

UNIVERSIDADE FEDERAL DA PARAÍBA  
CENTRO DE CIÊNCIAS EXATAS E DA NATUREZA  
DEPARTAMENTO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

MODELOS DE COMPRESSÃO DE DADOS  
PARA  
CLASSIFICAÇÃO E SEGMENTAÇÃO DE  
TEXTURAS

TATIANE CRUZ DE SOUZA HONÓRIO

JOÃO PESSOA - PB

Agosto - 2010

UNIVERSIDADE FEDERAL DA PARAÍBA  
CENTRO DE CIÊNCIAS EXATAS E DA NATUREZA  
DEPARTAMENTO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

**MODELOS DE COMPRESSÃO DE DADOS PARA  
CLASSIFICAÇÃO E SEGMENTAÇÃO DE TEXTURAS**

**TATIANE CRUZ DE SOUZA HONÓRIO**

JOÃO PESSOA-PB  
Agosto - 2010

**TATIANE CRUZ DE SOUZA HONÓRIO**

**MODELOS DE COMPRESSÃO DE DADOS PARA  
CLASSIFICAÇÃO E SEGMENTAÇÃO DE TEXTURAS**

DISSERTAÇÃO APRESENTADA AO CENTRO DE CIÊNCIAS EXATAS E DA  
NATUREZA DA UNIVERSIDADE FEDERAL DA PARAÍBA, COMO  
REQUISITO PARCIAL PARA OBTENÇÃO DO TÍTULO DE MESTRE EM  
INFORMÁTICA (SISTEMAS DE COMPUTAÇÃO).

Orientador: Prof. Dr. Leonardo Vidal Batista

JOÃO PESSOA-PB  
Mês-Ano

*H774m Honório, Tatiane Cruz de Souza.*

*Modelos de compressão de dados para classificação e segmentação de texturas / Tatiane Cruz de Souza Honório.- João Pessoa, 2010.*

*76f. : il.*

*Orientador: Leonardo Vidal Batista*

*Dissertação (Mestrado) – UFPB/CCEN*

*1. Sistemas de Computação. 2. PPM. 3. LZW. 4. Texturas – segmentação – classificação. 5. Compressão de dados.*

*UFPB/BC*

*CDU: 004(043)*

Ata da Sessão Pública de Defesa de Dissertação de Mestrado de TATIANE CRUZ DE SOUZA HONÓRIO, candidata ao Título de Mestre em Informática na Área de Sistemas de Computação, realizada em 31 de agosto de 2010.

3

4 Aos trinta e um dias do mês de agosto do ano dois mil e dez, às dez horas, na Sala de Redes  
5 do Centro de Ciências Exatas e da Natureza da Universidade Federal da Paraíba, reuniram-  
6 se os membros da Banca Examinadora constituída para examinar a candidata ao grau de  
7 Mestre em Informática, na área de “*Sistemas de Computação*”, na linha de pesquisa  
8 “*Processamento de Sinais e Sistemas Gráficos*”, a Sra. Tatiane Cruz de Souza Honório. A  
9 comissão examinadora composta pelos professores doutores: Leonardo Vidal Batista (DI -  
10 UFPB), Orientador e Presidente da Banca Examinadora, Natasha Correia Queiroz Lino  
11 (DI-UFPB) como examinador interno e Tsang Ing Ren (UFPE) como examinador externo.  
12 Dando início aos trabalhos, o Prof. Leonardo Vidal Batista, cumprimentou os presentes,  
13 comunicou aos mesmos a finalidade da reunião e passou a palavra ao candidato para que o  
14 mesmo fizesse, oralmente, a exposição do trabalho de dissertação intitulado “*MODELOS  
15 DE COMPRESSÃO DE DADOS PARA CLASSIFICAÇÃO E SEGMENTAÇÃO DE  
16 TEXTURAS*”. Concluída a exposição, o candidato foi argüido pela Banca Examinadora que  
17 emitiu o seguinte parecer: “*aprovado*”. Assim sendo, deve a Universidade Federal da  
18 Paraíba expedir o respectivo diploma de Mestre em Informática na forma da lei e, para  
19 constar, a professora Tatiana Aires Tavares, Sra. Coordenadora do PPGI, lavrou a  
20 presente ata, que vai assinada por ela, e pelos membros da Banca Examinadora. João  
21 Pessoa, 31 de agosto de 2010.

22

*Tatiana Aires Tavares*  
Tatiana Aires Tavares

23

24

Prof. Dr. Leonardo Vidal Batista  
Orientador (DI-UFPB)

*Leonardo Vidal Batista*

Prof<sup>a</sup>. Dr<sup>a</sup>. Natasha Correia Queiroz Lino  
Examinador Interno (DI-UFPB)

*Natasha Correia Queiroz Lino*

Prof. Dr. Tsang Ing Ren  
Examinador Externo (UFPE)

*Tsang Ing Ren*

25

Dedico este trabalho aos meus pais, Antonio Honório Neto e Onélia Cruz de Souza Honório a quem devo todas as minhas conquistas.

## AGRADECIMENTOS

Acredito que apenas Deus saiba o quanto foi difícil chegar até aqui. O quanto o caminho foi árduo, principalmente a reta final. A Ele devo minha maior gratidão.

Também tenho muito a agradecer ao meu orientador, o professor Dr. Leonardo Vidal Batista, não apenas por esse trabalho, mas por tudo o que fez por mim desde que ingressei no Programa de Educação Tutorial (PET) em 2006. Agradeço por tudo o que me foi ensinado, pelas reuniões (terapias) do PET, pela paciência e compreensão diante das dificuldades e por ter feito a diferença na minha vida.

Agradeço a toda minha família pela confiança depositada em mim. Aos meus pais, por tanto amor, compreensão e apoio e às minhas irmãs por toda a ajuda, companheirismo e amizade.

Aos amigos e colegas do mestrado e do PET que também contribuíram com idéias ou palavras de apoio e incentivo. Agradeço, em especial, Eduardo Freire Santana pela contribuição na pesquisa com imagens de Sensoriamento Remoto. Além daqueles que estão sempre torcendo por mim: Chico, Eduardo, Márcio, Moisés e Rodrigo.

A todos os professores do Programa de Pós-Graduação em Informática da UFPB. Em especial ao professor Lucídio dos Anjos Formiga Cabral, por ser um grande mestre, ao professor Ronei Marcos de Moraes e suas alunas pelas imagens de SR cedidas e à professora Tatiana Aires Tavares por toda sua ajuda.

## RESUMO

Este trabalho se propõe a analisar métodos de classificação e segmentação de texturas de imagens digitais usando algoritmos de compressão de dados sem perdas. Dois algoritmos de compressão são avaliados: o *Prediction by Partial Matching* (PPM) e o *Lempel-Ziv-Welch* (LZW), que já havia sido aplicado na classificação de texturas em trabalhos anteriores. As texturas são pré-processadas utilizando equalização de histograma. O método de classificação divide-se em duas etapas. Na etapa de aprendizagem, ou treinamento, o algoritmo de compressão constrói modelos estatísticos para as estruturas horizontal e vertical de cada classe. Na etapa de classificação, amostras de texturas a serem classificadas são comprimidas utilizando modelos construídos na etapa de aprendizagem, varrendo-se as amostras na horizontal e na vertical. Uma amostra é atribuída à classe que obtiver a maior compressão média. Os testes dos classificadores foram feitos utilizando o álbum de texturas de Brodatz. Os classificadores foram testados para vários tamanhos de contexto (no caso do PPM), amostras e conjuntos de treinamento. Para algumas das combinações desses parâmetros, os classificadores alcançaram 100% de classificações corretas. A segmentação de texturas foi realizada apenas com o PPM. Inicialmente, são criados os modelos horizontais usados no processo de segmentação, utilizando-se oito amostras de texturas de tamanho 32 x 32 pixels para cada classe, com o contexto PPM de tamanho máximo 1. As imagens a serem segmentadas são comprimidas utilizando-se os modelos das classes, inicialmente, em blocos de tamanho 64 x 64 pixels. Se nenhum dos modelos conseguir uma razão de compressão em um intervalo pré-definido, o bloco é dividido em quatro blocos de tamanho 32 x 32. O processo se repete até que algum modelo consiga uma razão de compressão no intervalo de razões de compressão definido para o tamanho do bloco em questão, podendo chegar a blocos de tamanho 4 x 4 quando o bloco é classificado como pertencente à classe do modelo que atingiu a maior taxa de compressão.

Palavras-chave: *Prediction by Partial Matching* (PPM), *Lempel-Ziv-Welch* (LZW), segmentação de texturas, classificação de texturas, reconhecimento de padrões, compressão de dados.

# ABSTRACT

This work analyzes methods for textures images classification and segmentation using lossless data compression algorithms models. Two data compression algorithms are evaluated: the *Prediction by Partial Matching* (PPM) and the Lempel-Ziv-Welch (LZW) that had been applied in textures classification in previous works. The textures are pre-processed using histogram equalization. The classification method is divided into two stages. In the learning stage or training, the compression algorithm builds statistical models for the horizontal and the vertical structures of each class. In the classification stage, samples of textures to be classified are compressed using models built in the learning stage, sweeping the samples horizontally and vertically. A sample is assigned to the class that obtains the highest average compression. The classifier tests were made using the Brodatz textures album. The classifiers were tested for various contexts sizes (in the PPM case), samples number and training sets. For some combinations of these parameters, the classifiers achieved 100% of correct classifications. Texture segmentation process was made only with the PPM. Initially, the horizontal models are created using eight textures samples of size 32 x 32 pixels for each class, with the PPM context of a maximum size 1. The images to be segmented are compressed by the models of classes, initially in blocks of size 64 x 64 pixels. If none of the models achieve a compression ratio at a predetermined interval, the block is divided into four blocks of size 32 x 32. The process is repeated until a model reach a compression ratio in the range of the compression ratios set for the size of the block in question. If the block get the 4 x 4 size it is classified as belonging to the class of the model that reached the highest compression ratio.

Key-words: *Prediction by Partial Matching* (PPM), *Lempel-Ziv-Welch* (LZW), texture segmentation, texture classification, histogram equalization, pattern recognition, data compression.

## LISTA DE FIGURAS

Figura 1 – Exemplos de texturas (a) e (b) do banco Vistex (Bark.0007 e Brick.0007), (c) e (d) do banco de Brodatz (D99 e D35).....	17
Figura 2 – (a) textura regular do banco de texturas da <i>Pennsylvania State University</i> [CMU NRT], (b) textura quase regular do banco de Brodatz, (c) textura irregular do banco de Brodatz. ....	19
Figura 3 - Representação gráfica usual de uma imagem digital monocromática.....	24
Figura 4 - Imagem predominantemente escura contendo uma região de alta luminosidade [Fonte: National Geographic's International Photography Contest 2009] .....	26
Figura 5 - Histograma da imagem mostrada na Figura 4. ....	26
Figura 6 – Imagem com histograma equalizado.....	27
Figura 7 – Histograma equalizado da Figura 6.....	28
Figura 8 - Imagem Ikonos, PSM, resolução de 1 m. Região de Paulista e Olinda - PE. Imageada em 08 de janeiro de 2001 [Engesat].....	36
Figura 9 - Efeito da equalização de histograma nas texturas D1 (acima) e D2 (abaixo). O resultado da equalização de histograma está mostrado nas imagens à direita.....	40
Figura 10 – Da Esquerda para direita, de cima para baixo: Histograma da textura D1, histograma equalizado de D1, histograma da textura D2, histograma equalizado de D2. ....	41
Figura 11 – Ordem de varredura das amostras. (a) horizontal, (b) vertical.....	42
Figura 12 - Mosaico 1 e seu mapa de texturas correspondente em níveis de cinza. ....	44
Figura 13 - Mosaico 2 e seu mapa de texturas correspondente em níveis de cinza. ....	45
Figura 14 – Da esquerda para direita, de cima para baixo: D9, D19, D24, D29, D38, D68, D84, D92. ....	45
Figura 15 – Imagem do Manual do Usuário do Catálogo de Imagens da DGI/INPE com informações sobre a Câmera CCD. ....	47
Figura 16 - Ordem de varredura das amostras. (a) horizontal, (b) vertical. ....	48
Figura 17 - Composição colorida de cinco bandas de imagem do município de João Pessoa. ....	49
Figura 18 - Da esquerda para direita, de cima para baixo: D1, D3, D6, D11, D16, D17, D20, D21, D24, D28, D29, D32, D34, D35, D46, D47, D49, D51, D52, D53, D55, D56, D57, D65, D78, DD82, D84, D85, D101, D104. ....	52
Figura 19 - Comparação entre o CPPHE para $K = 1$ com o classificador SVD.....	55
Figura 20 – À esquerda, mapa de níveis de cinza do mosaico 1. À direita, resultado da segmentação do mosaico 1. ....	55
Figura 21 - Segmentação do mosaico 2 usando os intervalos de razão de compressão contidos na Tabela 5.....	56
Figura 22 - Segmentação do mosaico 2 usando os intervalos de razão de compressão contidos na Tabela 6.....	57
Figura 23 - Segmentação do mosaico 2 usando os intervalos de razão de compressão contidos na Tabela 7.....	58
Figura 24 – Resultado da segmentação do mosaico da Figura 13 com o método SRI com vizinhança 5 x 5 e usando 64 vetores básicos. ....	59
Figura 25 – Mosaico original (à esquerda) e o resultado da segmentação pelo método de Decomposição Bidimensional Empírica e Dimensão Fractal (à direita).....	59
Figura 26 – Mosaicos originais (acima). Resultado da segmentação do método Fuzzy SVM (abaixo).....	60

Figura 27 – Resultado da segmentação da imagem da Figura 17. ....	61
Figura 28 - Textura de Brodatz D51. A original, à esquerda, e a rotacionada em 90°, à direita. .....	62
Figura 29 - Banda 1 .....	74
Figura 30 - Banda 2 .....	75
Figura 31 - Banda 3 .....	76
Figura 32 - Banda 4 .....	77
Figura 33 - Banda 5 .....	78

## LISTA DE TABELAS

Tabela 1 - Representação matricial de uma imagem digital monocromática.....	24
Tabela 2 - Níveis de cinza usados para diferenciação das classes de texturas.....	44
Tabela 3 – TCC obtidas com e sem equalização de histograma para PPM de contexto máximo $K = 1$ .....	53
Tabela 4 – TCC obtidas pelo classificador proposto, com equalização de histograma, usando apenas a varredura horizontal.....	53
Tabela 5 – Comparação entre o CPPMHE e outros métodos da literatura.....	54
Tabela 6 - Razões de compressão máxima e mínima alcançadas quando amostras de diferentes tamanhos foram comprimidas pelos seus respectivos modelos.....	70
Tabela 7 - Intervalos de razões de compressão obtidas quando amostras de diferentes tamanhos foram comprimidas pelos seus respectivos modelos e as razões máxima e mínima alcançadas foram desprezadas.....	71
Tabela 8 - Intervalos de razões de compressão obtidas quando amostras de diferentes tamanhos foram comprimidas pelos seus respectivos modelos e as duas maiores e as duas menores razões alcançadas foram desprezadas.....	72

## LISTA DE EQUAÇÕES

$g = T[f]$ (1) .....	25
$P(l) = \frac{n_l}{n}$ (2) .....	25
$s = T(r) = \text{round} \frac{L-1}{RC} \sum n_l$ (3) .....	27
$G_n(P) = -\frac{1}{n} \sum_{i=1}^{M^n} P(\mathbf{x}_i^n) \log_2 P(\mathbf{x}_i^n)$ (4) .....	29
$H(P) = \lim_{n \rightarrow \infty} G_n(P)$ bits/símbolo (5) .....	29
$F_n(P) = -\sum_{i=1}^{M^n} \sum_{j=1}^M P(\mathbf{x}_i^{n-1}, a_j) \log_2 P(a_j   \mathbf{x}_i^{n-1})$ bits/símbolo (6).....	29
$H(P) = \lim_{n \rightarrow \infty} F_n(P)$ bits/símbolo (7).....	29

## LISTA DE SIGLAS

<b>PDI</b>	<b>Processamento Digital de Imagens</b>
<b>PPM</b>	<b>Prediction by Partial Matching</b>
<b>PPM-C</b>	<b>Variação do algoritmo PPM</b>
<b>LVQ</b>	<b>Learning Vector Quantization</b>
<b>SVM</b>	<b>Support Vector Machine</b>
<b>SVD</b>	<b>Singular Value Decomposition</b>
<b>SR</b>	<b>Sensoriamento Remoto</b>
<b>USC-SIPI</b>	<b>Signal and Image Processing Institute of the University of Southern California</b>
<b>CPPM</b>	<b>Classificador proposto</b>
<b>CPPMHE</b>	<b>Classificador proposto utilizando equalização de histograma</b>
<b>TCC</b>	<b>Taxa de Classificações Corretas</b>
<b>LZW</b>	<b>Lempel-Ziv-Welch</b>
<b>CLZWHE</b>	<b>Classificador LZW utilizando equalização de histograma</b>
<b>INPE</b>	<b>Instituto Nacional de Pesquisas Espaciais</b>

## SUMÁRIO

<b>Capítulo 1 - INTRODUÇÃO .....</b>	<b>16</b>
1.1 O Problema .....	16
1.2 Objetivo Geral .....	19
1.3 Objetivos Específicos .....	20
1.4 Justificativa .....	20
1.5 Estrutura do Trabalho .....	21
1.6 Resumo do Capítulo .....	21
<b>Capítulo 2 - FUNDAMENTAÇÃO TEÓRICA E REVISÃO DA LITERATURA 23</b>	<b>23</b>
2.1 Imagem Digital .....	23
2.2 Equalização de Histograma .....	25
2.3 Entropia, Modelos Estatísticos e o Reconhecimento de Padrões .....	28
2.4 O Compressor de dados PPM .....	30
2.5 O Compressor de dados LZW .....	33
2.6 Classificação e Segmentação de Texturas .....	34
2.7 Sensoriamento Remoto .....	35
2.8 Resumo do Capítulo .....	37
<b>Capítulo 3 - PROCEDIMENTOS METODOLÓGICOS .....</b>	<b>38</b>
3.1 A Classificação .....	38
3.2 Pré-processamento .....	39
3.3 Etapa de Aprendizagem .....	41
3.4 Etapa de Classificação .....	42
3.5 A Segmentação .....	43
3.6 Sensoriamento Remoto .....	46
3.7 Resumo do Capítulo .....	50
<b>Capítulo 4 - RESULTADOS .....</b>	<b>51</b>
4.1 Classificação .....	51
4.2 Experimentos com 30 Texturas .....	52
4.3 Testes com 112 Texturas .....	54
4.4 Segmentação .....	55
4.5 Testes com Dados de Sensoriamento Remoto .....	60
4.6 Testes Variando a Rotação .....	61
4.7 Resumo do Capítulo .....	62
<b>Capítulo 5 - DISCUSSÃO E CONCLUSÕES .....</b>	<b>63</b>
<b>REFERÊNCIAS .....</b>	<b>66</b>
<b>APÊNDICES .....</b>	<b>69</b>
Apêndice A .....	70
Apêndice B .....	74

