado o problema de se utilizar um único valor para a extensão espacial, conforme descrito no capítulo III, a um número pequeno de frequências espaciais na extração de feições texturais. Este uso acarretou uma deterioração na classificação da imagem.

Entretanto, para os três experimentos restantes, onde foi utilizado um número maior de frequências espaciais, o uso da extensão espacial única melhorou consideravelmente a classificação da imagem.

Portanto, o uso da extensão espacial única, somente deve ser usado para um número significativo de frequências espaciais. (uma investigação mais ampla do resultado é mostrada no capítulo V).

#### **4.3. EXPERIMENTO ENVOLVENDO IMAGENS REAIS**

Para a execução deste experimento foi utilizada uma imagem digital obtida a partir de uma fotografia aérea de parte da cidade de Porto Alegre e suas ilhas, ilustrada na figura 4.38. Esta fotografia apresenta três classes texturais bem definidas (i) classe urbana; (ii) classe de área coberta por vegetação (ilhas do delta do Jacuí) e (iii) classe água (correspondente ao Rio Guaíba). Dessa forma, a imagem é utilizada para testar, em condições reais, o algoritmo proposto no capítulo III.



Figura 4.38

Imagem digitalizada de uma fotografia aérea de parte da cidade de Porto Alegre e ilhas.

Os filtros necessários para selecionar as feições nesta imagem foram tomados a partir das amostras ilustradas na figura 4.39. Após a seleção das frequências dominantes em cada uma das classes presentes nas amostras, foram estimados os parâmetros necessários à confecção dos filtros de Gabor, conforme é mostrado na tabela 4.16.



Figura 4.39  
Amostras representativas das classes utilizadas para seleção de feições.

As frequências mais representativas das amostras e seus respectivos espectros de Fourier são ilustradas nas figuras 4.40 a 4.53. Sendo os respectivos valores  $u$  e  $v$  das frequências espaciais apresentados na figura 4.54, dados em ciclos/dimensão da amostra, isto é,  $u(\text{ciclos}/\text{dim}_x)$  e  $v(\text{ciclos}/\text{dim}_y)$ .




Figura 4.40

(a) Localização da amostra 1 da classe urbana na imagem original (b) Amostra da classe (c) Espectro de Fourier da amostra (d) frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.41

(a) Localização da amostra 2 da classe urbana na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.42

(a) Localização da amostra 3 da classe urbana na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.43

(a) Localização da amostra 1 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.44

(a) Localização da amostra 2 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.45

(a) Localização da amostra 3 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).






Figura 4.46

(a) Localização da amostra 4 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.47

(a) Localização da amostra 5 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.48

(a) Localização da amostra 6 da classe vegetação na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.49

(a) Localização da amostra 1 da classe água na imagem original (b) Amostra (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.50

(a) Localização da amostra 2 da classe água na imagem original (b) Amostra  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.51

(a) Localização da amostra 3 da classe água na imagem original (b) Amostra  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.52

(a) Localização da amostra 4 da classe água na imagem original (b) Amostra  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.53

(a) Localização da amostra 5 da classe água na imagem original (b) Amostra  
 (c) Espectro de Fourier da amostra (d) Frequências da amostra que apresentam o maior nível de energia, com o escalonamento de energia descendente do branco para as mais elevadas até o preto para as mais baixas, sendo desconsiderada a frequência  $(u,v)=(0,0)$ , no centro da figura, onde está a origem dos eixos  $u$  (eixo horizontal) e  $v$  (eixo vertical).




Figura 4.54  
Gráfico das frequências espaciais mais energéticas para as amostras da figura (4.39)

#### 4.3.1. EXPERIMENTO 1

A partir das amostras ilustradas na figura 4.39 foram escolhidas as frequências espaciais mais representativas de cada classe e as respectivas extensões espaciais para fins de seleção de feições texturais. A tabela 4.16 apresenta os parâmetros estimados que foram utilizados para a confecção dos filtros de Gabor necessários à seleção de feições.

TABELA DE PARÂMETROS DOS FILTROS DE GABOR

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espacial ( $\sigma$ ) *
1	15	0.0678	-0.0333	2.5000
2	30	0.0508	0.0333	5.0000
3	22	0.0455	-0.0364	3.6667
4	55	0.0227	0.0182	9.1667
5	60	0	0.0167	10.0000
6	63	0.0159	0	10.5000
7	54	0.0476	0	9.0000
8	93	0.0108	0	15.5000
9	93	0.0108	-0.0141	15.5000
10	30	0.0333	0	5.0000
11	30	0	0.0435	5.0000
12	52	0.0192	0	8.6667
13	26	0.0385	-0.0385	4.3333
14	17	0.0588	0	2.8333
15	17	0.0588	0.0625	2.8333
16	23	0.0435	0.0800	3.8333
17	25	0	0.0400	4.1667

\* Correspondente a cada par de frequência espacial

Tabela 4.16

Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.39, referente ao experimento 1.

A partir dos parâmetros da tabela 4.16, foram geradas 17 imagens filtradas ou "bandas texturais", conforme ilustra a figura 4.55.




Figura 4.55

Imagens filtradas pelo filtro de Gabor na imagem de Porto Alegre( figura 4.38) para o experimento 1.




Figura 4.55 ( continuação)

Imagens filtradas pelo filtro de Gabor na imagem de Porto Alegre (figura 4.38) para o experimento 1.

Com base no espaço gerado pelas 17 imagens filtradas e com a utilização do classificador de Máxima Verossimilhança Gaussiana para as amostras definidas na figura 4.39, obteve-se uma imagem classificada que esta ilustrada na figura 4.56.