# Capítulo

---

# 1

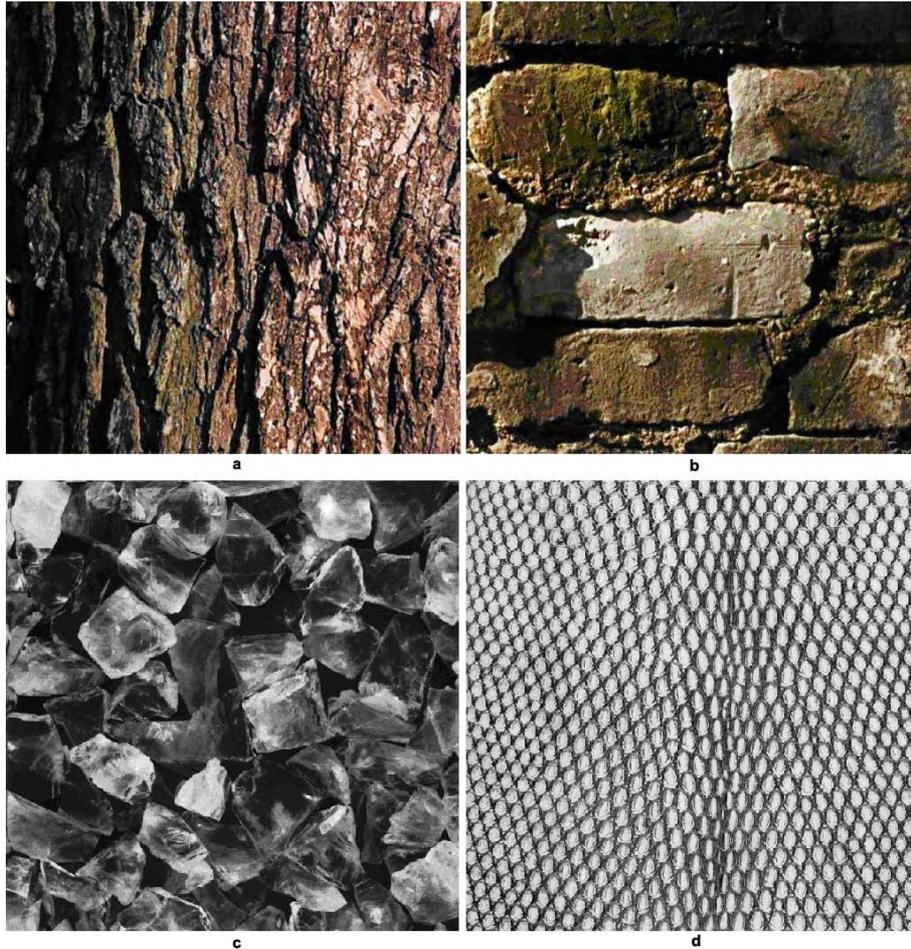
## INTRODUÇÃO

Imagens digitais estão cada vez mais presentes no cotidiano das pessoas. Com preços cada vez mais populares, é possível encontrar câmeras digitais nos mais diversos aparelhos eletrônicos e a internet possibilita o compartilhamento desse tipo de mídia. Assim, cresce a cada dia o número de aplicações possíveis para o processamento digital de imagens. A análise de imagens pode ser de grande utilidade para a medicina no auxílio ao diagnóstico de doenças; para atividades espaciais como a astronomia, o sensoriamento remoto e a meteorologia; em aplicações forenses; em questões de segurança, como o controle de acesso através da biometria; no controle do trânsito, através do reconhecimento de placas de veículos; nas artes e no entretenimento, como uso da computação gráfica no cinema, dentre muitas outras.

Por processamento digital de imagens (PDI) entende-se a manipulação de imagens por sistemas de computador com o objetivo tratar a informação pictórica para que possa ser interpretada por humanos ou pelo próprio sistema. O processamento digital de imagens está correlacionado com outras áreas como a computação gráfica e a visão computacional.

### 1.1 O Problema

Apesar de não haver consenso sobre a definição de textura, pode-se referenciá-la como sendo um conjunto de determinados padrões existentes nas superfícies físicas, perceptíveis ao olho humano e que trazem grande quantidade de informações sobre a natureza da superfície, como suavidade, rugosidade e regularidade. A Figura 1 apresenta exemplos de texturas.



**Figura 1 – Exemplos de texturas (a) e (b) do banco Vistex (Bark.0007 e Brick.0007), (c) e (d) do banco de Brodatz (D99 e D35).**

Para descrição de padrões de texturas em imagens, normalmente são utilizadas três abordagens principais: a estatística, a estrutural e a espectral [Gonzalez & Woods, 2002].

A textura é um dos mais importantes atributos usados pelo sistema visual humano e sistemas de visão computacional para segmentação, classificação e interpretação de cenas [Porat e Zeevi, 1989]. Há um grande interesse no desenvolvimento de métodos baseados em classificação e segmentação de texturas em diferentes áreas como sensoriamento remoto, diagnóstico e tratamento médico baseado em imagens [Southard, 1996], [Liu, X., Liu, J., Zhou, D. e Tang, J., 2010] e [Chevrefils, C., Cheriet, F., Aubin, C. e Grimard G., 2009], automação industrial [Ross, Prabhakar, 2004], reconhecimento biomédico [He, Hu, Zhang, Cheng, Yan, 2004] [Baheerathan, Albregtsen, Danielsen, 1999] e recuperação de imagens por conteúdo [Balan, Traina, Traina Jr., Marques, 2004].

O reconhecimento de texturas consiste em atribuir uma amostra de textura  $x$ , de natureza desconhecida, a uma dentre  $N$  classes  $C_i$ ,  $i = 1, 2, \dots, N$ .

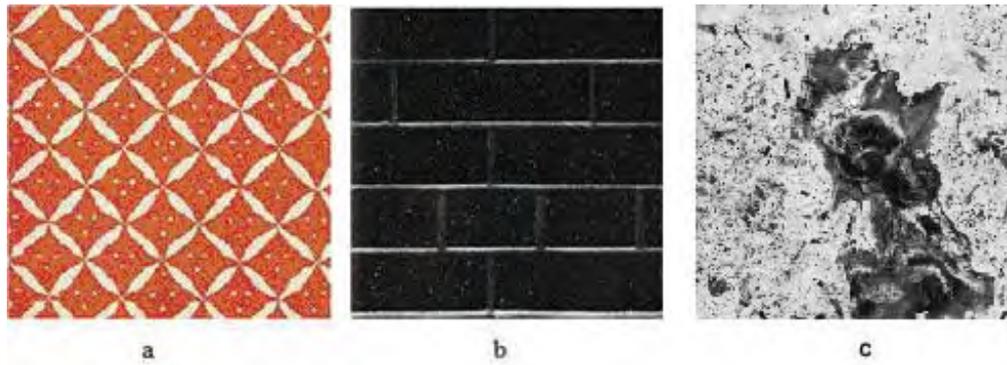
Características discriminantes ou modelos estruturais ou estatísticos são usados para caracterizar as classes de texturas e, então, é feita a classificação de acordo com algum método de mensuração de similaridade entre  $x$  e cada classe.

Embora sejam prontamente reconhecidas e intuitivamente compreendidas pelo sistema visual humano, texturas não são fáceis de caracterizar formalmente. A maior dificuldade está na definição do que é mais importante para caracterizar texturas, o que depende de considerações perceptuais subjetivas e das aplicações particulares para as quais o reconhecimento de texturas será utilizado. Portanto, a extração de características relevantes e a criação de modelos para as classes de texturas tendem a ser tarefas difíceis. Uma definição comum, mas ainda vaga, afirma que texturas são padrões espaciais formados por repetições mais ou menos precisas de alguns sub-padrões base. A colocação destes sub-padrões pode ser periódica, quase-periódica ou aleatória.

Após escolher as características específicas ou os modelos que serão utilizados para caracterizar as classes de textura, um método de classificação deve ser definido.

Uma das dificuldades encontradas pelos métodos de classificação de textura é o fato das texturas poderem ser divididas, quanto à regularidade de algumas de suas dimensões (cor, intensidade, geometria), em três tipos: texturas regulares, aquelas com padrões periódicos; texturas quase regulares, que são texturas com pequenas distorções estruturais geométricas, mas com consideráveis diferenças estatísticas em cor e intensidade em relação ao padrão de texturas regulares; e texturas irregulares, onde podem ser encontradas deformações substanciais tanto estruturais quanto na cor e intensidade comparadas às texturas regulares [Liu e Lin 2003]. A Figura 2 mostra exemplos desses diferentes tipos de texturas.

Com base na análise de diversos métodos de filtragem para classificação de texturas, Randem e Husøy sugerem que o desenvolvimento de métodos poderosos de classificação de textura com baixa complexidade computacional é uma direção de pesquisa de grande utilidade [Randem, T., Husøy, J. H, 1999]. Em algumas aplicações, tais como a inspeção industrial através da *Web*, a entrada a ser analisada é enorme e a maioria das soluções de visão computacional requer métodos rápidos e suporte especial ao hardware [Kumar e Pang, 2002]. Além disso, a alta acurácia é essencial em muitas aplicações, tais como em análise de imagens médicas.



**Figura 2 – (a) textura regular do banco de texturas da *Pennsylvania State University* [CMU NRT], (b) textura quase regular do banco de Brodatz, (c) textura irregular do banco de Brodatz.**

A segmentação de imagens é um problema fundamental para o processamento de imagens digitais e é ainda mais complexo que o da classificação. Traduzir para o computador o processo de seleção e agrupamento realizado pela visão humana na identificação de regiões semelhantes não é uma tarefa fácil. Várias dificuldades estão presentes: a complexidade da textura, a não-homogeneidade da iluminação, presença de texturas irregulares, imprecisões das regiões das bordas, etc. Não existe um modelo formal para a segmentação, o processo é essencialmente empírico e deverá se ajustar a diferentes tipos de imagens. Na análise de imagens, a eficiência obtida na identificação e separação das regiões de interesse influencia os resultados das etapas subsequentes. Como a segmentação não é um fim em si, sua qualidade é determinada pela adequação das regiões extraídas aos tratamentos que serão realizados nas próximas etapas [Conci, 2007].

## 1.2 Objetivo Geral

O objetivo geral deste trabalho foi desenvolver um método novo e eficaz de classificação e segmentação de texturas de imagens digitais utilizando o algoritmo de compressão de dados *Prediction by Partial Matching* (PPM) e fazer uma comparação com os resultados obtidos por outro algoritmo de compressão de dados, o *Lempel-Ziv Welch* (LZW), na solução problema de classificação de texturas.

### 1.3 Objetivos Específicos

- Realizar uma comparação entre os métodos de classificação
- Desenvolver um classificador de alta acurácia, capaz de reconhecer texturas corretamente, mesmo para um conjunto de treinamento reduzido e amostras pequenas, para possibilitar uma boa definição das fronteiras dos mosaicos segmentados;
- Realizar testes variando o tamanho e o número de amostras usadas nas fases de treinamento e classificação;
- Avaliar o efeito produzido pelo uso da equalização de histograma como pré-processamento;
- Reproduzir testes apresentados anteriormente na literatura para comparações diretas com outros métodos;
- Efetuar um estudo de caso, aplicando o método para segmentação de imagens de sensoriamento remoto.

### 1.3 Justificativa

Classificar e, conseqüentemente, poder segmentar uma imagem são métodos básicos e que antecedem a aplicação de diversos outros métodos para a análise de imagens digitais. Sendo assim, representam técnicas necessárias nas mais diversas áreas do processamento digital de imagens e de visão computacional.

A aplicação do algoritmo LZW na classificação de texturas já havia sido estudada por Meira, M. [Meira, M. M., 2008] e, devido ao alcance de resultados expressivos, constatou-se que o PPM também poderia se mostrar eficiente na classificação e segmentação de texturas.

Tanto o LZW quanto o PPM são compressores estatísticos, que exploram as dependências entre os símbolos, levando em consideração símbolos vistos anteriormente.

Essa característica representa outra evidência de que esses compressores podem ser aplicados na classificação de texturas.

## **1.4 Estrutura do Trabalho**

O capítulo 1 contém a Fundamentação Teórica deste trabalho, mostrando os conceitos de imagem digital, equalização de histograma, entropia e modelos estatísticos e os compressores PPM e LZW. É feita, também, uma revisão do que já foi mostrado na literatura a respeito da classificação e segmentação de texturas e sua aplicação na área de sensoriamento remoto.

No capítulo 2 são descritos os procedimentos metodológicos adotados durante a realização dos testes com os métodos de classificação e a segmentação. São descritas as etapas de pré-processamento, de treinamento, os testes realizados e as imagens utilizadas.

O capítulo 3 expõe os resultados dos testes com os classificadores feitos usando 30 das 112 texturas de Brodatz e usando o álbum completo. São mostrados também os resultados da segmentação de mosaicos feitos com texturas de Brodatz.

O capítulo 4 discute os resultados mostrados no capítulo 3 e apresenta as conclusões obtidas com a realização deste trabalho.

Por fim, são apresentadas as referências bibliográficas deste trabalho, organizadas por ordem alfabética. Há ainda dois Apêndices contendo tabelas e figuras utilizadas.

## **1.6 Resumo do Capítulo**

O objetivo do capítulo foi justificar a escolha do tema deste trabalho, expondo as aplicações da área de processamento de imagens e quais os problemas a classificação e segmentação de texturas se propõem a resolver. Foram apresentados, ainda, os objetivos gerais e específicos do trabalho.

No próximo capítulo, será apresentada a fundamentação teórica na qual se baseia esse trabalho e será feita uma revisão do que já foi apresentado à literatura à respeito de classificação e segmentação de texturas.

## 2

**FUNDAMENTAÇÃO TEÓRICA E REVISÃO DA  
LITERATURA****2.1 Imagem Digital**

Um pixel (*picture element*) representa o menor elemento de uma imagem digital.

Por imagem digital entende-se um sinal de duas dimensões que pode ser representado pela função  $f(x, y)$ , onde  $x$  e  $y$  são as coordenadas espaciais do pixel e o valor de  $f(x, y)$  é o *nível de cinza* ou intensidade luminosa, no caso de uma imagem monocromática, do pixel.

Uma imagem é composta pela quantidade de luz que incide sobre um ponto (iluminação) característica que depende da fonte de iluminação, e pela quantidade de luz refletida pelo ponto (reflectância) que depende dos objetos da cena fotografado. A multiplicação do valor da iluminação pelo valor da reflectância gera o valor da intensidade luminosa do ponto, ou seja, forma o valor de  $f(x, y)$  do pixel  $(x, y)$ .

A intensidade luminosa de um pixel varia de 0 a  $L-1$ , onde  $L$  é o número de níveis de quantização usados no processo de digitalização da imagem.

Uma imagem monocromática apresenta unicamente variações de cinzas, com pixels mais claros representando valores mais elevados e pixels mais escuros representados por valores mais baixos. Pixels pretos têm valor zero, enquanto que pixels brancos têm valor  $L-1$ . A Figura 3 mostra uma imagem monocromática de 512 linhas X 512 colunas, com  $L = 256$ . A Tabela 1 apresenta os valores dos pixels de parte da imagem.



**Figura 3 - Representação gráfica usual de uma imagem digital monocromática.**

**Tabela 1 - Representação matricial de uma imagem digital monocromática.**

161	162	163	162	...	154	127
162	162	162	161	...	157	130
162	162	162	161	...	156	128
163	163	162	161	...	156	129
164	163	161	160	...	152	127
163	162	160	160	...	103	80
161	160	159	158	...	66	53
...	...	...	...	...	...	...
43	41	57	50	...	106	106
44	42	57	48	...	108	109

## 2.2 Equalização de Histograma

Em processamento de imagens, um *filtro* é definido como uma operação unária, na qual uma única imagem é processada e produz uma imagem de saída. A equação 1, representa a operação de um filtro  $T$ , onde  $f$  é a imagem de entrada, e  $g$  representa a imagem  $f$  após o processamento.

$$g = T[f] \quad (1)$$

A equalização de histograma é um filtro bastante usado no melhoramento de contraste das imagens.

Seja  $l$  o nível de cinza que ocorre  $n_l$  vezes em uma imagem com  $n$  pixels. A probabilidade estimada de ocorrência do nível  $l$  na imagem por intermédio de sua frequência relativa é:

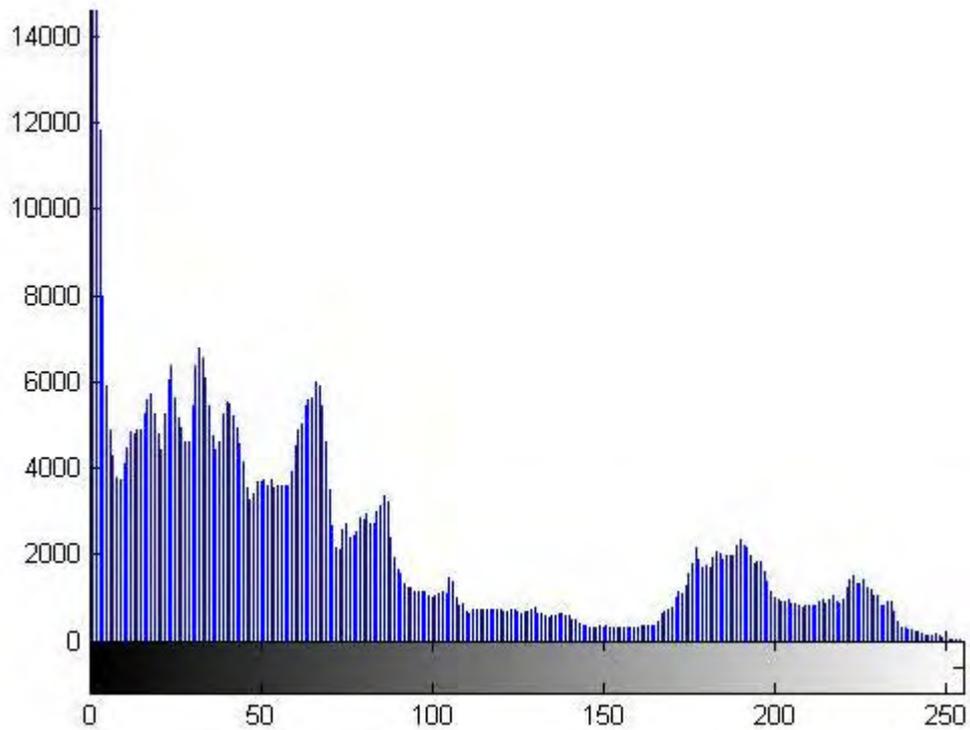
$$P(l) = \frac{n_l}{n} \quad (2)$$

O histograma de uma imagem é um gráfico estatístico que apresenta a quantidade de pixels ( $n_l$ ) contidos em cada um dos  $L$  níveis de cinza de uma imagem.

Através da análise do histograma de uma imagem é possível perceber como os níveis de cinza estão distribuídos. A Figura 4 apresenta uma imagem predominantemente escura contendo uma região de alta luminosidade, seu histograma correspondente é mostrado na Figura 5.



**Figura 4 - Imagem predominantemente escura contendo uma região de alta luminosidade [Fonte: National Geographic's International Photography Contest 2009]**



**Figura 5 - Histograma da imagem mostrada na Figura 4.**

O objetivo da equalização de histograma é uniformizar a distribuição dos níveis de cinza da imagem, produzindo um aumento substancial no nível de detalhes perceptíveis da imagem, já que diferenças sutis entre níveis de cinza próximos são realçados.

A operação de equalização de histograma em uma imagem de dimensões  $R \times C$  é proporcionada pela transformação:

$$s = T(r) = \text{round} \frac{L-1}{RC} \sum n_i \quad (3)$$

A Figura 6 mostra a imagem da Figura 4 após a equalização de histograma ser aplicada.



**Figura 6 – Imagem com histograma equalizado.**

Após a aplicação do filtro, detalhes que antes não eram vistos, como a vegetação, passaram a ser visíveis.

A Figura 7 contém o histograma equalizado.

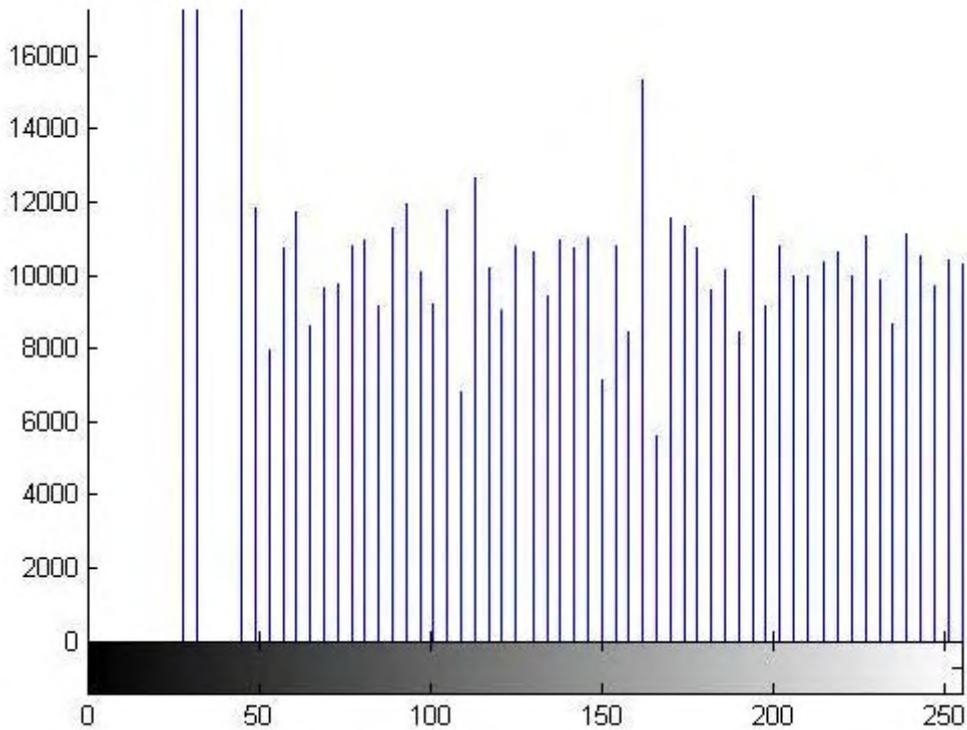


Figura 7 – Histograma equalizado da Figura 6.

## 2.3 Entropia, Modelos Estatísticos e o Reconhecimento de Padrões

A compressão de dados é o processo de redução do tamanho físico (número de bytes) necessário para armazenar a informação. Para que isso seja possível, muitos algoritmos precisam entender como a fonte de informação funciona, ou seja, precisam aprender o seu comportamento. Tal característica faz com que alguns algoritmos de compressão de dados sejam capazes de reconhecer fontes de informação e, por isso, sejam bastante eficazes no reconhecimento de padrões.

Seja  $S$  uma fonte de informação discreta e estacionária, que gera mensagens de um alfabeto finito  $A = \{a_1, a_2, \dots, a_M\}$ . A fonte escolhe símbolos sucessivos de  $A$  de acordo com alguma distribuição de probabilidades que depende, em geral, dos símbolos selecionados anteriormente. Uma mensagem genérica será modelada como um processo estatístico estacionário  $\mathbf{x} = \dots x_{-2} x_{-1} x_0 x_1 x_2, \dots$ , com  $x_i \in A$ . Seja  $\mathbf{x}^n$  a representação de uma mensagem de

comprimento  $n$ ,  $\mathbf{x}^n = x_1x_2\dots x_n$ . Uma vez que o alfabeto tem cardinalidade  $|A| = M$ , a fonte pode gerar  $M^n$  diferentes mensagens de comprimento  $n$ . Esteja  $\mathbf{x}_i^n$ ,  $i = 1, 2, \dots, M^n$  denotando o  $i^{\text{th}}$  dessas mensagens, de acordo com alguma ordenação arbitrária, e assumindo que a fonte segue a probabilidade de distribuição  $P$ , então aquela mensagem  $\mathbf{x}_i^n$  é produzida com probabilidade  $P(\mathbf{x}_i^n)$ .

Seja

$$G_n(P) = -\frac{1}{n} \sum_{i=1}^{M^n} P(\mathbf{x}_i^n) \log_2 P(\mathbf{x}_i^n) \quad (4)$$

$G_n(P)$  diminui monotonicamente com  $n$  [Shannon, C. E., 1948] e entropia da fonte é:

$$H(P) = \lim_{n \rightarrow \infty} G_n(P) \text{ bits/símbolo} \quad (5)$$

Uma formulação alternativa para  $H(P)$  usa probabilidades condicionais. Seja  $P(\mathbf{x}_i^{n-1}, a_j)$  a probabilidade da seqüência  $\mathbf{x}_i^n = (\mathbf{x}_i^{n-1}, a_j)$ , i.e., a probabilidade de  $\mathbf{x}_i^{n-1}$  concatenado com o símbolo  $x_n = a_j$ ; e seja  $P(a_j | \mathbf{x}_i^{n-1}) = P(\mathbf{x}_i^{n-1}, a_j) / P(\mathbf{x}_i^{n-1})$  a probabilidade do símbolo  $x_n = a_j$  dado  $\mathbf{x}_i^{n-1}$ . A  $n^{\text{th}}$  ordem de aproximação para  $H(P)$  [19] é:

$$F_n(P) = -\sum_{i=1}^{M^n} \sum_{j=1}^M P(\mathbf{x}_i^{n-1}, a_j) \log_2 P(a_j | \mathbf{x}_i^{n-1}) \text{ bits/símbolo} \quad (6)$$

$F_n(P)$  diminui monotonicamente com  $n$  [Shannon, C. E., 1948] e entropia da fonte é:

$$H(P) = \lim_{n \rightarrow \infty} F_n(P) \text{ bits/símbolo} \quad (7)$$

A equação 7 envolve a estimativa das probabilidades condicionais em uma seqüência infinita de símbolos anteriores. Em muitos casos práticos, memória finita pode ser assumida, e as fontes são modeladas por um processo de Markov de ordem  $k$ . Se a ordem de Markov é  $n-1$ ,  $P(a_j | \dots x_{-1} x_0 x_1 \dots x_{n-1}) = P(a_j | x_1 \dots x_{n-1})$ , e  $H(P) = F_n(P)$ . O conceito de entropia como uma medida de informações é crucial para a Teoria da Informação [Welch, 1984], e a compressão de dados provê uma perspectiva concreta ao conceito. Define-se a taxa de compressão de um sistema de codificação como a média do número de bits por símbolo que o sistema usa para codificar a saída de uma fonte. Um *compressor sem perdas* é um esquema de codificação unicamente decodificável cuja meta é atingir a menor taxa de compressão possível. A taxa de compressão de qualquer esquema de codificação unicamente decodificável é sempre maior ou igual à entropia da fonte [Welch, 1984]. Esquemas de codificação ótimos têm uma taxa de compressão igual à taxa teórica mais baixa vinculada  $H(P)$ , conseguindo, assim, a máxima compressão. Para a  $(n-1)$ -ordem do processo de Markov, a codificação ótima é alcançada se, e somente se, um símbolo  $x_n = a_j$  ocorrido após  $\mathbf{x}_i^{n-1}$  é codificado com  $-\log_2 P(a_j | \mathbf{x}_i^{n-1})$  bits [Bell, Cleary, e Witten, 1984] [Shannon, C. E., 1948]. No entanto, pode ser impossível estimar com precisão a distribuição condicional  $P(\cdot | \mathbf{x}_i^{n-1})$  para grandes valores de  $n$ , devido ao crescimento exponencial do número de contextos diferentes, o que traz problemas bem conhecidos, tais como a diluição de contexto [Bell, Cleary, e Witten, 1984].

## 2.4 O Compressor de dados PPM

Apesar de a fonte  $P$  do modelo ser, geralmente, desconhecida, é possível construir um sistema de codificação com base em algum modelo probabilístico, implícito ou explícito,  $Q$  que se aproxima de  $P$ . Quanto mais  $Q$  se aproxima de  $P$ , menor é a taxa de compressão alcançada pelo esquema de codificação. A fim de alcançar baixas taxas de compressão, modernos compressores sem perdas contam com a construção de modelos sofisticados que seguem de perto o modelo real da fonte. *Compressores estatísticos* codificam mensagens de acordo com um modelo estatístico estimado da fonte.

O algoritmo *Prediction by Partial Matching* (PPM) [Bell, Cleary, e Witten, 1984] é considerado estado-da-arte no que diz respeito à compressão de dados sem perdas. Embora o algoritmo PPM seja exigente quanto a recursos computacionais, Moffat [Moffat, A., 1990] apresentou uma variação deste algoritmo, chamado de PPM-C, cuja implementação apresentou bom desempenho e permitiu o uso comercial do PPM.

O algoritmo PPM-C é baseado na modelagem e previsão de contexto. O método começa com um modelo completamente desconhecido, assumindo variáveis equiprováveis e independentes, e, adaptativamente, o modelo é atualizado à medida que os símbolos vão sendo codificados. Baseado em toda a seqüência de símbolos já codificados, o modelo calcula as distribuições de probabilidade para o próximo símbolo, condicionados à seqüência de  $k$  símbolos anteriores do fluxo de entrada. O número de símbolos no contexto,  $k$ , determina a ordem do modelo.

O próximo símbolo,  $x$ , é codificado por codificação aritmética [Bell, Cleary, e Witten, 1984], com a probabilidade de  $x$  condicionada ao seu contexto atual. Se  $x$  não tinha ocorrido anteriormente no atual contexto, não há previsão para a sua probabilidade. Neste caso, um símbolo especial (um *escape*) é codificado, e o PPM-C tenta codificar  $x$  em um contexto reduzido contendo  $k-1$  símbolos anteriores. Este processo é repetido até que seja encontrada uma correspondência, ou o símbolo é codificado utilizando o modelo de equiprobabilidade. Experiências mostram que o desempenho da compressão do PPM aumenta à medida que o tamanho máximo do contexto aumenta até certo ponto, após o qual o desempenho começa a cair. Esse comportamento pode ser explicado pelo fenômeno da diluição de contexto e pelo aumento de ocorrências dos símbolos de escape. O tamanho ótimo do contexto depende da mensagem a ser comprimida, mas geralmente os valores típicos situam-se no intervalo de 4 a 6.

A Tabela 2 contem os pixels de uma imagem de tamanho 3 x 3. Na tabela 3 está o modelo obtido após aplicação do algoritmo PPM, com contexto máximo  $k = 2$ .

**Tabela 2 – Pixels de uma imagem de tamanho 3 x 3.**

0	3	4
3	4	0
3	1	2

**Tabela 3 – Construção do modelo PPM para os pixels da Tabela 2.**

	Contexto $k = 2$	Contexto $k = 1$	Contexto $k = 0$

Símbolo Atual	Contexto	Símbolo	C	P	Contexto	Símbolo	C	P	Símbolo	C	P
0									<b>0</b>	<b>1</b>	<b>1/9</b>
3					<b>0</b>	<b>3</b>	<b>1</b>	<b>1/2</b>	0	1	1/9
						<b>esc</b>	<b>1</b>	<b>1/2</b>	<b>3</b>	<b>1</b>	<b>1/9</b>
4	<b>0 3</b>	<b>4</b>	<b>1</b>	<b>1/2</b>	0	3	1	1/2	0	1	1/9
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>1</b>	<b>1/2</b>	3	1	1/9
					<b>3</b>	<b>4</b>	<b>1</b>	<b>1/2</b>	<b>4</b>	<b>1</b>	<b>1/9</b>
						<b>esc</b>	<b>1</b>	<b>1/2</b>			
3	0 3	4	1	1/2	0	3	1	1/2	0	1	1/9
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>1</b>	<b>1/2</b>	<b>3</b>	<b>2</b>	<b>2/9</b>
	<b>3 4</b>	<b>3</b>	<b>1</b>	<b>1/2</b>	3	4	1	1/2	4	1	1/9
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>1</b>	<b>1/2</b>			
					<b>4</b>	<b>3</b>	<b>1</b>	<b>1/2</b>			
						<b>esc</b>	<b>1</b>	<b>1/2</b>			
4	0 3	4	1	1/2	0	3	1	1/2	0	1	1/9
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>1</b>	<b>1/2</b>	3	2	2/9
	3 4	3	1	1/2	<b>3</b>	<b>4</b>	<b>2</b>	<b>2/3</b>	<b>4</b>	<b>2</b>	<b>2/9</b>
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>1</b>	<b>1/3</b>			
	<b>4 3</b>	<b>4</b>	<b>1</b>	<b>1/2</b>	4	3	1	1/2			
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>1</b>	<b>1/2</b>			
0	0 3	4	1	1/2	0	3	1	1/2	<b>0</b>	<b>2</b>	<b>2/9</b>
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>1</b>	<b>1/2</b>	3	2	2/9
	<b>3 4</b>	<b>3</b>	<b>1</b>	<b>1/4</b>	3	4	2	2/3	4	2	2/9
		<b>0</b>	<b>1</b>	<b>1/4</b>		<b>esc</b>	<b>1</b>	<b>1/3</b>			
		<b>esc</b>	<b>2</b>	<b>1/2</b>	<b>4</b>	<b>3</b>	<b>1</b>	<b>1/4</b>			
	4 3	4	1	1/2		<b>0</b>	<b>1</b>	<b>1/4</b>			
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>2</b>	<b>1/2</b>			
3	0 3	4	1	1/2	<b>0</b>	<b>3</b>	<b>2</b>	<b>2/3</b>	0	2	2/9
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>1</b>	<b>1/3</b>	<b>3</b>	<b>3</b>	<b>1/3</b>
	3 4	3	1	1/4	3	4	2	2/3	4	2	2/9
		0	1	1/4		<b>esc</b>	<b>1</b>	<b>1/3</b>			
		<b>esc</b>	<b>2</b>	<b>1/2</b>	4	3	1	1/4			
	4 3	4	1	1/2		0	1	1/4			
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>2</b>	<b>1/2</b>			
	<b>4 0</b>	<b>3</b>	<b>1</b>	<b>1/2</b>							
		<b>esc</b>	<b>1</b>	<b>1/2</b>							
1	<b>0 3</b>	<b>4</b>	<b>1</b>	<b>1/4</b>	0	3	2	2/3	0	2	2/9
		<b>1</b>	<b>1</b>	<b>1/4</b>		<b>esc</b>	<b>1</b>	<b>1/3</b>	3	3	1/3
		<b>esc</b>	<b>2</b>	<b>1/2</b>	<b>3</b>	<b>4</b>	<b>2</b>	<b>2/5</b>	4	2	2/9
	3 4	3	1	1/4		<b>1</b>	<b>1</b>	<b>1/5</b>	<b>1</b>	<b>1</b>	<b>1/9</b>
		0	1	1/4		<b>esc</b>	<b>2</b>	<b>2/5</b>			
		<b>esc</b>	<b>2</b>	<b>1/2</b>	4	3	1	1/4			
	4 3	4	1	1/2		0	1	1/4			
		<b>esc</b>	<b>1</b>	<b>1/2</b>		<b>esc</b>	<b>2</b>	<b>1/2</b>			
	4 0	3	1	1/2							

		esc	1	1/2							
2	0 3	4	1	1/4	0	3	2	2/3	0	2	2/9
		1	1	1/4		esc	1	1/3	3	3	1/3
		esc	2	1/2	3	4	2	2/5	4	2	2/9
	3 4	3	1	1/4		1	1	1/5	1	1	1/9
		0	1	1/4		esc	2	2/5	<b>2</b>	<b>1</b>	<b>1/9</b>
		esc	2	1/2	4	3	1	1/4			
	4 3	4	1	1/2		0	1	1/4			
		esc	1	1/2		esc	2	1/2			
	4 0	3	1	1/2	<b>1</b>	<b>2</b>	<b>1</b>	<b>1/2</b>			
		esc	1	1/2		<b>esc</b>	<b>1</b>	<b>1/2</b>			
	<b>3 1</b>	<b>2</b>	<b>1</b>	<b>1/2</b>							
		<b>esc</b>	<b>1</b>	<b>1/2</b>							

## 2.5 O Compressor de dados LZW

Em 1978, Jakob Ziv e Abraham Lempel definiram um esquema de codificação simples, capaz de explorar as dependências estatísticas entre os símbolos produzidos por uma fonte de informação. O algoritmo deu origem a uma grande família de compressores práticos, de bom desempenho e baixos requisitos computacionais, amplamente utilizados até hoje [Bell *et al*, 1990].

O algoritmo Lempel-Ziv-Welch (LZW) foi desenvolvido em 1984 por Terry Welch. Ele realiza a compressão sem perdas baseada em dicionário. É um algoritmo muito simples, cuja idéia é associar códigos à seqüência de símbolos.

Seja  $S$  uma fonte de informação que gera mensagens de um alfabeto finito  $A = \{a_1, a_2, \dots, a_M\}$ . Uma seqüência de símbolos selecionados de  $A$  é chamado de *frase* e um conjunto de frases é chamado de *dicionário*.