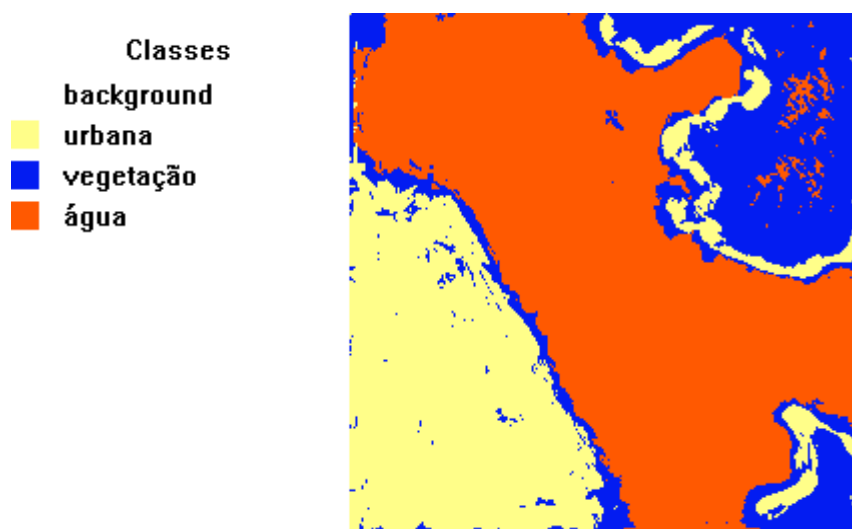


Figura 4.56

Imagem classificada referente ao experimento 1 da imagem real de parte de Porto Alegre e ilhas .

A exatidão obtida para esta classificação é apresentada na tabela 4.17.

TABELA DA MATRIZ DE ERRO

Imagem Referência	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada		
				Classe 1	Classe 2	Classe 3
Classe 1	95.99	4.01	<b>62768</b>	60251	2517	0
Classe 2	84.78	15.22	<b>44660</b>	4903	37864	1893
Classe 3	83.60	16.40	<b>154716</b>	8266	17100	129350
<i>Número de Pixels da Imagem Classificada</i>			<b>262144</b>	<b>73420</b>	<b>57481</b>	<b>131243</b>
Erro de Comissão (%)				20.98	43.93	1.22
<b>EXATIDÃO GERAL (%)*</b>			<b>86.77</b>			

\* exatidão com relação à imagem de Referência

Tabela 4.17

Tabela da Matriz de Erro para classificação da imagem real de parte de Porto Alegre e ilhas, referente ao experimento 1.

#### 4.3.2. EXPERIMENTO 2

Um último experimento foi ainda realizado com a finalidade de mostrar o efeito introduzido pelo aumento de frequências espaciais, isto é, um aumento no número de filtros de Gabor. Foram utilizadas, para tanto, as mesmas amostras ilustradas na figura 4.39, para extração de frequências, porém, o número de frequências espaciais foi aumentado. As características dos filtros de Gabor utilizadas neste experimento estão relacionadas na tabela 4.18.



TABELA DE PARÂMETROS DOS FILTROS DE GABOR

Filtro	Dimensão do filtro (pixels)	Frequência ao longo de x ( $k_x$ )	Frequência ao longo de y ( $k_y$ )	Valor da extensão espacial ( $\sigma$ ) *
1	35	0.0290	-0.0118	5.8333
2	23	0.0435	-0.0235	3.8333
3	23	0.0435	-0.0118	3.8333
4	29	0.0435	0.0353	4.8333
5	32	0.0317	-0.0164	5.3333
6	61	0.0794	0.0164	10.1667
7	24	0.0426	0.0545	4.0000
8	47	0.0213	0.0727	7.8333
9	39	0.0256	0	6.5000
10	39	0	0.0741	6.5000
11	39	0.0256	-0.0741	6.5000
12	39	0.0256	0.0741	6.5000
13	33	0.0513	0	5.5000
14	39	0.0256	0.0303	6.5000
15	39	0.0256	-0.0303	6.5000
16	50	0	0.0408	8.3333
17	10	0.1053	-0.0833	1.6667
18	19	0.0526	0.0833	3.1667
19	19	0.0526	0	3.1667
20	19	0	0.0833	3.1667
21	8	0.1250	-0.1053	1.3333
22	6	0.1667	-0.0526	1.0000
23	19	0.1667	0.0526	3.1667
24	57	0.0317	0.0175	9.5000
25	57	0.0476	0	9.5000
26	55	0	0.0392	9.1667
27	51	0.0364	0	8.5000
28	81	0	0.0370	13.5000
29	81	0	0.1111	13.5000
30	38	0.0317	0	6.3333
31	41	0	0.0588	6.8333
32	41	0	0.0784	6.8333

\* Correspondente a cada par de frequência espacial

Tabela 4.18

Parâmetros para o filtro de Gabor extraídos da amostra da figura 4.39, referente ao experimento 2.

As 32 imagens filtradas ou "bandas texturais" obtidas a partir dos parâmetros definidos na tabela 4.18 são mostrados na figura 4.57.




Figura 4.57  
Imagens filtradas pelo filtro de Gabor na imagem de Porto Alegre( figura 4.38) para o experimento 2.

Baseado-se no espaço gerado pelas 32 imagens filtradas e na utilização do classificador de Máxima Verossimilhança Gaussiana para as amostras definidas na figura 4.39, obteve-se uma imagem classificada que esta ilustrada na figura 4.58.

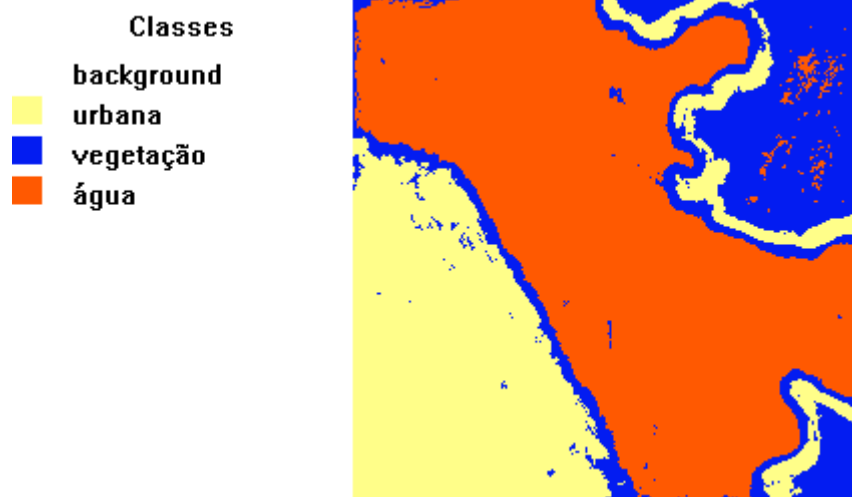


Figura 4.58

Imagem classificada referente ao experimento 2 da imagem real de parte de Porto Alegre e ilhas.

A exatidão obtida para esta classificação é apresentada na tabela 4.19.