No LZW, inicialmente o dicionário é formado por todas as frases de tamanho um, ou seja, o dicionário é composto por todos os  $M$  símbolos do alfabeto. Seja  $\mathbf{x} = x_0x_1x_2\dots$  uma seqüência de símbolos a ser codificada, e  $f$  uma frase inicialmente vazia. Os símbolos de  $\mathbf{x}$  são

seqüencialmente concatenados a  $f$  até que a concatenação de um dado símbolo  $x_i$  produza uma frase que não se encontre no dicionário. A frase  $f$  é codificada com o índice que havia sido dado há frase anterior ao aparecimento de  $x_i$  e  $f$  é adicionada ao dicionário. A frase  $f$  volta a ser vazia e o processo se repete a partir do símbolo que interrompeu a coincidência,  $x_i$  [Bell *et al.* 1990].

O algoritmo é descrito abaixo em pseudo-código:

1. FRASE = recebe caracter da entrada
2. ENQUANTO ainda há caracteres na mensagem FAÇA
3.     CHARACTER = recebe caracter da entrada
4.     SE FRASE+CHARACTER está presente no dicionário ENTÃO
5.         FRASE = FRASE+CHARACTER
6.     SENÃO
7.         codifique a FRASE
8.         adicione FRASE+CHARACTER ao dicionário
9.     FRASE = CHARACTER
10.    FIM do SE
11. FIM do ENQUANTO
12. Apresente a codificação para a FRASE

## 2.6 Classificação e Segmentação de Texturas

Os métodos de classificação dividem-se, basicamente, em dois grupos:

**Classificação Não-Supervisionada:** os *pixels* são aglomerados em classes espectrais, sem que estas sejam especificadas com antecedência. É baseada em métodos que utilizam critérios de similaridade, e pode ser usada para determinar o numero e a localização das classes espectrais da imagem e para determinar a classe espectral de cada *pixel*. Após a classificação, o analista interpreta e rotula cada classe [Furtado, 2008].

**Classificação Supervisionada:** são fornecidas informações sobre a cena, que servem de treinamento para o classificador. Estas informações são chamadas de amostras de treinamento

e devem ser representativas das classes que deverão ser mapeadas [Richards, 1986; Mendonça, 2006].

Vários métodos vêm sendo propostos para resolver o problema da classificação e da segmentação de texturas de imagens digitais, incluindo redes neurais, aprendizagem por quantização vetorial (LVQ), máquinas de suporte vetorial (SVM) [Li, Kwok, Zhu, e Wang, 2003] e fuzzy SVM [Liu, L. e Wang, T., 2009], classificadores Bayesianos [Randen, T., Husøy, J. H., 1999], classificadores baseados em decomposição de valor singular (SVD) [Selvan e Ramakrishnan, 2007].

Modernos compressores de dados sem perda também têm sido usados para solucionar o problema de classificação e segmentação, devido a sua capacidade de construir modelos estatísticos precisos, em alguns casos com baixos requisitos computacionais [Bell *et al.*, 1990].

Métodos baseados em modelos construídos por algoritmos de compressão apresentam diversas vantagens potenciais sobre métodos clássicos de aprendizagem de máquina: já que não há seleção de características, nenhuma informação é descartada e, portanto, os modelos descrevem as classes como um todo [Teahan, Harper, 2001]; não há necessidade de se fazer suposições sobre as distribuições de probabilidade das classes de texturas; a capacidade de construção de modelos adaptativos dos algoritmos de compressão oferece uma maneira uniforme para classificar diferentes tipos de fontes [Teahan, Harper, 2001], a regra de classificação é muito simples [Bell, Cleary, Witten, 1984].

## **2.7 Sensoriamento Remoto**

O termo sensoriamento remoto significa a obtenção de informações sem o contato direto com o objeto de estudo. Trata-se de uma técnica que se iniciou com a utilização de fotografias da superfície da Terra, tomadas a partir de balões, para a elaboração de mapas, ainda no século XIX, pouco depois da invenção da fotografia. Posteriormente evoluiu com o uso de aviões e satélites.

Com o aparecimento do *scanner* e a possibilidade de digitalizar as fotografias aéreas, desenvolveu-se uma das tecnologias que mais rapidamente tem crescido no século XX e XXI, o Sensoriamento Remoto (SR), também chamado de Teledetecção [Jorge Raffo e Rúbia Gomes Morato]. A Figura 8 é um exemplo de uma imagem digital de SR.



**Figura 8 - Imagem Ikonos, PSM, resolução de 1 m. Região de Paulista e Olinda - PE. Imageada em 08 de janeiro de 2001 [Engesat].**

Especialistas em sensoriamento remoto fazem uso de informações de textura para interpretar a cobertura do solo, já que pixels isolados não fornecem muitas informações a respeito do conteúdo da imagem. [Daniela Faur, Inge Gavat, e Mihai Datcu, 2009].

O problema da segmentação de imagens de SR foi escolhido para estudo de caso devido a sua importância e enorme aplicabilidade, já que o SR permite a extração de informações fundamentais para o planejamento, a tomada de decisões e as pesquisas em outras áreas, como as mostradas abaixo [R. M. Moraes, 1999]:

- Meteorologia – em previsões do tempo, no mapeamento climático, etc.
- Geologia – procura de jazidas minerais, estudos de aproveitamento do solo, etc.
- Agricultura – previsão de safras, estudos de contaminação por pragas, etc.
- Militar – em espionagem, teleguiagem de mísseis, controle de tráfego aéreo e marítimo, etc.
- Indústria – inventário e projeções de recursos hídricos, pesca e salinas.
- Ecologia – pesquisas sobre o equilíbrio ecológico do planeta.
- Demografia – inventário e planejamento para controle do aumento demográfico, etc.

## 2.8 Resumo do Capítulo

O objetivo deste capítulo foi contextualizar o leitor a respeito do problema da classificação e segmentação de texturas, mostrando o que foi feito anteriormente na área.

Foram apresentados, também, os conceitos-chaves dessa dissertação: *imagem digital*, *equalização de histograma*, *entropia* e *modelos estatísticos* e como eles se aplicam ao *reconhecimento de padrões*, *PPM*, *LZW*, *classificação e segmentação de texturas* e *sensoriamento remoto*.

O próximo capítulo explica a metodologia usada no desenvolvimento do trabalho.

## **PROCEDIMENTOS METODOLÓGICOS**

Para fontes estacionárias, o algoritmo PPM aprende um modelo progressivamente melhor durante a codificação. Muitos resultados experimentais mostram que a superioridade do desempenho de compressão do PPM, em comparação com outros compressores ótimos, resulta, sobretudo, da sua capacidade de construir um modelo preciso para a fonte logo nas fases iniciais do processo de compressão. Em outras palavras, o PPM constrói (ou aprende) um modelo eficiente da mensagem a ser comprimida mais rápido que a maioria dos outros modernos algoritmos de compressão de dados. Por esta razão, o algoritmo PPM será utilizado no método de classificação, e conseqüentemente, no método de segmentação proposto.

Devido ao seu bom compromisso com a precisão do modelo e os requisitos computacionais exigidos [Augusteijn, Clemens e Shaw, 1995], o algoritmo PPM-C foi implementado e adaptado para realizar adequadamente as etapas exigidas para o treinamento, a classificação e a segmentação das imagens de texturas.

Os testes foram feitos em um computador com processador Pentium IV de 3.0 GHz, 1GB de Ram, 80GB de HD e sistema operacional Windows XP. A implementação foi feita na linguagem de programação Java versão 6.0, usando o ambiente de desenvolvimento integrado Eclipse.

### **3.1 A Classificação**

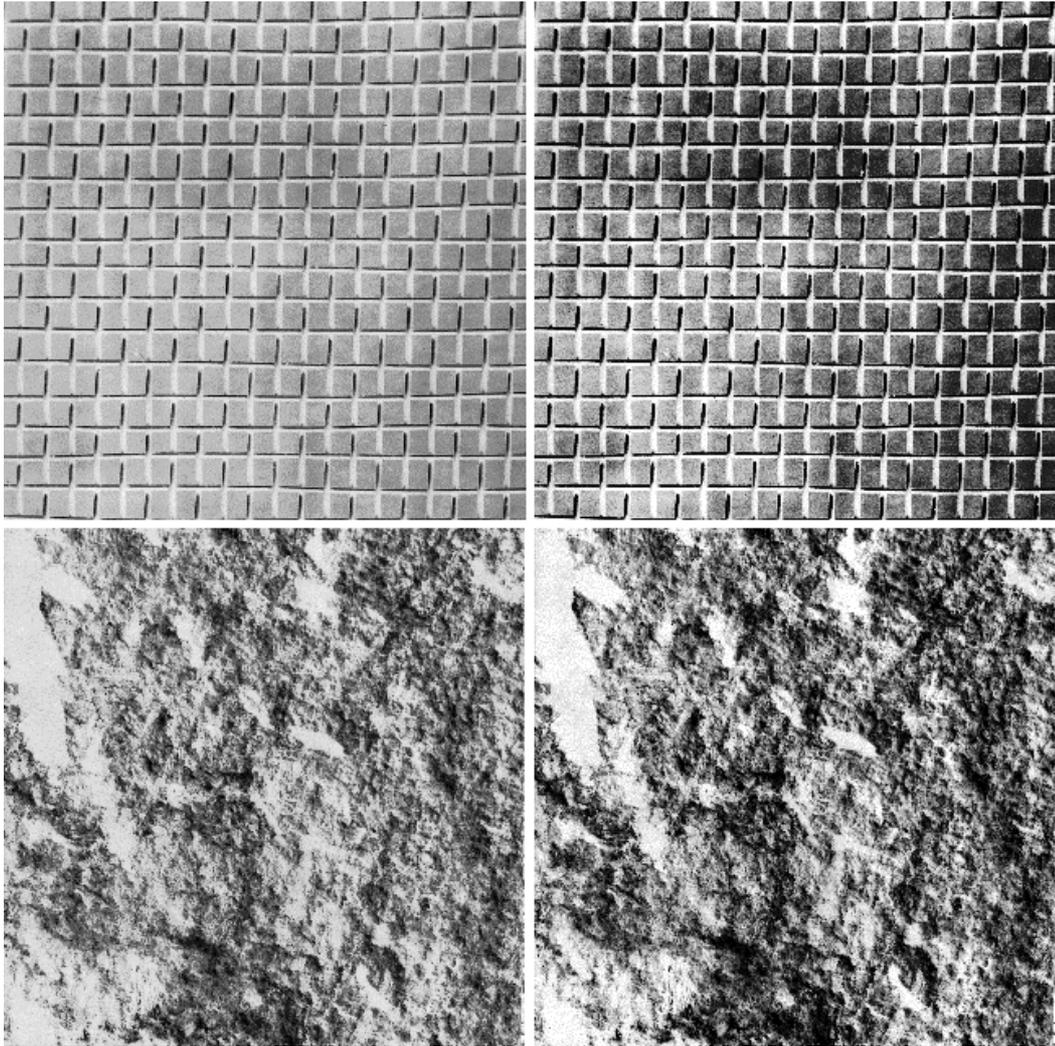
O álbum de Brodatz foi utilizado para avaliar o desempenho do método de classificação proposto. Nos experimentos, cada textura de Brodatz constitui uma classe distinta. As imagens de Brodatz usadas têm 640 x 640 pixels, com 8 bits / pixel.

Cada textura foi particionada em  $n \times n$  sub-imagens não sobrepostas, tidas como amostras de textura. As amostras foram separadas em dois conjuntos disjuntos, um para treinamento e o outro para testes do classificador. As amostras usadas na construção dos modelos na fase de aprendizagem foram tomadas a partir do primeiro quadrante da imagem. As amostras utilizadas na fase de classificação foram tomadas a partir do quarto quadrante. É importante notar que apenas com conjuntos disjuntos para treinamento e testes é possível chegar a resultados precisos. No entanto, como salientado por Randen e Husøy [Randen, T., Husøy, J. H, 1999] e por Li [Li *et al*, 2003], o uso de sobreposição de conjuntos é comum na literatura de classificação de texturas. Nestes casos, os resultados obtidos são otimistas e não são alcançáveis em situações reais.

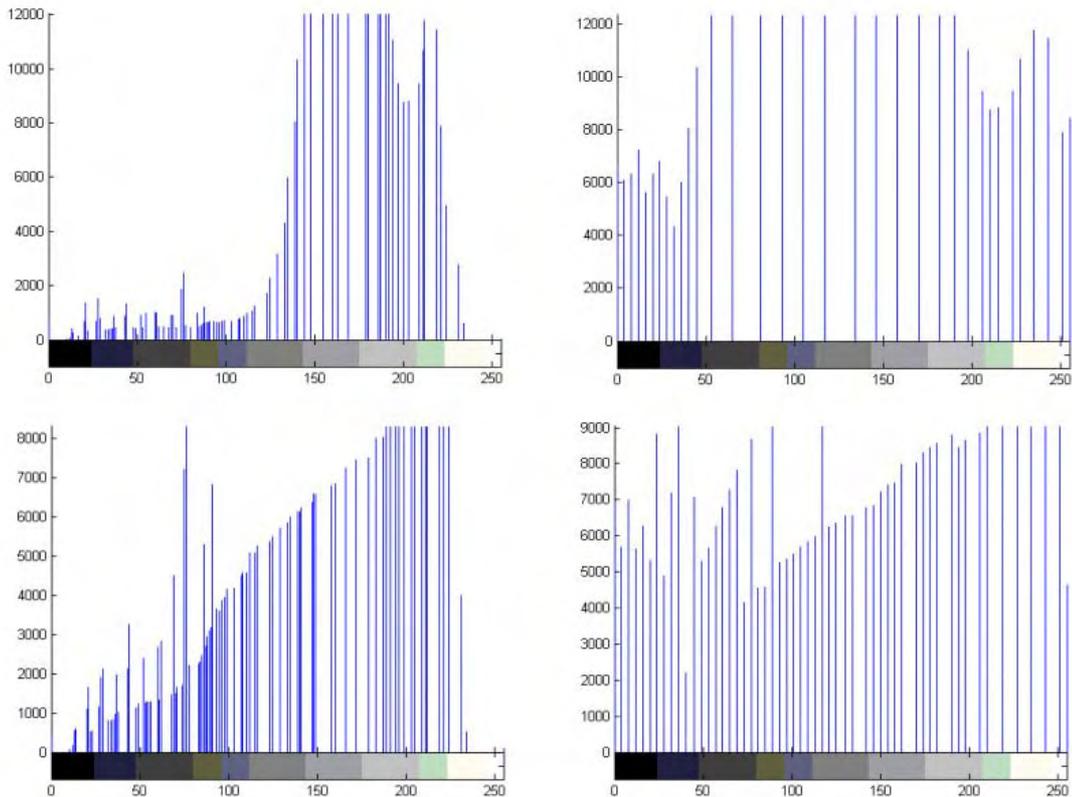
## 3.2 Pré-processamento

O modelo PPM gera os modelos para cada classe de textura a partir da intensidade luminosa de cada pixel. Os contextos de cada pixel são as intensidades luminosas dos pixels anteriores. Então, uma simples alteração na iluminação da textura pode causar problemas na classificação. A fim de obter uma distribuição uniforme das intensidades, foi aplicada a equalização de histograma a cada textura, antes da fase de aprendizagem para que o PPM captasse apenas as características da textura em si, ignorando a iluminação da imagem.

A Figura 9 mostra o efeito da equalização do histograma nas texturas D1 e D2 do álbum de Brodatz. A Figura 10 apresenta os respectivos histogramas das imagens mostradas na Figura 9.



**Figura 9 - Efeito da equalização de histograma nas texturas D1 (acima) e D2 (abaixo). O resultado da equalização de histograma está mostrado nas imagens à direita.**



**Figura 10 – Da Esquerda para direita, de cima para baixo: Histograma da textura D1, histograma equalizado de D1, histograma da textura D2, histograma equalizado de D2.**

### 3.3 Etapa de Aprendizagem

Na fase de treinamento, o número  $N$  de classes está definido, e um conjunto de treinamento  $T_i$  contendo amostras de textura pertencentes à classe  $C_i$ , é selecionado,  $i = 1, 2, \dots, N$ . As amostras são imagens  $n \times n$  extraídas de imagens com histograma equalizado.

**O algoritmo PPM comprime seqüencialmente as amostras em  $T_i$ , varrendo as amostras na ordem horizontal como mostrado na**

Figura 11 (a), e a tabela de probabilidades condicionais resultantes  $H_i$  é mantida como um modelo para a estrutura horizontal das texturas em  $C_i$ ,  $i = 1, 2, \dots, N$ .

**O algoritmo PPM então comprime as amostras em  $T_i$ , varrendo as amostras na ordem vertical como mostrado na**

Figura 11 (b), e a tabela de probabilidades condicionais resultantes  $V_i$  é mantida como um modelo para a estrutura vertical das texturas em  $C_i$ ,  $i = 1, 2, \dots, N$ .

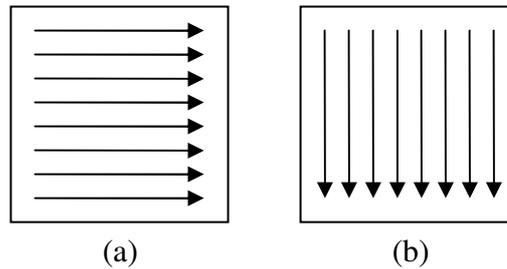


Figura 11 – Ordem de varredura das amostras. (a) horizontal, (b) vertical.

### 3.4 Etapa de Classificação

Na fase de classificação, o PPM opera no *modo estático*, o que não é permitido no algoritmo PPM-C utilizado para a compressão de dados. Neste modo, um dos modelos gerados na fase de treinamento é usado para comprimir amostras de texturas desconhecidas, sem que sejam feitas novas modificações no modelo durante o processo de codificação. Isso impede a adaptação dos modelos (e, conseqüentemente, a aprendizagem) para amostras desconhecidas durante a classificação.

A entropia condicional é usada para avaliar a qualidade dos modelos construídos durante o treinamento, e, portanto, para classificar amostras de classes desconhecidas. Dado um modelo vertical (ou horizontal) do PPM-C construído na fase de treinamento, a entropia condicional da estrutura vertical (ou horizontal) da amostra a ser classificada é estimada como a informação média, condicionada ao contexto, de cada pixel da amostra, de acordo com o modelo. Se símbolos de escape são emitidos durante a codificação de um determinado pixel, a informação condicional correspondente é acrescentada à informação condicional associada ao pixel.

Assim, a informação condicional  $g_i$  do símbolo  $x_i$  e a entropia condicional  $h_c$  para uma determinada mensagem são dadas por:

$$g_i = \log_2 \left( \frac{1}{P} (e_{i1} | c(e_{i1})) \right) + \log_2 \left( \frac{1}{P} (e_{i2} | c(e_{i2})) \right) + \dots + \log_2 \left( \frac{1}{P} (e_{in} | c(e_{in})) \right) + \log_2 \left( \frac{1}{P} (x_i | c(x_i)) \right) \quad (11)$$

e

$$h_c = \frac{g_1 + g_2 + \dots + g_L}{L} \quad (12)$$

onde  $e_{ij}$ , representa o  $j$ th símbolo de escape gerado durante a codificação do símbolo  $x_i$ ;  $c(x)$  representa o contexto para o símbolo  $x$ , e  $L$  é o número de símbolos na mensagem. No método proposto, uma mensagem é uma amostra de textura desconhecida.

**A classificação é realizada da seguinte forma. Uma amostra de textura com histograma equalizado  $x$  de uma classe desconhecida é codificada pelo algoritmo PPM com modelo estático  $H_i$ , na seqüência da varredura horizontal mostrada na**

**Figura 11 (a), e a entropia condicional correspondente  $h_i$  é gravada,  $i = 1, 2, \dots, N$ . Então, o algoritmo PPM codifica  $x$  com o modelo estático  $V_i$ , na seqüência da varredura vertical indicada na**

**Figura 11 (b), e a entropia condicional correspondente  $v_i$  é registrada,  $i = 1, 2, \dots, N$ .**

Seja,

$$r_i = \frac{h_i + v_i}{2} \quad (13)$$

A amostra  $x$  é atribuída a  $C_i$  se  $r_i < r_j$ ,  $j = 1, 2, \dots, N$ ,  $j \neq i$ . A idéia é que se  $x$  é uma amostra da classe  $C_i$ , as tabelas de contexto  $H_i$  e  $V_i$  contêm os modelos que melhor descrevem sua estrutura horizontal e vertical produzindo, assim, a menor entropia condicional.

Note que apenas cálculos de entropia, e não taxas de codificação reais, são necessários para a classificação. Assim, no classificador proposto implementado, o codificador aritmético é substituído por um estimador de entropia condicional mais simples e eficiente, o que reduz os requisitos computacionais e evita degradações na precisão da classificação causadas por eventuais deficiências na implementação da codificação aritmética.

### 3.5 A Segmentação

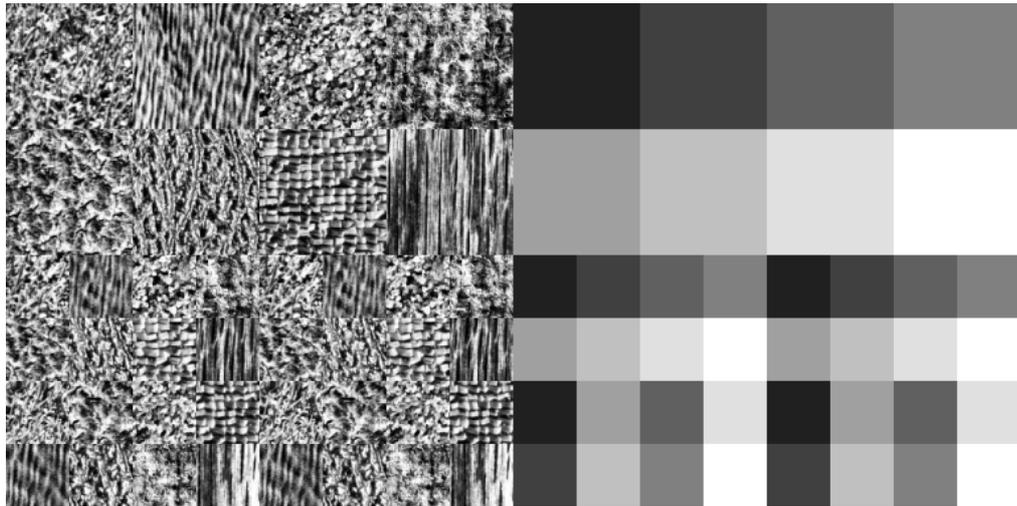
Os testes para segmentação foram feitos com as texturas de Brodatz do Instituto de Processamento de Sinais e Imagens da Universidade do Sul da Califórnia (USC-SIPI).

Para visualização dos mosaicos segmentados, as texturas foram diferenciadas usando os níveis de cinza mostrados na Tabela 2.

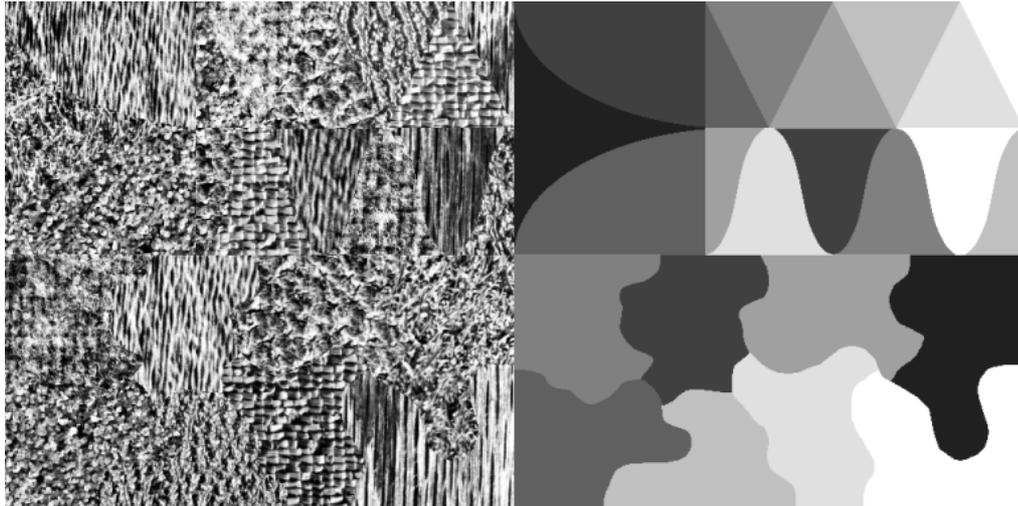
**Tabela 4 - Níveis de cinza usados para diferenciação das classes de texturas.**

<b>Textura</b>	<b>Nível de Cinza</b>
D9	32
D38	64
D29	96
D19	128
D92	160
D24	192
D84	224
D68	255

Os mosaicos de texturas usados na segmentação e seus mapas de texturas correspondentes em níveis de cinza estão mostrados na Figura 12 e na Figura 13.

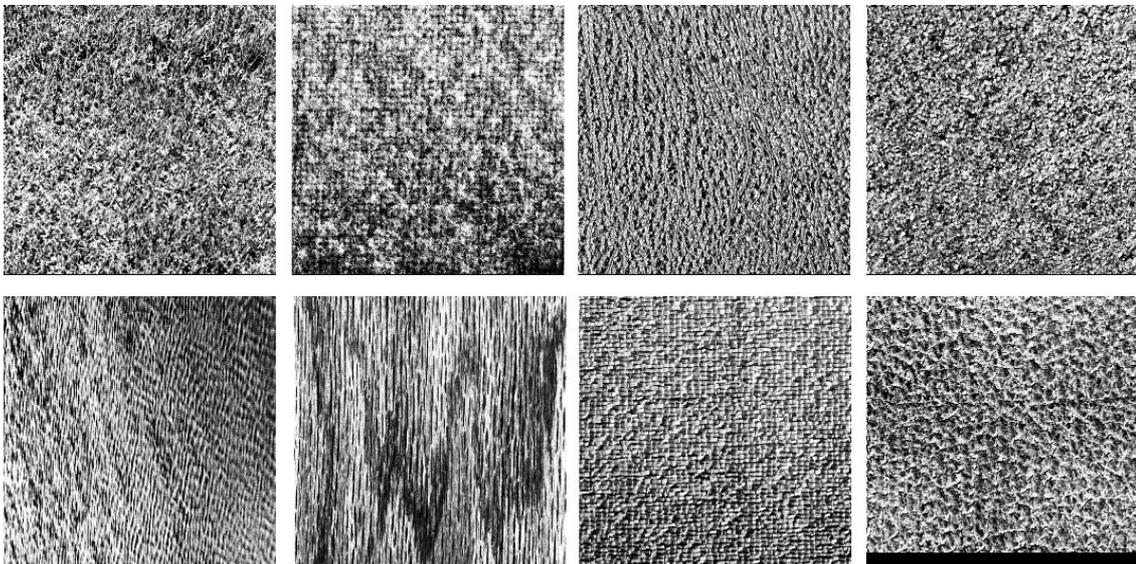


**Figura 12 - Mosaico 1 e seu mapa de texturas correspondente em níveis de cinza.**



**Figura 13 - Mosaico 2 e seu mapa de texturas correspondente em níveis de cinza.**

Foram construídos os modelos horizontais para as versões, já com histograma equalizado, de 13 classes de texturas de Brodatz disponibilizadas pelo USC-SIPI (D9, D12, D15, D15, D19, D24, D29, D38, D68, D84, D92, D94, D112). Das 13 classes, 8 foram usadas na construção dos mosaicos e estão mostradas na Figura 14. Os modelos foram criados usando 8 amostras de tamanho 32 x 32 de cada textura, com contexto PPM de tamanho 1.



**Figura 14 – Da esquerda para direita, de cima para baixo: D9, D19, D24, D29, D38, D68, D84, D92.**

Foram comprimidas amostras (64 x 64, 32 x 32, 16 x 16 e 8 x 8) de cada imagem, usando o seu modelo correspondente, e as razões de compressão máximas e mínimas obtidas foram guardadas para cada tamanho de amostra de cada imagem, ou seja, foram determinados intervalos de razões de compressão para cada classe. Define-se razão de compressão como

sendo a razão entre o tamanho, em bytes, do bloco original, e o tamanho do bloco após a compressão<sup>1</sup>.

No processo de segmentação, os mosaicos são percorridos em blocos de tamanho 64 x 64, e comprimidos pelos modelos das 13 classes. A razão de compressão do modelo que melhor comprimir a amostra é comparada com o intervalo de razões de compressão daquele modelo. Se a razão obtida estiver contida no intervalo esperado a amostra é classificada como sendo pertencente àquela classe. Caso contrário, entende-se que aquele bloco pode conter texturas diferentes e, por esse motivo, nenhum dos modelos foi tão eficiente. Neste caso, o bloco de tamanho 64 x 64 é dividido em quatro blocos de tamanho 32 x 32 e o processo se repete. Os blocos podem chegar ao tamanho mínimo de 4 x 4 pixels.

### 3.6 Sensoriamento Remoto

As técnicas de classificação e segmentação de texturas apresentadas neste trabalho são técnicas genéricas que podem ser aplicadas em qualquer área na qual se deseje extrair informações de imagens a partir da sua textura.

Como estudo de caso, as técnicas foram aplicadas a imagens de satélite. As imagens utilizadas são do Catálogo de Imagens do INPE (Instituto Nacional de Pesquisas Espaciais), instituição do Ministério da Ciência e Tecnologia brasileiro. As imagens foram captadas pelo satélite sino-brasileiro CBERS-2.

O projeto CBERS - *China Brazil Earth Resources Satellite* (Satélite Sino-Brasileiro de Recursos Terrestres) é resultado da cooperação técnica entre o Brasil e a China para a construção de satélites de SR de recursos terrestres. A implantação do projeto CBERS, no Brasil, ficou a cargo do INPE [INPE, 2007].

O satélite CBERS2, lançado em 21 de outubro de 2003 do Centro de Lançamento de Taiyuan, na China, é equipado com câmara para observações ópticas de todo o globo terrestre,

---

<sup>1</sup> Os intervalos de razões de compressão gerados e usados nos testes estão expostos no Apêndice A.

além de um sistema de coleta de dados ambientais. O satélite possui uma órbita síncrona com o Sol a uma altitude de 778 km, completando 14 revoluções da Terra por dia. Neste tipo de órbita o satélite cruza sempre a linha do Equador às 10h30min da manhã, hora local, provendo assim condições similares de iluminação solar e tornando possível a comparação de imagens adquiridas em dias diferentes [INPE, 2007].

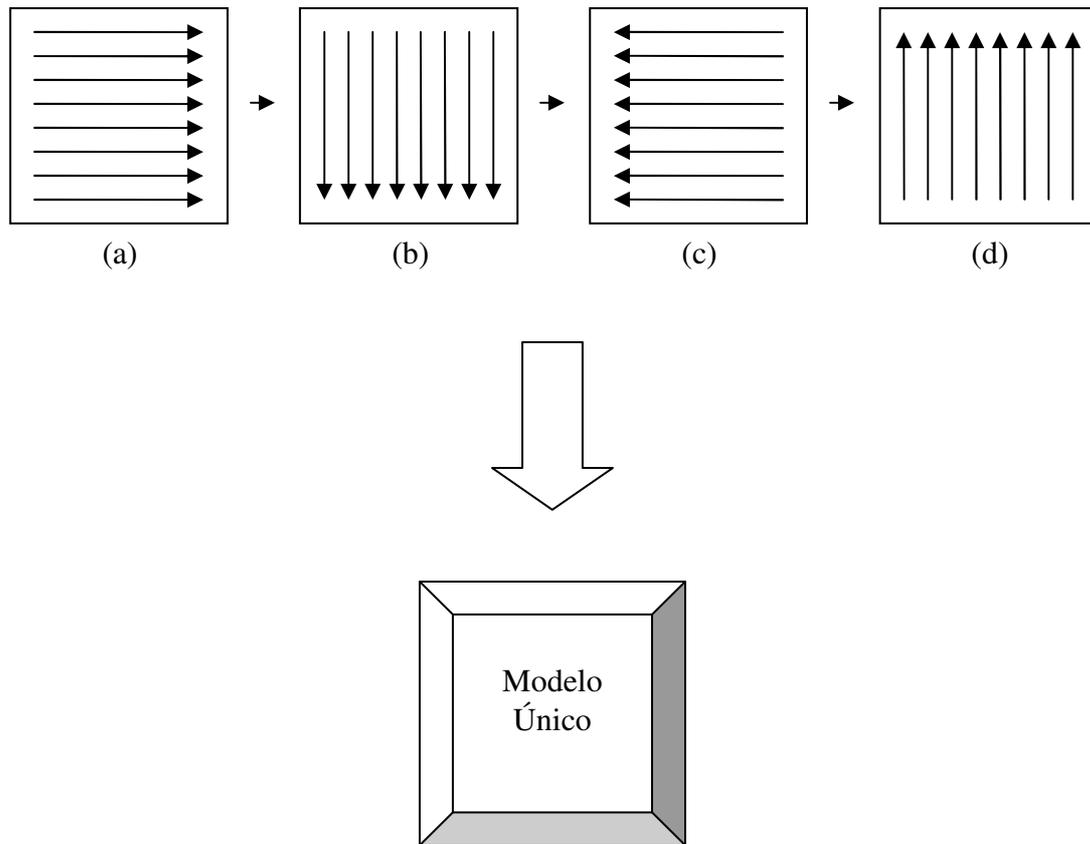
O satélite CBERS-2 é composto por dois módulos. O módulo "carga útil" acomoda os sistemas ópticos (CCD – Câmera Imageadora de Alta Resolução, IRMSS – Imageador por Varredura de Média Resolução e WFI – Câmera Imageadora de Amplo Campo de Visada) usadas para observação da Terra, e o Repetidor para o Sistema Brasileiro de Coleta de Dados Ambientais; e o módulo "serviço" que contém os equipamentos que asseguram o suprimento de energia, os controles, as telecomunicações e demais funções necessárias à operação do satélite.

As imagens utilizadas são da câmera CCD que opera em cinco faixas espectrais com resolução (pixel) de 20 m. Outras características da câmera estão na Figura 15.

Características da Câmera Imageadora de Alta Resolução CCD	
Bandas espectrais	0,51 - 0,73 $\mu\text{m}$ (pan)
	0,45 - 0,52 $\mu\text{m}$ (azul)
	0,52 - 0,59 $\mu\text{m}$ (verde)
	0,63 - 0,69 $\mu\text{m}$ (vermelho)
	0,77 - 0,89 $\mu\text{m}$ (infravermelho próximo)
Campo de Visada	8,3°
Resolução espacial	20 x 20 m
Largura da faixa imageada	113 km
Capacidade de apontamento do espelho	$\pm 32^\circ$
Resolução temporal	26 dias com visada vertical (3 dias com visada lateral)
Frequência da portadora de RF	8103 MHz e 8321 MHz
Taxa de dados da imagem	2 x 53 Mbit/s
Potência Efetiva Isotrópica Irradiada	43 dBm

**Figura 15 – Imagem do Manual do Usuário do Catálogo de Imagens da DGI/INPE com informações sobre a Câmera CCD.**

Para os testes com as imagens de SR, a forma de criação dos modelos foi modificada. Agora, no lugar de serem criados dois modelos (horizontal e vertical), a imagem foi varrida em quatro direções (da direita para a esquerda, da esquerda para a direita, de cima para baixo e de baixo para cima) e apenas um modelo foi criado para cada classe de textura. Esse processo está detalhado na Figura 16.



**Figura 16 - Ordem de varredura das amostras. (a) horizontal, (b) vertical.**

Foram usadas nos testes as imagens georreferenciadas das bandas CCD-1, CCD-2, CCD-3, CCD-4 e CCD-5<sup>2</sup> do satélite CBERS-2, Orbita/Ponto 146/108, de 19 de agosto de 2005 do município de João Pessoa. A composição colorida da imagem, utilizando as cinco bandas, está na Figura 17. As imagens foram obtidas no *site* do INPE.

O treinamento foi feito utilizando pequenas amostras da própria imagem classificada, o que não desqualifica os resultados obtidos, visto que a imagem possui 1308 x 1308 pixels e as amostras retiradas representam apenas uma pequena porcentagem da imagem. Além disso, o resultado da segmentação foi bem uniforme, ou seja, a segmentação foi feita em toda a imagem e não apenas nas áreas usadas para treinamento.

<sup>2</sup> As imagens correspondentes das cinco bandas estão no Apêndice B.



**Figura 17 - Composição colorida de cinco bandas de imagem do município de João Pessoa.**

Nessa imagem, foram definidas sete classes:

- **Área antropizada** – áreas de plantações ou regiões desmatadas, representadas nessa imagem pelo verde mais claro;
- **Água doce** – rios e lagos, representados pelo azul mais escuro;
- **Água do mar** – representado pelo azul mais claro à direita na imagem;
- **Mancha urbana** – regiões de construções e ruas do perímetro urbano;
- **Nuvem** – manchas brancas à esquerda na imagem;
- **Sombra** – sombras formadas pelas nuvens;
- **Vegetação** – áreas em verde escuro.

### **3.7 Resumo do Capítulo**

O objetivo do capítulo foi apresentar os materiais e a metodologia utilizada nas etapas de pré-processamento, treinamento, classificação e segmentação das texturas de Brodatz, além dos recursos computacionais utilizados na realização dos testes. Foi também mostrada a metodologia aplicada na segmentação da imagem de sensoriamento remoto.