TABELA DA MATRIZ DE ERRO

	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada		
Imagem Referência				Classe 1	Classe 2	Classe 3
Classe 1	97.85	2.15	<b>62768</b>	61417	1351	0
Classe 2	78.85	21.15	<b>44660</b>	8069	35213	1378
Classe 3	84.38	15.62	<b>154716</b>	7017	17154	130545
<i>Número de Pixels da Imagem Classificada</i>			<b>262144</b>	<b>76503</b>	<b>53718</b>	<b>131923</b>
Erro de Comissão (%)				24.03	41.44	0.89
<b>EXATIDÃO GERAL (%)*</b>			<b>86.66</b>			

\* exatidão com relação à imagem de Referência

Tabela 4.19

Tabela da Matriz de Erro para classificação da imagem real de parte de Porto Alegre e ilhas, referente ao experimento 2.

Com base nos experimentos realizados na imagem real da cidade de Porto Alegre e ilhas, fica evidente

- a necessidade de um conjunto grande de frequências espaciais para representar de forma ampla todas as feições texturais presentes na imagem. Esta condição é verificada na exatidão da classificação obtida em ambos os experimentos que, não foi alterada apesar do aumento significativo do número de feições texturais de um para outro experimento.
- o uso de uma extensão espacial única não melhoraria a classificação da imagem, em virtude da vasta quantidade de frequências espaciais presentes na mesma.

Uma avaliação mais ampla destes resultados é apresentada no capítulo V.

## **CAPÍTULO V**

### **CONCLUSÕES E SUGESTÕES**

Nesta dissertação foi proposta uma metodologia para fins de classificação supervisionada de imagens digitais utilizando o atributo de textura. Esta metodologia baseia-se na utilização de um conjunto de filtros de Gabor com parâmetros estimados a partir de amostras das classes presentes na imagem, com a utilização da Transformadas de Fourier. A classificação textural, propriamente dita, foi obtida por intermédio de um processo supervisionado conhecido como classificador de Máxima Verossimilhança Gaussiana, o qual usa amostras das classes contidas no espaço N-dimensional gerado pelo conjunto das imagens filtradas, com a finalidade de estimar os parâmetros a serem usados pelo classificador.

Os resultados obtidos no capítulo IV mostram a eficiência da metodologia proposta para fins de classificação de imagens digitais, utilizando atributos de textura.

Nos experimentos iniciais envolvendo sinais unidimensionais pode-se verificar o efeito da filtragem de Gabor de uma maneira simples e com fácil visualização, em virtude da simplicidade do sinal utilizado. Dessa forma, pode-se também avaliar as conseqüências advindas do uso de um valor único para o parâmetro  $\sigma$  (extensão espacial) em relação ao procedimento, utilizando valores distintos para cada classe. O valor comum para extensão espacial torna a separabilidade entre as classes mais nítida. Esta característica deve-se ao fato de que a não utilização de valores distintos para a extensão espacial em cada filtro evita que freqüências espaciais sejam capturadas de forma apenas parcial, gerando, portanto, ruído no processo de classificação. A utilização deste parâmetro único atingiu um ótimo resultado na separação das classes texturais, conforme pode ser visto na figura 4.4.

No experimento com sinal unidimensional (figuras 4.6 e 4.8) foi também verificado o problema de freqüências espaciais de amplitudes diferentes. Pelos resultados obtidos naqueles experimentos (figuras 4.7 e 4.9) constatou-se que somente ocorre erro na classificação quando as freqüências espaciais são iguais em comprimento de onda, mas diferem em amplitude.

Dos resultados obtidos na classificação de imagem

formada por frequências únicas por classe, pode-se verificar mais uma vez a melhoria ocasionada no processo de classificação ocasionada pelo uso de um valor único para a extensão espacial  $\sigma$ .

Da análise dos resultados da imagem mosaico de textura natural extraída do álbum de Brodatz ( figura 4.17) pode-se verificar que a extração de frequências espaciais associadas a cada classe é muito dependente da escolha das amostras. Desta forma, quanto mais representativa é a amostra da classe melhor resulta a seleção de feições. Como se trata de uma imagem natural ocorre um número muito grande de frequências espaciais presentes em cada classe na imagem. Torna-se, portanto, computacionalmente inviável considerar a totalidade das frequências espaciais presentes. Por outro lado ao se utilizar um número reduzido de frequências espaciais, ocorre o perigo de não se capturar todas as frequências espaciais necessárias a uma perfeita classificação, como fica evidenciado na figura 4.27 que apresenta uma exatidão boa (86.11%), porém, não apresenta uma homogeneidade na classificação intra-classe. As fronteiras entre as classes fica, entretanto, razoavelmente definida. À medida que se toma um valor único para a extensão espacial dos filtros para o mesmo conjunto de frequências espaciais há uma deterioração na classificação ( figuras 4.29 e 4.31).

Isto ocorre devido a diminuição de feições texturais que são extraídas por estas frequências para esse novo valor extensão espacial tomado, de foram análoga ao ocorrido na figura 4.9. Uma vez que, características antes presentes nas imagens filtradas não mais aparecem ou são muito atenuadas para este novo  $\sigma$ , ocasionando, dessa forma, uma perda de informação necessária uma melhor classificação.

Na medida em que se utiliza um número maior de frequências espaciais conjuntamente com um parâmetro de extensão espacial adequado, ocorre uma melhoria significativa na classificação geral e na homogeneidade dos padrões classificados intra-classe (figuras 4.35 e 4.37) . Portanto, sugere-se para o caso de imagens caracterizadas por um número grande de frequências espaciais, não utilizar um valor único para extensão espacial  $\sigma$ , pois, dessa foram, com uma quantidade menor de frequências espaciais ocorre uma extração de feições suficiente para uma boa classificação.

Um dos problemas que inerentemente surge na extração de feições é o fato de ocorrerem frequências espaciais idênticas em classes distintas, ambas representativas de suas texturas, mas que, por terem amplitudes distintas, podem gerar erros de classificação. Fato este constatado na classificação de sinal unidimensional (figura 4.9), que levou a não se utilizar um valor único  $\sigma$  para extensão espacial na



imagem de Parte de Porto Alegre e suas ilhas. Neste último experimento referente à imagem de parte de Porto Alegre e suas ilhas ocorreram confusões entre a classe de vegetação e a classe urbana, provavelmente ocasionadas pela similaridade de determinadas frequências espaciais que apresentavam o mesmo comprimento de onda, porém com amplitudes diferentes em ambas as classes. Esse erro de classificação na imagem poderia ser ampliado se tivesse sido utilizado um valor único de extensão espacial.