No próximo capítulo serão apresentados os resultados dos testes.

## RESULTADOS

## 4.1 Classificação

Vários testes foram realizados, para avaliar o desempenho do classificador, variando o tamanho do contexto máximo, no caso do PPM ( $K = 1, 2$ ), o tamanho da amostra de textura ( $n \times n = 4 \times 4, 8 \times 8, 16 \times 16, 32 \times 32$ ) e o tamanho do conjunto de treinamento usado ( $M = 5, 10, 15, 20, 25, 30, 35, 40$ ).

A acurácia dos classificadores será avaliada pela *Taxa de Classificações Corretas* (TCC):

$$TCC = \frac{\text{Número de amostras classificadas corretamente}}{\text{Número de amostras classificadas}} \times 100\% \quad (14)$$

No primeiro experimento, 30 texturas foram selecionadas para comparação direta com vários outros classificadores de textura da literatura. As 30 texturas selecionadas foram: D1, D3, D6, D11, D16, D17, D20, D21, D24, D28, D29, D32, D34, D35, D46, D47, D49, D51, D52, D53, D55, D56, D57, D65, D78, D82, D84, D85, D101 e D104. Este corpus é o mesmo utilizada em [Li *et al*, 2003] e está na Figura 18.

Denomina-se o classificador proposto de CPPMHE, quando a equalização de histograma for usada, e de CPPM quando a equalização de histograma não for usada. O mesmo é válido para o LZW. CLZWHE é a versão implementada por Meira, usando equalização de histograma, enquanto que CLZW é a versão que não utiliza equalização de histograma.

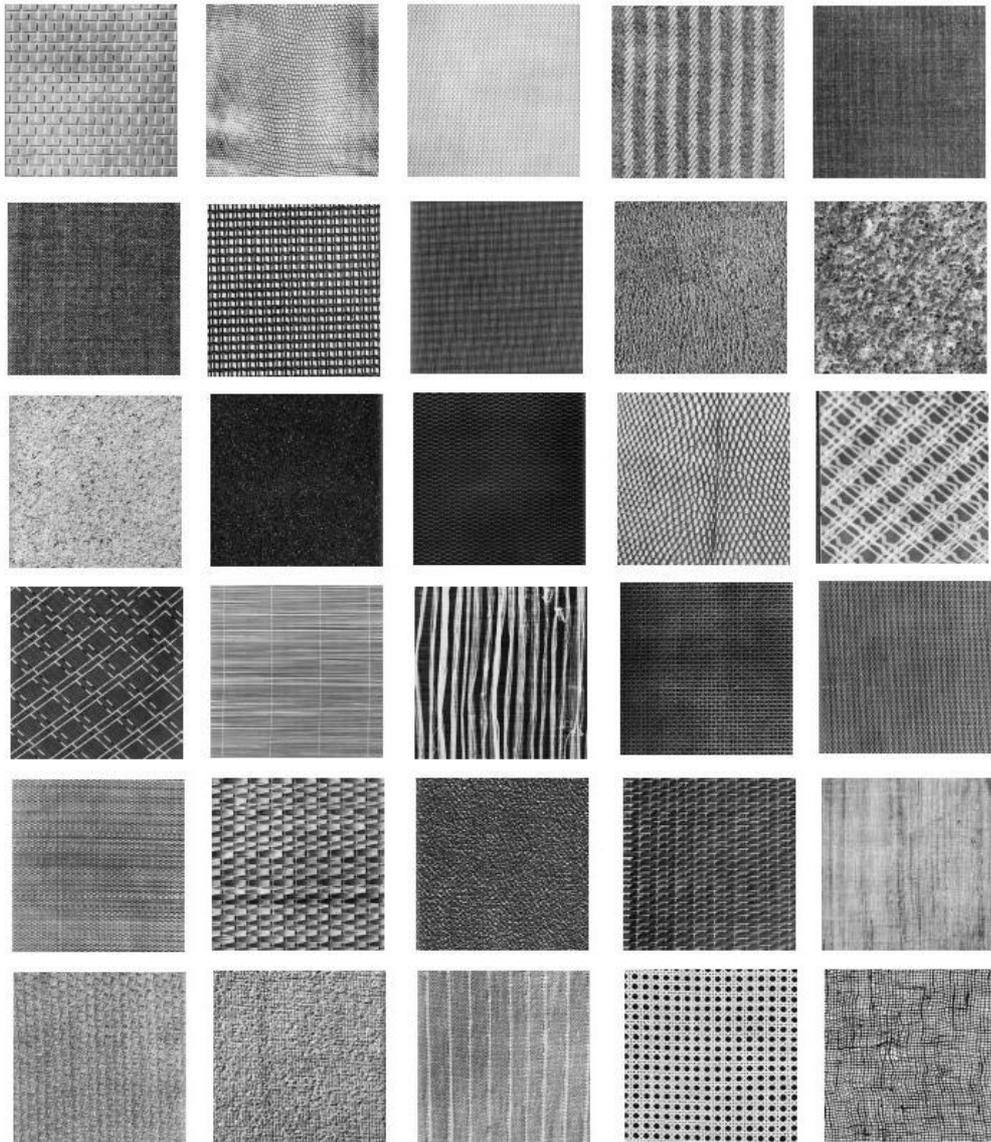


Figura 18 - Da esquerda para direita, de cima para baixo: D1, D3, D6, D11, D16, D17, D20, D21, D24, D28, D29, D32, D34, D35, D46, D47, D49, D51, D52, D53, D55, D56, D57, D65, D78, DD82, D84, D85, D101, D104.

## 4.2 Experimentos com 30 Texturas

As amostras utilizadas para a construção dos modelos na fase de aprendizagem foram retiradas dos três primeiros quadrantes das imagens de Brodatz e as primeiras cem amostras do quarto quadrante de cada imagem de textura foram selecionadas para a classificação.

O desempenho dos classificadores foi avaliado de duas maneiras diferentes com as 30 classes de texturas, como descrito no próximo parágrafo.

Primeiramente, o efeito do tamanho da amostra na TCC foi avaliado para  $n = 4, 8, 16,$

32, utilizando todas as amostras dos três primeiros quadrantes da imagem para o treinamento. Isto significa que, por exemplo, para  $n = 4$ , 19200 amostras de  $4 \times 4$  pixels foram utilizados para o treinamento.

A Tabela 3 mostra as TCC obtidas pelo classificador PPM, com equalização (CPPMHE) e sem equalização de histograma (CPPM), e com contexto máximo de tamanho 1.

**Tabela 5 – TCC obtidas com e sem equalização de histograma para PPM de contexto máximo  $K = 1$ .**

<b>Tamanho da Amostra</b>	<b>CPPM</b>	<b>CPPMHE</b>
4x4	72.40%	99.93%
8x8	96.90%	100%
16x16	99.73%	100%
32x32	99.80%	100%

A Tabela 4 apresenta os resultados gerados, para tamanho de contexto  $K = 1$  e  $K = 2$ , quando apenas a ordem de varredura horizontal foi usada nas etapas de treinamento e classificação.

**Tabela 6 – TCC obtidas pelo classificador proposto, com equalização de histograma, usando apenas a varredura horizontal.**

<b>Tamanho da Amostra</b>	<b><math>K = 1</math></b>	<b><math>K = 2</math></b>
4x4	99,7%	99,67%
8x8	99,83%	99,83%
16x16	99,83%	99,83%
32x32	99,83%	99,83%

No segundo experimento, o tamanho da amostra foi fixado em  $32 \times 32$ . O efeito do tamanho do conjunto de treinamento na precisão do classificador foi avaliado através da variação do número de amostras utilizadas na fase de aprendizagem ( $M = 5, 10, 15, 20, 25, 30, 35, 40$  amostras). A Tabela 5 compara os resultados do CPPMHE com os obtidos pelos classificadores Single SVM, Fused SVM, de Baye e LVQ [Li *et al.* 2003] e com CLZWHE. O tamanho do contexto usado pelo CPPMHE foi  $K = 1$ .

**Tabela 7 – Comparação entre o CPPMHE e outros métodos da literatura.**

Número de amostras de treinamento	TCC (%)					
	Bayes-Bayes	LVQ	Single SVM	Fused SVM	CLZWHE	CPPMHE
5	79.5	69.7	78.2	78.4	99.3	99.73
10	86.5	80.0	87.5	87.9	99.6	99.87
15	87.9	83.9	89.6	90.2	99.9	99.87
20	90.3	87.0	91.8	92.5	100	99.87
25	91.2	88.2	91.4	92.9	100	99.87
30	91.8	89.6	94.6	95.1	100	99.87
35	92.1	90.2	94.9	95.9	100	99.87
40	92.7	90.4	95.8	96.3	100	99.87

### 4.3 Testes com 112 Texturas

Nos testes utilizando o álbum completo de Brodatz, o tamanho da amostra foi fixado em 128 x 128 e as dezesseis primeiras amostras de cada imagem foram utilizados, variando o número de amostras utilizadas na fase de aprendizagem ( $M = 1, 2, 3, 4$ ) e usando as demais amostras para testes. A Figura 19 compara o classificador proposto, para  $K = 1$ , com a abordagem baseada na transformação *wavelet* e decomposição em valores singulares (SVD). Os resultados do método SVD são para dois níveis de decomposição *wavelet*.

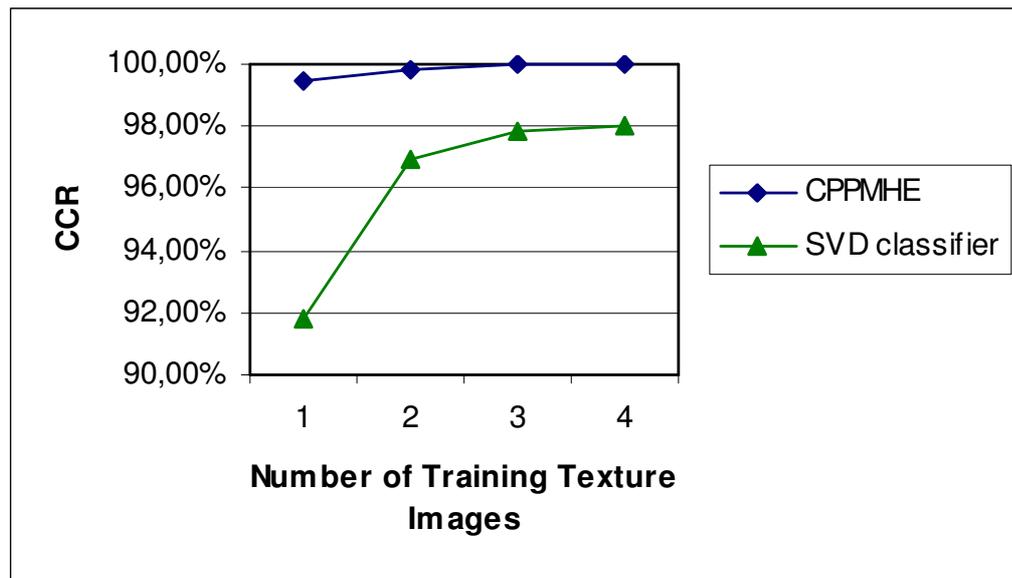


Figura 19 - Comparação entre o CPPMHE para  $K = 1$  com o classificador SVD.

## 4.4 Segmentação

O resultado obtido para a segmentação do mosaico 1 está mostrado na Figura 20.

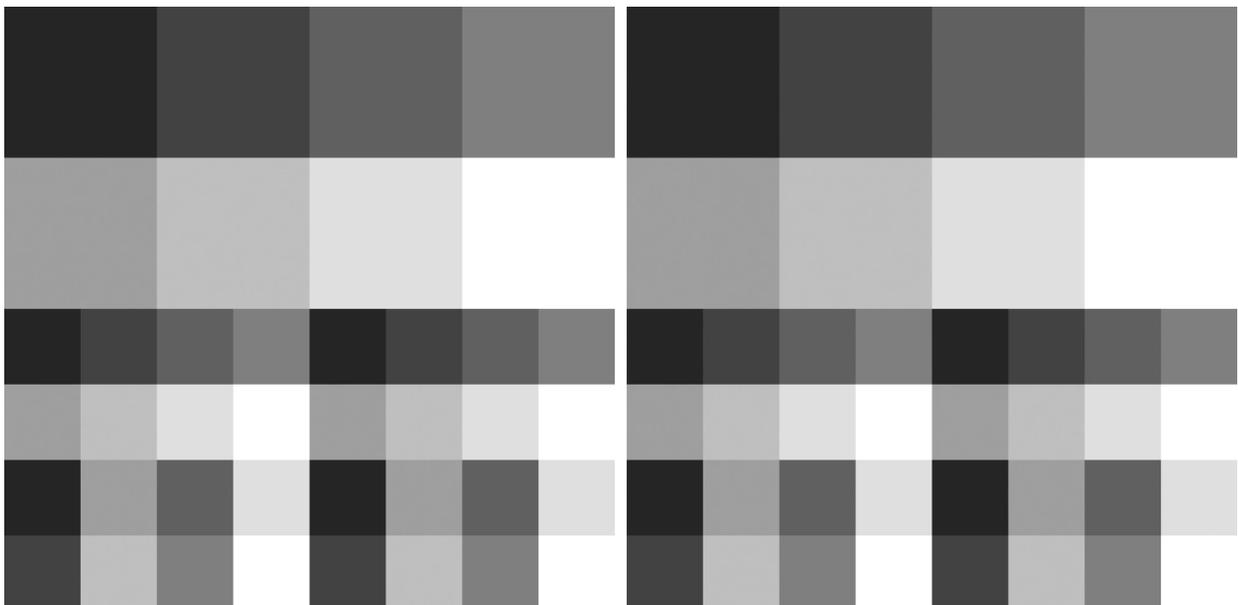


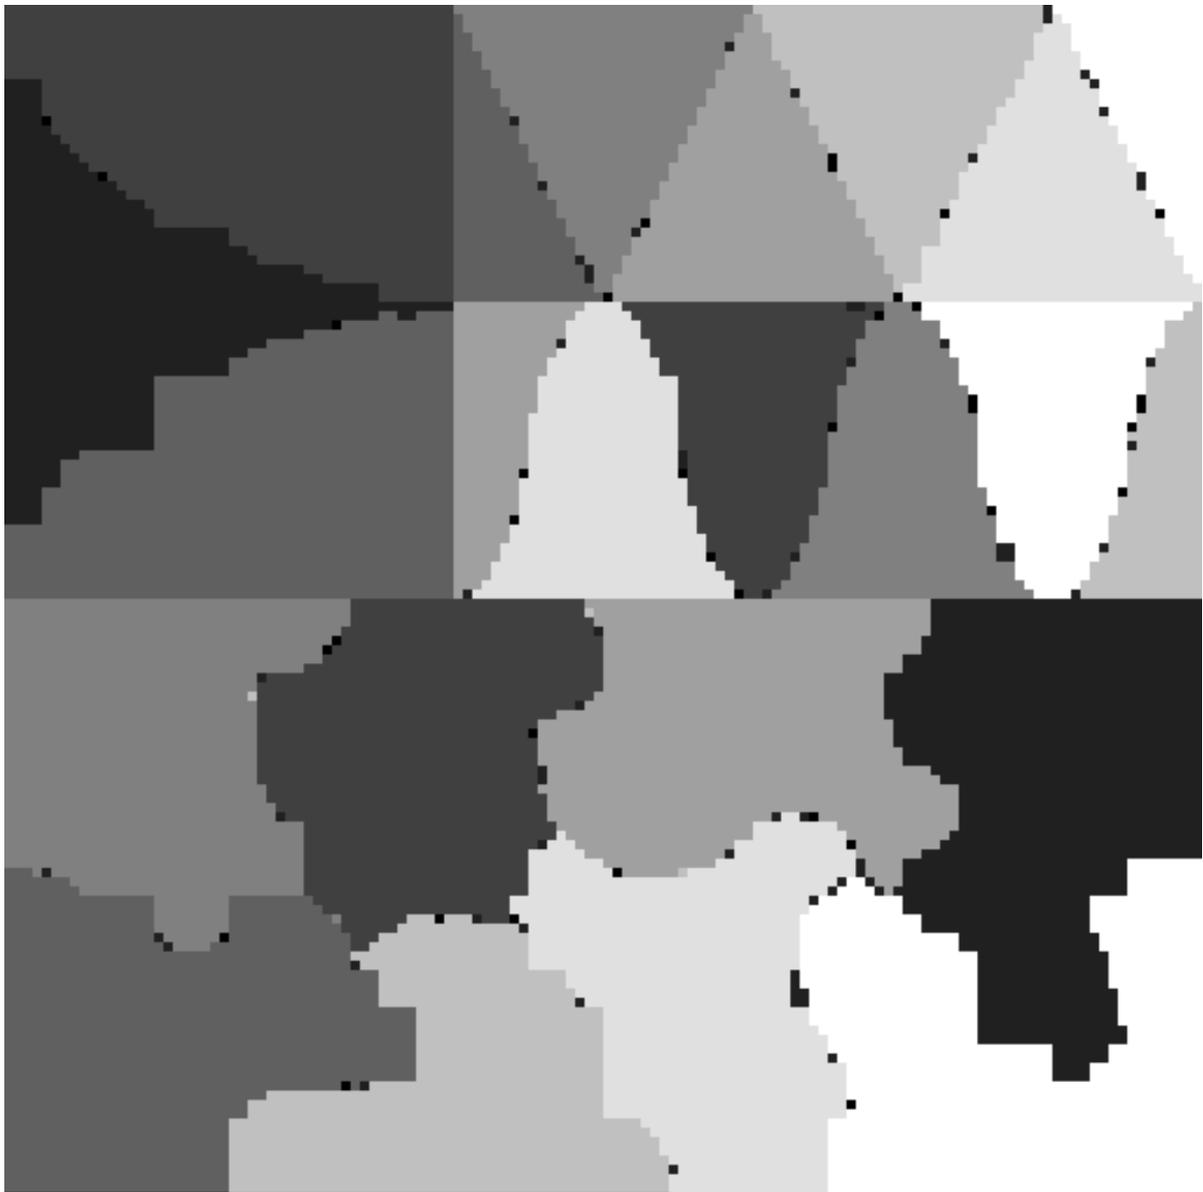
Figura 20 – À esquerda, mapa de níveis de cinza do mosaico 1. À direita, resultado da segmentação do mosaico 1.

Para o mosaico 2, pela sua maior dificuldade de segmentação, foram feitos três diferentes testes, variando os intervalos de razões de compressão utilizados.

No primeiro teste foram usados os intervalos que estão apresentados na Tabela 8 no Apêndice A. O resultado obtido está na Figura 21.