Um outro problema que pode, eventualmente, ocorrer utilizando esta metodologia proposta diz respeito ao uso do classificador de Máxima Verossimilhança Gaussiana no espaço N-dimensional gerado pelas imagens filtradas. Este classificador parte do princípio que as classes a serem classificadas apresentam distribuição normal multivariada. Se tal suposição não for cumprida pode ocorrer uma deterioração nos resultados obtidos.

Como forma de dar continuidade ao caminho proposto nesta dissertação e resolver os problemas mencionados são oferecidas as seguintes sugestões:

- ◆ Utilizar outro classificador como, por exemplo, um classificador de redes neurais, que não faz suposição alguma a respeito dos parâmetros estatísticos de cada classe (classificação não

paramétrica).

- ◆ Para o caso de frequências espaciais com o mesmo período, mas amplitudes distintas, poder-se-ia incluir uma etapa de pré-processamento, na qual se implementaria uma equalização na amplitude das frequências espaciais ao longo da imagem.
- ◆ Utilizar, conjuntamente, além da extensão espacial inerente a cada frequência espacial escolhida, outras extensões espaciais únicas para as mesmas frequências espaciais como forma de aproveitar as vantagens do uso deste parâmetro único na eliminação de ruído na classificação.
- ◆ Pode-se ainda, como forma de melhorar a exatidão da classificação, utilizar a concatenação de outros atributos (espectrais e de contexto), além dos atributos texturais para extração de feições, simulando, desta forma, o processo desenvolvido pela percepção visual humana que se utiliza de todos estes atributos.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
CENTRO ESTADUAL DE PESQUISA EM SENSORIAMENTO REMOTO  
E METEOROLOGIA - CEP SRM  
CURSO DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

APLICAÇÃO DE FILTROS DE GABOR NO PROCESSO DE CLASSIFICAÇÃO DE  
IMAGENS DIGITAIS COM BASE EM ATRIBUTOS DE TEXTURA

- APÊNDICES -

Por

**NEIDE PIZZOLATO ANGELO**

Porto Alegre, RS  
Janeiro de 2000

## APÊNDICE 1

### TRANSFORMADA DE FOURIER

Nesta seção será abordado em detalhe a transformada de Fourier contínua e discreta com suas propriedades, tal conteúdo é extraído de BRIGHAM(1974), GONZALES e WOODS(1992) GABEL e ROBERTS(1987) e TOU e GONZALES(1974).

A transformada de Fourier tem sido amplamente utilizada em várias áreas do conhecimento científico tais como: análise de séries temporais, processamento de sinais e de imagens, entre outras. Mostrando-se uma ferramenta imprescindível para tratamento de frequências.

### INTRODUÇÃO A TRANSFORMADA DE FOURIER

O par de transformada de Fourier para o caso bidimensional é definido da seguinte forma: seja  $f(x,y)$  uma função contínua e integrável e  $F(u,v)$  integrável. A transformada de Fourier de  $f(x,y)$  é definida por

$$\mathfrak{F}\{f(x,y)\} = F(u,v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x,y) \exp(-2\pi i(ux + vy)) \, dx dy \quad (A1)$$

e

$$\mathfrak{F}^{-1}\{F(u,v)\} = f(x,y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u,v) \exp(2\pi i(ux + vy)) \, dudv \quad (\text{A2})$$

onde  $u$  e  $v$  são variáveis de frequência (que é a variação de sinal na unidade de comprimento) e  $i = \sqrt{-1}$ . A transformada de Fourier pode ser decomposta em uma soma de suas componentes, real e imaginária.

$$F(u,v) = \mathbf{Re}(u,v) + i \mathbf{Im}(u,v) \quad (\text{A3})$$

Ou ainda pode ser interpretada em sua forma exponencial

$$F(u,v) = |F(u,v)| e^{i\phi(u,v)}, \quad (\text{A4})$$

onde

$$|F(u,v)| = [\mathbf{Re}^2(u,v) + \mathbf{Im}^2(u,v)]^{1/2}, \quad (\text{A5})$$

é o espectro de Fourier de  $f(u,v)$  e

$$\phi(u,v) = \text{tg}^{-1}(\mathbf{Im}(u,v) / \mathbf{Re}(u,v)), \quad (\text{A6})$$

é o ângulo de fase da transformada. Ademais

$$\mathbf{E}(u,v) = |F(u,v)|^2 = \mathbf{Re}^2(u,v) + \mathbf{Im}^2(u,v) \quad (\text{A7})$$

é o espectro de energia de  $f(x,y)$ .

#### TRANSFORMADA DISCRETA DE FOURIER

As definições acima são válidas para as funções de variáveis contínuas. Para o caso de imagens digitais esta definição deve ser estendida para funções de variável

discreta. Com esta finalidade, a função  $f(x,y)$  pode ser redefinida, através da discretização da função  $f(x,y)$  em intervalos de  $\Delta x$  e  $\Delta y$  nos respectivos eixos coordenados. Esta função pode ser passa a ser representada por

$$f(x,y) = f(x_0 + x\Delta x, y_0 + y\Delta y), \quad (\text{A8})$$

onde  $x$  e  $y$  assumem valores discretos de  $0, \dots, M-1$  e  $0, \dots, N-1$ , respectivamente. Dessa forma o par transformada discreta de Fourier e dado por:

$$F(u,v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \exp \left[ -2\pi i \left( \frac{ux}{M} + \frac{vy}{N} \right) \right], \quad (\text{A9})$$

onde  $u = 0, \dots, M-1$  e  $v = 0, \dots, N-1$ . E

$$f(x,y) = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u,v) \exp \left[ 2\pi i \left( \frac{ux}{M} + \frac{vy}{N} \right) \right], \quad (\text{A10})$$

onde  $x = 0, \dots, M-1$  e  $y = 0, \dots, N-1$ .

os valores de  $u$  e  $v$ , representam na transformada discreta amostras da transformada contínua nos valores  $0, \Delta x, 2\Delta x, \dots, (M-1)\Delta x$  e valores  $0, \Delta y, 2\Delta y, \dots, (N-1)\Delta y$ , respectivamente e portanto  $F(u,v) = F(u\Delta u, v\Delta v)$ . Sendo o incremento na amostra discretizada para o domínio espacial e de frequência definidos por:

$$\Delta u = \frac{1}{M\Delta x} \quad (\text{A11})$$

e

$$\Delta v = \frac{1}{N\Delta y} \quad (\text{A12})$$

Se as dimensões da imagem forem iguais, isto é,  $M=N$  podemos simplificar as transformadas discretas de Fourier para,

$$F(u,v) = \frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x,y) \exp \left[ -2\pi i \left( \frac{ux + vy}{N} \right) \right] , \quad (\text{A13})$$

Onde  $u, v = 0, \dots, N-1$ ; e

$$f(x,y) = \frac{1}{N} \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} F(u,v) \exp \left[ 2\pi i \left( \frac{ux + vy}{N} \right) \right] , \quad (\text{A15})$$

onde  $x, y = 0, \dots, N-1$ .

Assim como no caso contínuo o espectro de energia tem a mesma formulação, a única diferença é que as variáveis independentes  $x$  e  $y$  são discretas.

## **PROPRIEDADES DA TRANSFORMADA BIDIMENSIONAL**

### **DE FOURIER**

Para as propriedades a seguir ilustradas são utilizadas dimensões iguais,  $N=M$ , para melhor apresentação, sem perda de generalidade.

### **SEPARABILIDADE**

O par transformada discreta de Fourier pode ser expresso em separadamente

$$F(u, v) = \frac{1}{N} \sum_{x=0}^{N-1} \exp\left(\frac{-2\pi i u x}{N}\right) \sum_{y=0}^{N-1} f(x, y) \exp\left(\frac{-2\pi i v y}{N}\right), \quad (\text{A17})$$

onde  $u, v = 0, \dots, N-1$ ; e

$$f(x, y) = \frac{1}{N} \sum_{u=0}^{N-1} \exp\left(\frac{2\pi i u x}{N}\right) \sum_{v=0}^{N-1} F(u, v) \exp\left(\frac{2\pi i v y}{N}\right), \quad (\text{A18})$$

onde  $x, y = 0, \dots, N-1$ .

Essa propriedade mostra que se pode obter  $f(x, y)$  e  $F(u, v)$ , através da aplicação sucessiva das transformadas discretas unidimensionais de Fourier direta ou inversas.

### TRANSLAÇÃO

A propriedade de translação do par transformada de Fourier é dado por

$$f(x, y) \exp\left[2\pi i \left(\frac{u_0 x + v_0 y}{N}\right)\right] \Leftrightarrow F(u - u_0, v - v_0) \quad (\text{A19})$$

e

$$f(x - x_0, y - y_0) \Leftrightarrow F(u, v) \exp\left[-2\pi i \left(\frac{u_0 x + v_0 y}{N}\right)\right] \quad (\text{A20})$$

O sinal de equivalência corresponde ao par função e sua transformada (e vice-versa). A equação acima mostra que ao multiplicar-se a função no domínio espacial pelo termo exponencial acima ilustrado em (A19) a transformada de Fourier sofre um deslocamento da origem do plano de frequência para o ponto  $(u_0, v_0)$ , similarmente, o mesmo ocorre para a transformada, que multiplicada pela mesma exponencial move a



origem no plano no domínio espacial para  $(x_0, y_0)$ . Ademais, a magnitude da transformada de Fourier da função não é afetada, isto é

$$\left| f(x, y) \exp \left[ 2\pi i \left( \frac{u_0 x + v_0 y}{N} \right) \right] \right| = | f(x, y) | \quad \text{e} \quad (\text{A21})$$

$$\left| F(u, v) \exp \left[ -2\pi i \left( \frac{u_0 x + v_0 y}{N} \right) \right] \right| = | F(u, v) |, \text{ pois} \quad (\text{A22})$$

$$\left| \exp \left[ -2\pi i \left( \frac{u_0 x + v_0 y}{N} \right) \right] \right| = \left| \exp \left[ 2\pi i \left( \frac{u_0 x + v_0 y}{N} \right) \right] \right| = 1 \quad (\text{A23})$$

### PERIODICIDADE

A transformada discreta de Fourier e sua inversa são periódicas com período  $N$ , isto é,

$$F(u, v) = F(u+N, v) = F(u, v+N) = F(u+N, v+N) \quad (\text{A24})$$

Esta propriedade garante que somente um período da  $F(u, v)$  é necessária para representá-la completamente no domínio de frequência, o mesmo valendo para  $f(x, y)$  no domínio espacial.

### VALOR MÉDIO

Esta propriedade mostra que o valor médio de uma função discreta bidimensional pode ser calculada a partir da Transformada de Fourier nas frequências  $u=v=0$ . Sendo

$$\bar{f}(x, y) = \frac{1}{N^2} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) \quad (\text{A25})$$

o valor médio de uma função discreta bidimensional e sabendo que

$$F(0,0) = \frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x,y), \quad (\text{A26})$$

então o valor médio da função pode ser descrito por

$$\bar{f}(x,y) = \frac{1}{N} F(0,0) \quad (\text{A27})$$

### CONVOLUÇÃO

A convolução entre duas funções  $f(x,y)$  e  $g(x,y)$  é denotada por  $f(x,y) * g(x,y)$  e definida, para os casos contínuo e discreto por:

$$f(x,y) * g(x,y) = \int \int_{-\infty}^{\infty} f(\alpha,\beta) g(x-\alpha, y-\beta) d\alpha d\beta. \quad (\text{A28})$$

e

$$f(x,y) * g(x,y) = \sum_{M=0}^{M-1} \sum_{N=0}^{N-1} f(m,n) g(x-m, y-n) \quad (\text{A29})$$

Sendo que, as seguintes equivalências constituem importante resultado derivado do teorema da convolução.

$$f(x,y) * g(x,y) \Leftrightarrow F(u,v) G(u,v) \quad (\text{A30})$$

$$f(x,y) g(x,y) \Leftrightarrow F(u,v) * G(u,v) \quad (\text{A31})$$

Onde, para a convolução discreta,  $f(x,y)$  e  $g(x,y)$  são funções discretas de dimensões A e B ; C e D, respectivamente. Como o resultado da convolução das duas funções é assumido ser

periódico com valores  $M$  e  $N$  nas direções  $x$  e  $y$ , então estes valores são definidos por

$$M \geq A + C - 1 \text{ e } N \geq B + D - 1 \quad (\text{A32})$$

### TRANSFORMADA RÁPIDA DE FOURIER

Pode-se claramente verificar, que para implementar a Transformada de Fourier, o número de multiplicações e adições é proporcional a  $N^2$ . Usando-se o algoritmo de FFT (Fast Fourier Transform), reduzimos o número de operações a  $N \log_2 N$  multiplicações e adições, o que computacionalmente representa um ganho no tempo de processamento, conforme pode ser visto na tabela A1.