Então, o mesmo processo, descrito na seção 3.5, para encontrar um intervalo de razões de compressão foi repetido, descartando-se a maior e a menor razão de compressão obtida. A segmentação gerada com esses novos intervalos está na Figura 22 e os intervalos usados estão na Tabela 9 no Apêndice A.

A Figura 23 mostra a segmentação do mosaico quando as duas maiores e as duas menores razões de compressão foram descartadas na formação dos intervalos de razões de compressão. Os intervalos estão na Tabela 9 no Apêndice A.



**Figura 21 - Segmentação do mosaico 2 usando os intervalos de razão de compressão contidos na Tabela 5.**

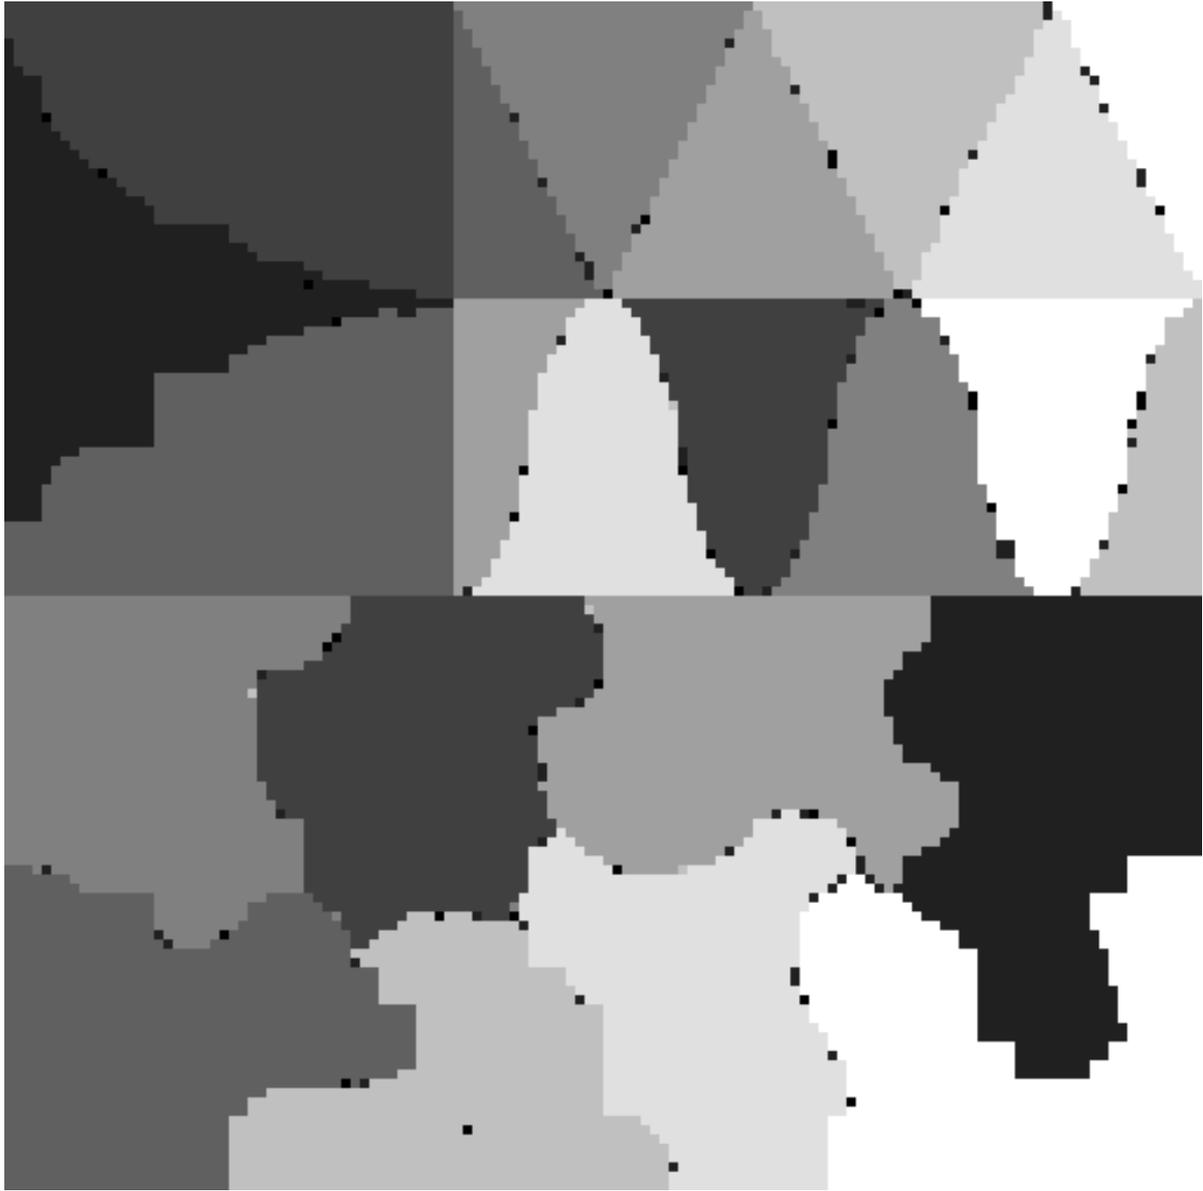
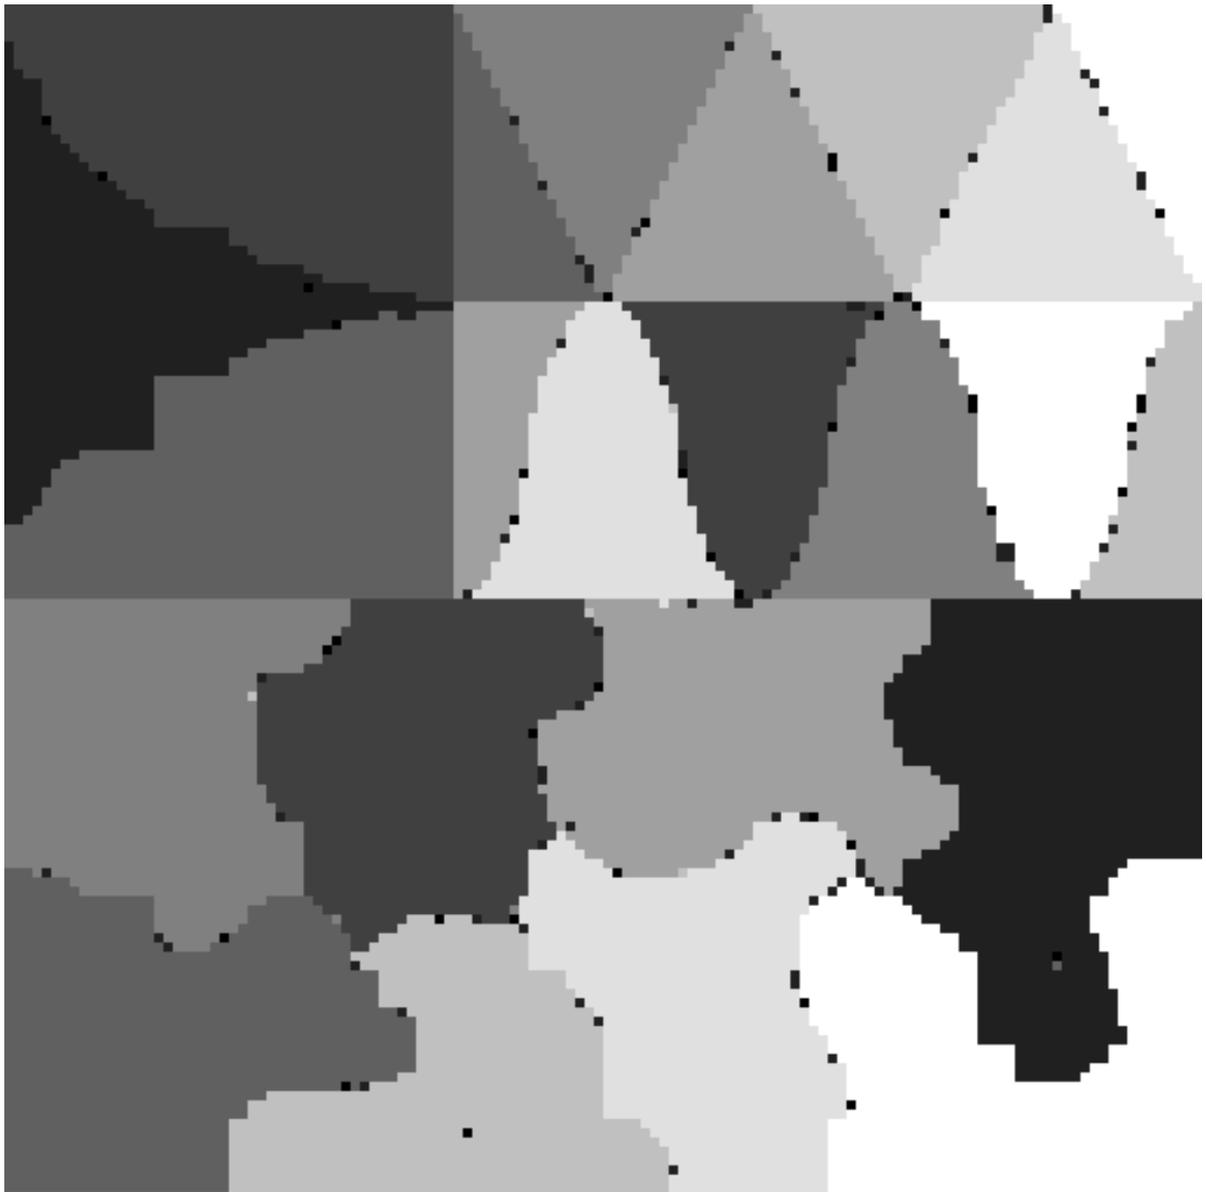


Figura 22 - Segmentação do mosaico 2 usando os intervalos de razão de compressão contidos na Tabela 6.



**Figura 23 - Segmentação do mosaico 2 usando os intervalos de razão de compressão contidos na Tabela 7.**

Para efeito de comparação, a Figura 24 mostra o resultado obtido por Blas et Al. [2008] na segmentação do mesmo mosaico, utilizando o método denominado SRI que faz um agrupamento de regiões similares utilizando o algoritmo *k-means*.

A Figura 25 contém o resultado da segmentação de um mosaico com quatro texturas de Brodatz. A segmentação foi feita utilizando o método baseado na Decomposição Bidimensional Empírica e Dimensão Fractal [Ling L., Ming L. e YuMing, L., 2009].

A Figura 26 mostra o resultado da segmentação de mosaicos de Brodatz usando Fuzzy SVM [Liu, L. e Wang, T., 2009].

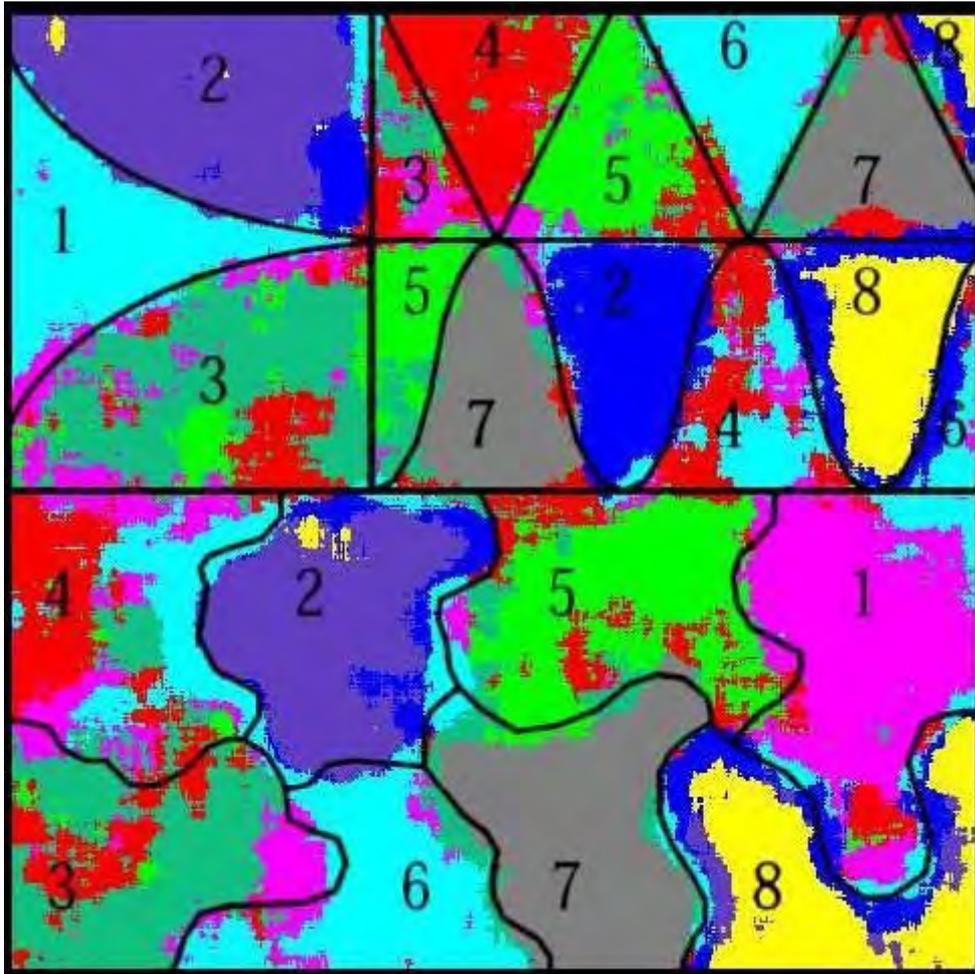


Figura 24 – Resultado da segmentação do mosaico da Figura 13 com o método SRI com vizinhança 5 x 5 e usando 64 vetores básicos.

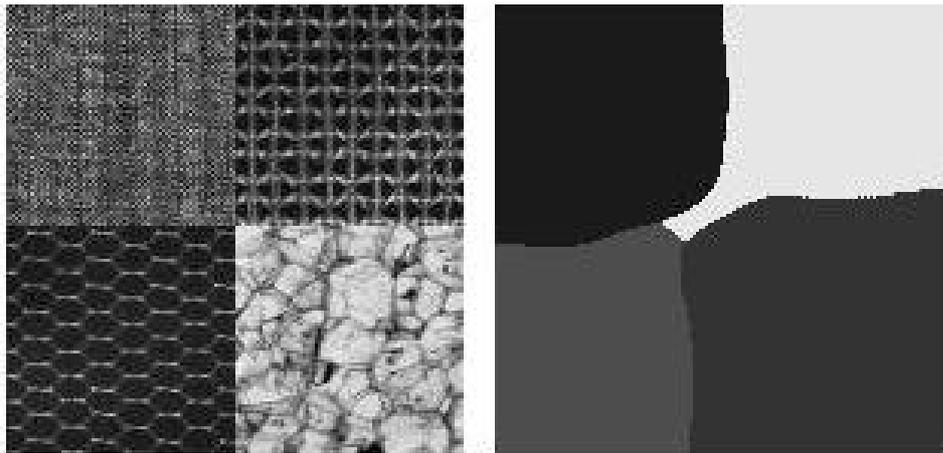


Figura 25 – Mosaico original (à esquerda) e o resultado da segmentação pelo método de Decomposição Bidimensional Empírica e Dimensão Fractal (à direita).

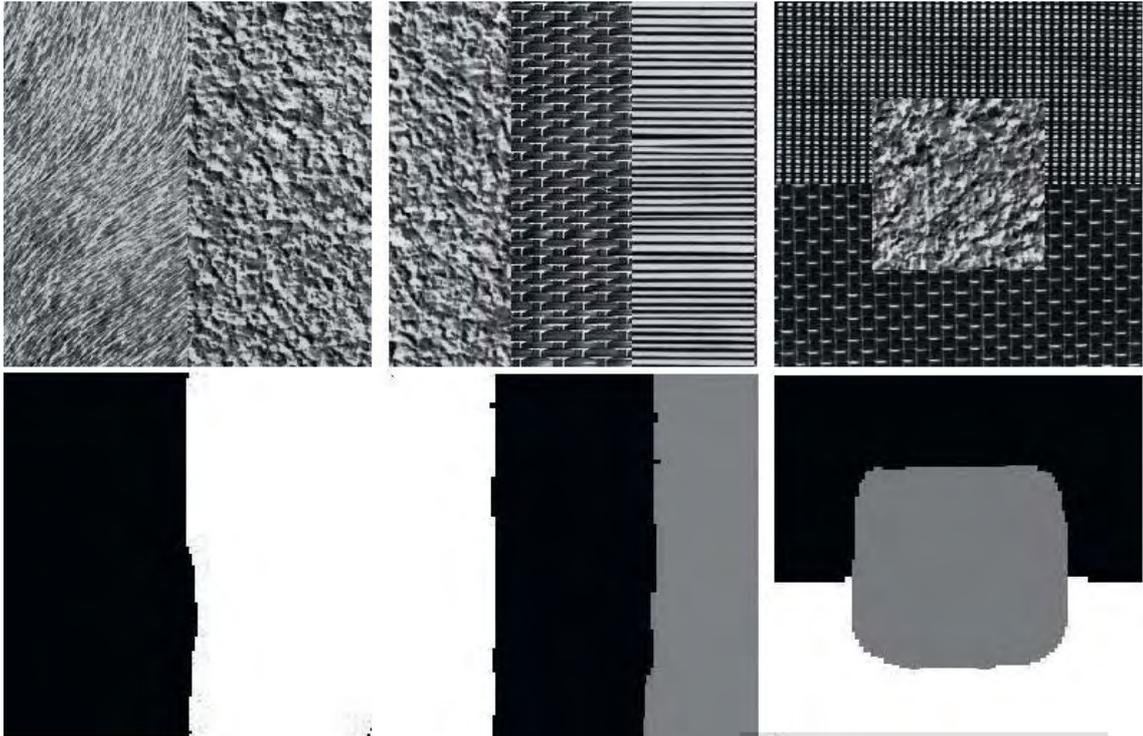


Figura 26 – Mosaicos originais (acima). Resultado da segmentação do método Fuzzy SVM (abaixo).

## 4.5 Testes com Dados de Sensoriamento Remoto

A imagem abaixo representa o resultado da segmentação da imagem mostrada na Figura 17. Foi utilizado o PPM-C com contexto máximo  $k = 1$  e não foi usada a equalização de histograma.