N	FT convencional ( $N^4$ )	FFT ( $N^2 \log_2 N$ )	vantagem computacional ( $N^2 / \log_2 n$ )
2	16	4	4
4	256	32	8
8	4 096	192	21
16	65 536	1 024	64
32	1 048 576	5 120	205
64	16 777 216	24 576	683
128	268 435 456	114 688	2 341
256	4 294 967 296	524 288	8 192
512	68 719 476 736	2 359 296	29 127
1 024	1 099 511 627 776	10 485 760	104 858

Tabela A1

Comparação entre o custo computacional da transformada de Fourier convencional bidimensional e da transformada rápida de Fourier para alguns valores de  $N$

## APÊNDICE 2

### CLASSIFICADOR DE MÁXIMA VEROSSIMILHANÇA

Nesta seção será abordado em detalhe o classificador de máxima verossimilhança. Tal conteúdo é extraído de FUKUNAGA(1990), GONZALES e WOODS(1992), BOW(1992), TOU e GONZALES(1974) e TODT(1998).

Algoritmos de reconhecimento de padrões são freqüentemente classificados como paramétricos ou não-paramétricos. Em algumas classificações as classes dos padrões são conhecidas a priori, sendo caracterizadas por uma conjunto de parâmetros. Uma técnica paramétrica consiste em definir uma função discriminante de classe a partir da densidade de probabilidade definida por um número pequeno de parâmetros. Existem muitas outras técnicas de classificações de padrões em que nenhuma suposição é feita sobre a caracterização de parâmetros, conhecidas como técnicas não-paramétricas. Na técnica paramétrica, os padrões das classes são assumidos como oriundos de uma distribuição gaussiana multivariada onde os parâmetros são o vetor média e a matriz

de covariância. Um classificador paramétrico muito utilizado é o de Máxima verossimilhança Gaussiana. Neste classificador, cada padrão é visto como um ponto no espaço dos padrões. Padrões pertencentes a diferentes classes estarão localizados em diferentes regiões do espaço de padrões, isto é, as diferentes classes serão agrupadas em diferentes regiões e apresentarão uma distribuição de probabilidade característica com uma média e variância próprias. Portanto, cada padrão desconhecido terá uma probabilidade de pertencer a uma determinada classe, isto é,

$$\mathbf{x} \in w_i \text{ se } P(w_i/\mathbf{x}) > P(w_j/\mathbf{x}) , \forall i \neq j \quad (\text{A33})$$

onde  $P(w_i/\mathbf{x})$  é a probabilidade de  $\mathbf{x}$  pertencer a classe  $w_i$ . Porém, como esta probabilidade é desconhecida, podemos usar algumas amostras de cada classe para estimá-la. Utilizando-se do teorema de Bayes

$$P(w_i/\mathbf{x}) = P(\mathbf{x}/w_i) P(w_i) / P(\mathbf{x}) \quad (\text{A34})$$

Onde  $P(w_i)$  é a probabilidade de ocorrência da classe  $w_i$ , isto é, a percentagem de pixel da imagem que pertence à classe  $w_i$  (probabilidade a priori) e  $P(\mathbf{x}/w_i)$  é a probabilidade de um valor da classe  $w_i$  estar na posição  $\mathbf{x}$ . Nota-se que esta probabilidade é obtida das amostras de cada classe. A  $P(\mathbf{x})$  é

a probabilidade de encontrar um valor de qualquer classe na posição  $x$ . Ademais,  $P(\mathbf{x})$ , pode ser obtida por

$$P(\mathbf{x}) = \sum_{i=1}^n P(\mathbf{x}/w_i) \cdot P(w_i) \quad (\text{A35})$$

Utilizando-se o Teorema de Bayes em (A33) e fazendo as simplificações necessárias, tem-se:

$$\mathbf{x} \in w_i \text{ se } P(\mathbf{x}/w_i) P(w_i) > P(\mathbf{x}/w_j) P(w_j) , \forall i \neq j \quad (\text{A36})$$

supondo-se que as classes têm as mesmas probabilidades de ocorrência, então

$$\mathbf{x} \in w_i \text{ se } P(\mathbf{x}/w_i) > P(\mathbf{x}/w_j) , \forall i \neq j \quad (\text{A37})$$

Dessa forma, assumindo que as classes tem distribuição de probabilidade Gaussiana , então:

$$P(\mathbf{x}/w_i) = (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{x} - m_i)^T \Sigma_i^{-1} (\mathbf{x} - m_i)\right] \quad (\text{A38})$$

Onde  $m_i$  é o vetor média e  $\Sigma_i$  é a matriz de covariância para a amostra da classe  $w_i$  em suas  $N$  bandas, com

$$m_i = \frac{1}{k} \sum_{j=1}^k x_j \quad (\text{A39})$$

e

$$\Sigma_i = \frac{1}{k-1} \sum_{j=1}^k (x_j - m_i)(x_j - m_i)^T , \quad (\text{A40})$$

sendo  $k$  o número de elementos de cada amostra.

Aplicando o logaritmo natural em (A38) e eliminando os termos comuns, tem-se

$$G_i(x) = \ln(P(\mathbf{x}/w_i)) = -\ln(\sum_i) - \left[ (x - m_i)^T \Sigma_i^{-1} (x - m_i) \right], \quad (\text{A41})$$

que é a função de Máxima verossimilhança Gaussiana e, portanto,

$$\mathbf{x} \in w_i \text{ se } G_i(\mathbf{x}/w_i) > G_i(\mathbf{x}/w_j), \quad \forall i \neq j \quad (\text{A42})$$

### CLASSIFICADOR DE DISTÂNCIA MÍNIMA OU EUCLIDIANO

O classificador de Distância Mínima ou Euclidiana surge de uma simplificação do classificador de Máxima verossimilhança Gaussiana. Esta simplificação ocorre quando são assumidas três condições restritivas para o classificador de Máxima verossimilhança Gaussiana, isto é:

- 1- todas as probabilidades de ocorrência das classes são iguais, isto é,  $P(w_i) = P(w_j), \quad \forall i, j$
- 2- as matrizes de covariância das classes são iguais entre si. ( $\Sigma_1 = \Sigma_2 = \dots = \Sigma_n = \Sigma$ ).
- 3- a matriz covariância ( $\Sigma_i$ ) é igual a  $\sigma^2 \mathbf{I}$ , onde  $\sigma^2 = \sigma_1^2 = \dots = \sigma_n^2$ , é a variância e  $\mathbf{I}$  é a matriz identidade, tal que  $|\Sigma_i| = \sigma^2$ .

Desta forma, a equação definida em (A41) passa a ter o seguinte aspecto

$$D_i(x) = -\frac{1}{2} \frac{(x - m_i)^T (x - m_i)}{\sigma^2} + \left[ \log(P(w_i)) - \frac{1}{2} \log(\sigma^2) \right] \quad (\text{A43})$$

Pois,  $|\Sigma_i|^{-1} = 1/\sigma^2$ . Eliminando os termos dentro do colchete na equação acima, e o valor  $-\frac{1}{2\sigma^2}$ , pois são valores constantes para todas as classes, obtemos

$$D_i(x) = -(x - m_i)^T(x - m_i) = -|x - m_i|^2 \quad (\text{A44})$$

O classificador definido em (A43) é conhecido como Classificador de Distância Euclidiana ou Classificador de Distância Mínima.



### APÊNDICE 3

#### MATRIZ DE ERRO OU MATRIZ DE CONFUSÃO

A forma padrão para informar o erro local específico é a matriz de erro, às vezes chamada "matriz" de confusão, porque não só identifica erros globais para cada classe, mas também erros de classificação (devido à confusão entre classes) nas classes. Por isso ela é essencial para qualquer estudo sério de precisão.

A matriz de erro consiste em uma matriz  $n \times n$ , onde  $n$  é igual ao número de classes na imagem (tabela A2). Na tabela A2, a primeira coluna a esquerda da tabela refere-se às classes na imagem de referência ("classificação correta"). A quinta linha na parte superior da tabela da matriz de erro diz respeito às mesmas classes de  $n$ , porém estas se referem à imagem a ser avaliada.

Na Tabela A2, vê-se que há 225 pixels de área urbana na imagem de referência (o valor na primeira linha e terceira coluna na matriz de erro). Destes 225 pixels, 150 foram classificados corretamente como "área urbana" (linha 1,

coluna 4). Nos valores que se sucedem ao longo da primeira linha, vê-se os valores incorretamente classificados e as classes para as quais eles foram atribuídos: plantação, pastagem, água, floresta, e terra estéril. Deste modo, cada linha mostra como o classificador atribui pixels pertencentes a cada uma das classes na imagem referência às classes classificadas na imagem temática. A diagonal composta pelos valores referentes às mesmas classes, tanto na imagem de referência, quanto na imagem a ser classificada, mostra os pixels corretamente classificados, de forma que a soma destes valores resulta no total de pixels corretamente classificado pelo classificador.

MATRIZ DE CONFUSÃO OU MATRIZ DE ERRO

Imagem Referência	Exatidão* (%)	Erro de omissão (%)	Número de Pixels Referência	Imagem Classificada					
				Urbana	Plantação	Pastagem	Floresta	Água	Estéril
Urbana	66.67	33.33	<b>225</b>	150	21	0	7	17	30
Plantação	75.03	24.97	<b>973</b>	0	730	93	14	115	21
Pastagem	53.87	46.13	<b>594</b>	33	121	320	23	54	43
Floresta	65.87	34.13	<b>126</b>	3	18	11	83	8	3
Água	72.46	27.54	<b>483</b>	23	81	12	4	350	13
Estéril	60.21	39.79	<b>191</b>	39	8	15	3	11	115
Numero de Pixels Imagem classificada			<b>2592</b>	<b>248</b>	<b>979</b>	<b>451</b>	<b>134</b>	<b>555</b>	<b>115</b>
Erro de Comissão (%)				43.56	25.59	22.05	40.48	42.44	57.59
EXATIDÃO GERAL (%)	<b>67.44</b>								

\* exatidão com relação a imagem de Referência

Tabela A2  
Matriz de contingência para uma imagem de 6 classes

Outras informações relevantes da matriz de erro podem ser ainda apresentadas. A coluna do total de pixels mostra o número total de pixels em cada classe na imagem de referência. A linha de total de pixels, mostra os números de pixels classificados para cada classe na imagem a ser avaliada.

Para construir a matriz de erro deve-se usar duas imagens:

- (1) a imagem de referência e
- (2) o imagem a ser avaliada,

utilizando uma base pixel a pixel para determinar exatamente como cada região na imagem de referência é representado na imagem classificada. Para que esta comparação seja possível, as duas imagens têm que ter a mesma resolução.

#### **ERROS DE OMISSÃO E DE COMISSÃO**

Uma análise da matriz de erro revela, para cada classe, erros de omissão e erros de comissão. Erros de omissão são aqueles cometidos quando atribui-se um pixel que efetivamente pertence a uma determinada classe na imagem de referência a outra classe na imagem a ser avaliada. O erro de comissão é causado por se atribuir um pixel a determinada

classe na imagem a ser classificada quando, na verdade, ele pertence a outra classe na imagem de referência.

#### **INTERPRETAÇÃO DA MATRIZ DE ERRO.**

Os valores fora da diagonal na matriz de erro em cada linha mostram os erros de omissão. Desta forma, para os valores da tabela A2, na primeira linha, 150 pixels são classificados corretamente como área urbana. Os demais 75 pixels são classificados de forma equivocada. Estes 75 pixels são "erros de omissão" porque o classificador errou em atribuí-los a outras classes, quando pertencem realmente à classe urbana.

Em contraste, os valores fora da diagonal na matriz de erro em cada coluna mostram os erros de comissão. Desta maneira, para os valores da tabela A2 na primeira coluna, 150 pixels, são classificados corretamente com área urbana, os demais 98 pixels são classificados de forma equivocada. Estes 98 pixels são "erros de comissão" porque o classificador errou em atribuí-los à classe área urbana quando, na verdade, eles pertencem a outras classes na imagem de referência. Estes erros de omissão e de comissão podem ser representados na forma de percentagem. Assim os 75 pixel não classificados como área urbana na primeira linha representam cerca de 33% da área urbana total, que foi incorretamente

classificada. Portanto, esta percentagem representa o erro de omissão para área urbana.

Da mesma forma, os erros de comissão para área urbana representam aproximadamente 43% do total da área urbana na imagem de referência. Para este exemplo, é evidente que a confusão entre a área urbana e a área estéril é a fonte principal de erro na classificação.

A análise da matriz de erro revela os tipos de erros gerados pelo processo de classificação, permitindo uma melhor interpretação da classificação feita e uma maior precisão em classificações futuras.

Finalmente, a matriz de erro informa a proporção global de pixels corretamente classificados (Exatidão Geral) ou a proporção de pixel por classe em relação à imagem de referência (exatidão\*). A porcentagem de pixels corretamente classificados (exatidão geral) é calculada, somando-se os valores da diagonal e então dividindo este valor pelo número total de pixels da imagem.

**BIBLIOGRAFIA**

- AUGUSTEIJN, Marijki F., CLEMENS, Laura E., SHAW, KELLY A. Performance evaluation of texture measure for ground cover identification in satellite images by means of a neural network classifier. **IEEE Transaction on Geoscience and Remote Sensing**, v. 33, n. 33 , p. 616-625, may. 1995.
- BOVIK, Alan C.; CLARK, Mariana; GEISLER, Wilson S. Multichannel texture analysis using localized spatial filters. **IEEE Transactions on Pattern Analysis And Machine Intelligence**, v 12, n. 1, p. 55-73, jan. 1990.
- BOW, Sing-Tze. **Pattern Recognition on Image Processing**, New York: Marcel Dekker, Inc. 1992.
- BRIGHAM, E.O. **The Fast Fourier Transform**, New York: Prentice-Hall, 1974.
- BRODATZ, P. **Textures : A photogrametric album for artists and designers**, Dover, New York, 1966.
- CHAUDHURI, B.B.; SARKAR, N. Texture segmentation using fractal dimension. **IEEE Transaction on Pattern Analysis and Machine Intelligence**, v. 17 , p. 72-77, 1995.
- DAUGMAN, Jonh G. Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters. **Journal of optics Society American**, v. 2, n. 7, p. 1160-1169, jul. 1985.
- DAUGMAN, Jonh G. Complete discrete 2-D Gabor transform by neural networks for image analysis and compression. **IEEE Transactions on Acoustics, Speech and Signal Processing**, v. 36, n. 7, p. 1169-1179, jul. 1988.
- DUBES,R.C. How many cluster are best? - an experiment. **PATERN RECOGNITION**, v. 20, p. 645-663, 1987.
- DUNN, D.F. ; HIGGINS, W. E. Optimal Gabor filterer for texture segmentation. **IEEE Transactions on Image Processing**, v. 4, n. 7, p. 947-963, set. 1996.
- DUNN, D. F.; HIGGINS, W. E.; WAKELEY, J. texture segmentation using 2-d Gabor elementary functions. **IEEE Transactions on Pattern Analysis And Machine Intelligence**, v. 16, n. 2, p. 130-149, feb. 1994.

- FUKUNAGA, K. **Introduction to statistical Pattern Recognition.** San Diego : Academic Press, Inc. 1990.
- GABEL, R.A.; ROBERTS, R.A. **Signals and linear systems.** Singapore : Jonh Wiley and Sons, inc. 1987.
- GABOR, Dennis. Theory of communication. **Journal of IEEE**, v. 93, p. 429-459. 1946.
- GONZALES, R.F.; WOODS, R.E. **Digital image processing.** New York : Addison-Wesley Publishing Company, 1992.
- HARALICK, Robert M. Statistical and structural approach to texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786-803, may, 1979.
- JAIN, Anil K.; FARROKHANIA, Farshid. Unsupervised texture segmentation using Gabor filters. **Pattern Recognition**, v. 24, n. 12, p. 1167-1186. 1991.
- MEHROTRA, R.; NAMUDURI, K.R.; RANGANATHAN, N. Gabor filter-based edge detection. **Pattern Recognition**, v. 25, n. 12, p. 1479-1494. 1992.
- MUHAMAD, Anwar K.; DERAVI, Farzin. Neural network for the Classification of Image Textur. **Engeneering Application and Artificial Intelligence.** v 7, n.4, p. 381-393. 1994.
- NAMUDURI, K.R.; MEHROTRA, R.; RANGANATHAN, N. Efficient computation of Gabor filter based multiresolution responses. **Pattern Recognition**, v. 27, n. 7, p. 925-938. 1994.
- POLLEN, D.A.; RONNER, S.F. Visual cortical neurons as localized spatial frequency filters. **IEEE Transactions on System, Man and Cybernetics**, v. 13, N. 5, p. 907-916, 1983.
- RAGHU, P.P.; POONGODI, R.; YEGNANARAYANA, B. A combined neural network approach for texture classification. **Neural Networks**, v 8, v. 6, p. 975-987, 1995.
- RICHARDS, J.A. **Remote Sensing Digital Image Analysis:** an introduction. New York : Springer-Verlag, 1986.

- SARKAR, N.; CHAUDHURI, B.B. An efficient approach to estimate fractal dimension of texture image. **Pattern Recognition**, v. 25, p 1035-1041, 1992.
- SKLANSKY, J. Image segmentation and feature extractin. **IEEE Transactions on System, Man and Cybernetics**, v. 13, n. 5, p. 907-916. 1978.
- SLATER, P.N. **Remote Sensing; optics ans optical systems**. Massachusetts: Addison-Wesley Publishing Company, 1980.
- SWAIN, P.H. ; DAVIS, S. M. **Remote Sensing: The Quantitative Approach**. New york: McGraw-Hill, 1978.
- TODT, Viviane. **Avaliação do desempenho de classificadores neurais para aplicação em sensoriamento remoto**. Porto Alegre : CEPSSRM-UFRGS, 1998, 232 p., Dissertação (Mestrado em Sensoriamento Remoto).
- TOU, J.T.; GONZALES, R.F. **Pattern Recognition Principles**. Massachusetts: Addison-Wesley Publishing Company, 1974.
- TURNER, M.R. Texture discrimination by Gabor functions. **Biological Cybernetics**, p. 71-82, Springer-Verlag, 1986.
- VAN HULLE, M.M.; TOLLENAERE, T. A modular artificial neural network for texture processing. **Neural Networks**, v. 6, p. 7-32, 1993.