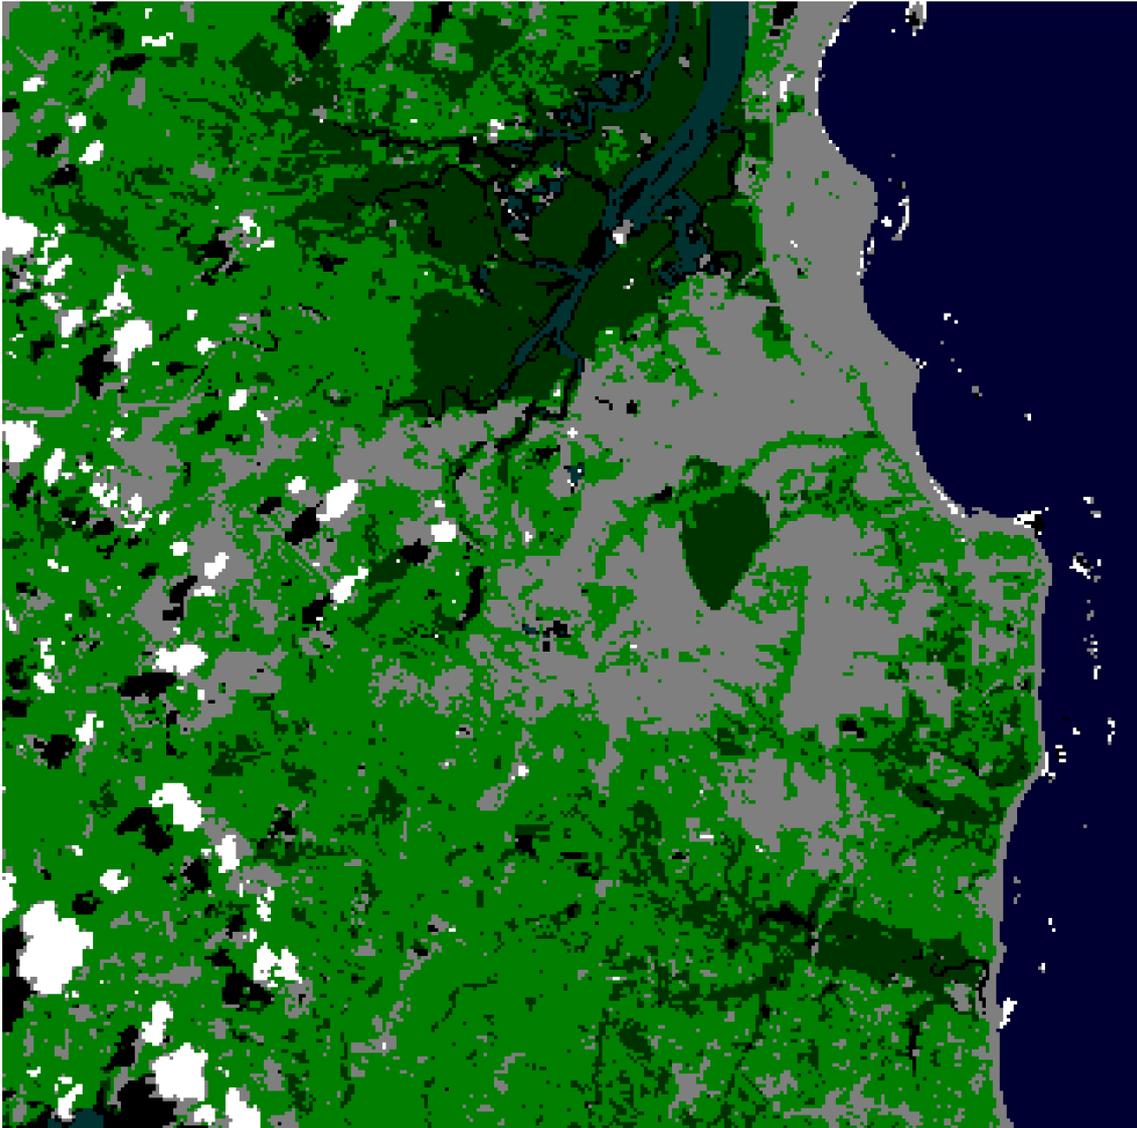
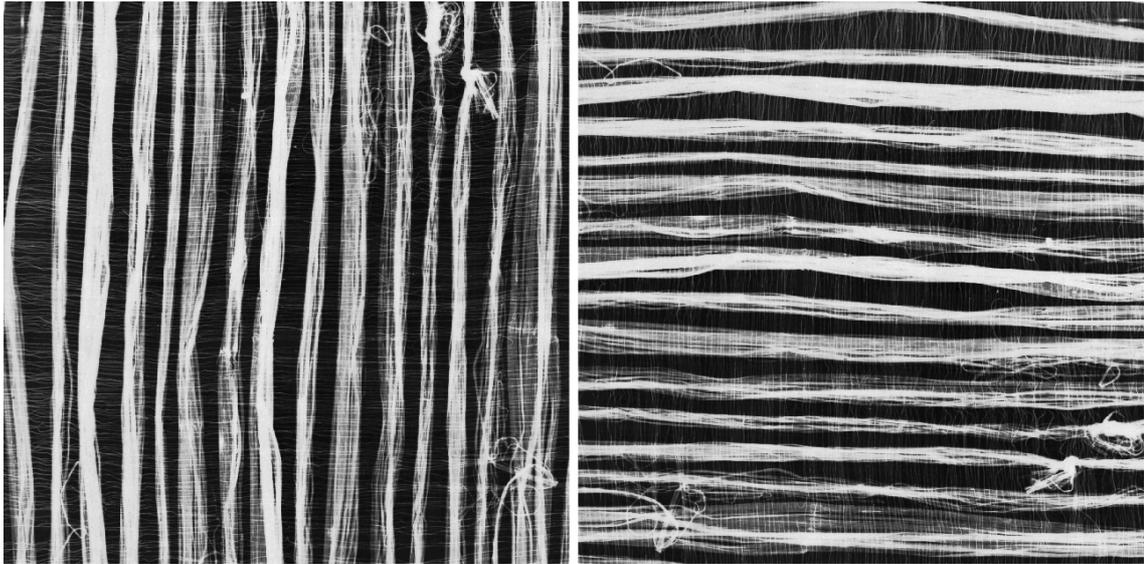


Figura 27 – Resultado da segmentação da imagem da Figura 17.

## 4.6 Testes Variando a Rotação

A criação de um modelo único, gerado a partir da varredura da imagem em quatro direções, como mostra o esquema da Figura 16, faz com que o método ainda consiga elevadas taxas de classificações corretas quando a imagem a ser classificada está rotacionada em  $90^\circ$ ,  $180^\circ$  e  $270^\circ$ .

A Figura 28 contém um exemplo de rotação em  $90^\circ$ .



**Figura 28 - Textura de Brodatz D51. A original, à esquerda, e a rotacionada em 90°, à direita.**

Foram classificadas 100 amostras das 30 classes de tamanho 32x32, pixels rotacionadas em 90°. Os modelos usados foram criados a partir das imagens originais, ou seja, sem rotação, usado 5 amostras de 32x32 pixels de cada classe.

O classificador atingiu 97.033% de classificações corretas usado contexto de tamanho máximo  $k = 1$  e sem a equalização de histograma.

## 4.7 Resumo do Capítulo

Esse capítulo apresentou as taxas de classificações corretas alcançadas pelo CPPM e CPPMHE, para várias combinações de tamanho de contexto máximo, número de amostras e tamanho das amostras, e os comparou com os resultados obtidos pelo CLZW e CLZWHE, além de outros classificadores da literatura.

Foram apresentados, também, o resultado da segmentação dos mosaicos de Brodatz e da imagem de sensoriamento remoto. Além da taxa de classificações corretas alcançadas pelo classificador, quando as imagens foram rotacionadas em 90°.

O próximo capítulo discute a respeito dos resultados obtidos e apresenta as conclusões tiradas deste trabalho.

**5****DISCUSSÃO E CONCLUSÕES**

Este trabalho propõe um esquema simples e de alta acurácia para a classificação e segmentação de texturas com base no algoritmo PPM e analisa os resultados em comparação com os obtidos pelo compressor LZW para que possam ser feitas considerações a respeito do desempenho dos algoritmos de compressão de dados quando aplicados ao problema da classificação e segmentação de texturas. A Tabela 3 mostra o efeito, para o PPM, do tamanho da amostra sobre a precisão da classificação quando um grande conjunto de treinamento está disponível. Pode ser visto que o classificador CPPMHE atingiu 100% de classificações corretas para amostras de tamanho 8 x 8. Para amostras de tamanho 4 x 4, das três mil amostras testadas apenas duas amostra não foram classificadas corretamente pelo CPPMHE. Com amostras 4 x 4, os erros são esperados, pois em muitos casos, a estrutura das texturas não é devidamente capturada por amostras de textura muito pequenas.

A Tabela 3 também evidência a importância da equalização de histograma para alcançar maiores taxas de classificações corretas. É possível concluir, a partir destes resultados, que CPPM precisa de um conjunto maior de treinamento, quando equalização de histograma não é usada, para alcançar taxas mais elevadas. Particularmente, a melhoria devida à equalização de histograma para amostras de tamanho 4 x 4 foi muito expressiva.

Os resultados apresentados na Tabela 4 indicam a importância da utilização de modelos para as estruturas horizontais e verticais da textura, já que quando apenas a ordem de varredura horizontal foi utilizada a TCC do CPPMHE não chegou a 100%. Por outro lado, os resultados obtidos sem os modelos verticais foram também competitivos, com metade da demanda computacional das versões com modelos verticais e horizontais.

Da Tabela 5, é possível avaliar o efeito do tamanho do conjunto de treinamento sobre a exatidão do método proposto. O CPPMHE alcançou TCC = 99,87%, com quatro erros apresentados. Também foi possível ver que outros estados da arte em classificadores necessitam de muito mais amostras de textura que o CLZWHE e o CPPMHE, para alcançar taxas de classificações corretas competitivas.

O compressor PPM foi muito eficiente na tarefa de classificação e, conseqüentemente, de segmentação das texturas de Brodatz. Ele foi capaz de aprender a estrutura da maioria das texturas utilizando pequenas amostras de cada textura para treinamento.

O CPPMHE foi marginalmente mais eficiente que o CLZWHE para os conjuntos menores de treinamento, com 5 e 10 amostras. Isto concorda com os resultados da literatura de compressão de dados, o que indica que o PPM aprende mais rapidamente do que o LZW. Para conjuntos maiores, o CLZWHE foi marginalmente superior.

Para os testes com o álbum completo de Brodatz, o gráfico da Figura 19 mostra a superioridade da CPPMHE sobre o classificador SVD, principalmente quando apenas uma amostra de 128 x 128 foi usada na fase de aprendizagem.

Os resultados obtidos pela segmentação foram muito satisfatórios já que os mosaicos 1 e 2 são compostos por texturas muito similares, sendo uma tarefa difícil, até mesmo para o olho humano, segmentá-los.

O mosaico 1, por não ter nenhuma fronteira irregular, não ofereceu dificuldades ao método proposto.

No mosaico 2, os pequenos blocos que não apresentaram os níveis de cinza corretos são resultados de classificações incorretas que, porém, não afetam a detecção da textura.

O ótimo desempenho do classificador foi fundamental para que a segmentação dos mosaicos fosse executada com sucesso. O fato de o classificador atingir altas taxas de classificações corretas para amostras de tamanho 4 x 4 permitiu a detecção das fronteiras com maior precisão, o que não é uma tarefa fácil, como pode ser visto nos resultados mostrados nas Figuras 24, 25 e 26.

Outro ponto chave para o bom desempenho da segmentação foi a definição dos intervalos de razões de compressão para cada tamanho de bloco de cada classe de textura. Os diferentes intervalos usados não apresentaram melhoras nem piores significativas em relação uns aos outros. Maiores investigações serão feitas a respeito da definição desses intervalos de

razões de compressão para alcançar uma melhor definição das fronteiras e menos erros de classificação durante o processo de segmentação.

Com os resultados apresentados na segmentação das imagens de sensoriamento remoto, ficou comprovada a aplicabilidade prática do método. Os resultados também mostraram que a construção de um único modelo contendo as várias estruturas (horizontais e verticais) da imagem pode ser um mais eficiente do que se ter diferentes modelos de diferentes estruturas. A construção de um único modelo tornou o método pouco variante a rotações retas, como mostraram os testes da seção 4.6.

## REFERÊNCIAS

- Augusteijn, M. F., Clemens, L. E., Shaw, K. A.: *Performance evaluation of texture measures for ground cover identification in satellite images by means of a neural network classifier*. IEEE Transactions on Geoscience and Remote Sensing, Vol. 33, Issue 3, 616-626, 1995.
- Baheerathan, S., Albregtsen, F., Danielsen, H. E.: *New Texture Features Based on the Complexity Curve*. Pattern Recognition, Vol. 32, Issue 4, 605-618, 1999.
- Balan, A. G. R., Traina, A. J. M., Traina Jr, C., Marques, P. M. A. *Integrando Textura e Forma para a Recuperação de Imagens por Conteúdo*. Anais do IX Congresso Brasileiro de Informática em Saúde, 2004.
- Banco de Texturas *VisTex*.
- Batista, L. V.: *Notas de aula da disciplina Processamento Digital de Imagens*, 2005.
- Bell, T., Cleary, J., Witten, I.: *Data compression using adaptive coding and partial string matching*. IEEE Transactions on Communications, v. 32, n. 4, pp. 396-402, 1984.
- Blas, M. R., Agrawal, M., Sundaresan, A. e Konolige, K.: *Fast Color/Texture Segmentation For Outdoor Robots*. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2008.
- Brodatz, P.: *Textures: A Photographic Album for Artists and Designers*. Dover, New York (1966).
- Carleer, A. P., Debeir, O. e Wolff, E.: *Assessment of very high spatial resolution satellite image segmentations*, Photogramm. Eng. Remote Sens., vol. 71, no. 11, pp. 1285–1294, 2005.
- Chevrefils, C., Cheriet, F., Aubin, C. e Grimard G.: *Texture Analysis for Automatic Segmentation of Intervertebral Disks of Scoliotic Spines from MR Images*. IEEE Transactions On Information Technology In Biomedicine, 2009.
- CMU NRT Database: <http://vivid.cse.psu.edu/texturedb/gallery/>
- Duda, R. O., Hart, P. E., Stork, D. G.: *Pattern Classification*. 2nd ed. Wiley Interscience, New York, 2000.
- Engesat Imagens De Satélites - <http://www.engesat.com.br/>
- Faur, D., Gavati, I., e Datcu, M., *Salient Remote Sensing Image Segmentation Based on Rate-Distortion Measure*, 2009.
- Frank, E., Chui, C., Witten, I. H.: *Text Categorization Using Compression Models*, Proc. DCC, Salt Lake City (2000), 555.
- Furtado, P. C. H.: *Análise Espacial E Classificação de Imagens Aplicadas ao Estudo do Dengue em Relação às Áreas de Vegetação na Cidade de João Pessoa – PB*, 2008.

Gonzalez & Woods: *Processamento Digital de Imagens*, 2002.

He, X., Hu, Y., Zhang, H., Li, M., Cheng, Q., Yan, S.: *Bayesian Shape Localization for Face Recognition Using Global and Local Textures*. IEEE Transactions on Circuits and Systems for Video Technology, Vol. 14, Issue 1 (2004) 102-113.

INPE – Instituto Nacional de Pesquisas Espaciais.

Jain, A. K., Ross, A., Prabhakar, S.: *An Introduction to Biometric Recognition*. IEEE Transactions on Circuits and Systems for Video Technology, Vol. 14, Issue 1 (2004) 4-20.

Karantzalos, K. G. e Argialas, D. P.: *Evaluation of selected edge detection techniques in remote sensing*, in Proc. SPIE—Image and Signal Processing for Remote Sensing VIII, S. B. Serpico, Ed., vol. 4885, pp. 102–110, 2003.

Kumar, A., Pang, G. K. H., *Defect Detection in Textured Materials Using Optimized Filters Systems*, IEEE Transactions on Man and Cybernetics, Part B, v. 32, n. 5, 553-570, 2002.

Li, S., Kwok, J. T., Zhu, H., Wang, Y.: *Texture Classification Using the Support Vector Machines*. Pattern Recognition, Vol. 36, Issue 12 2883-2893, 2003.

Ling, L., Ming, L. e YuMing, L.: *Texture Classification and Segmentation based on Bidimensional Empirical Mode Decomposition and Fractal Dimension*. IEEE First International Workshop on Education Technology and Computer Science, 2009.

Liu, L. e Wang, T.: *Algorithm of Texture Segmentation Combining FCM and FSVM*. IEEE Second International Conference on Intelligent Networks and Intelligent Systems, 2009.

Liu, X., Liu, J., Zhou, D. e Tang, J.: *A Benign And Malignant Mass Classification Algorithm Based on An Improved Level Set Segmentation and Texture Feature Analysis*. IEEE Bioinformatics and Biomedical Engineering, 2010.

Liu Y., Lin, W. *Deformable Texture: the Irregular-Regular-Irregular Cycle*. Proceedings of the 3rd International Workshop on Texture Analysis and Synthesis (Texture 2003), October, 2003, pp. 65 - 70.

Meira, M. M.: *Classificação de Texturas Usando o Algoritmo Lempel-Ziv-Welch*. Dissertação de Mestrado, 2008.

Mendonca, L. E. R.: *Utilizacao de algoritimo de classificacao em uma imagem ikonos para o mapeamento de feicoes terrestres: um estudo de caso*. Dissertação Magister Scientiae. Ciencia Florestal, Universidade Federal de Vicosa, 2006.

Moffat, A.: *Implementing the PPM data compression scheme*. IEEE Transactions on Communications, v. 38, n. 11, pp. 1917-1921, 1996.

Moraes, R. M.: *Sensoriamento Remoto e Classificação de Imagens*, 1999.

Nunes, E. O. e Conci, A.: *Segmentação por Textura e Localização do Contorno de Regiões em Imagens Multibandas*; Ieee Latin America Transactions, Vol. 5, No. 3, June 2007.

Porat, M., Zeevi, Y. Y.: *Localized Texture Processing in Vision: Analysis and Synthesis in the Gaborian Space*. IEEE Transactions on Biomedical Engineering, Vol. 36, Issue: 1 (1989) 115-129.

Raffo, J. e Morato, R. G.: *Revista Geografia*.

Randen, T., Husøy, J. H.: *Filtering for Texture Classification: a Comparative Study*. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol 21, Issue 4 (1999) 291-310.

Richards, A.: *Remote sensing digital image analysis: an introduction*. Berlin, Springer-Verlag, 1986.

Selvan, S., Ramakrishnan, S.: *SVD-Based Modeling for Image Texture Classification Using Wavelet Transformation*. IEEE Transactions on Image Processing, Vol. 16, Issue 11, 2688 – 2696, 2007.

Shannon, C. E.: *A Mathematical Theory of Communication*. Bell Syst. Tech. J., Vol. 27 379-423, 1948.

Southard, T. E., Southard, K. A.: *Detection of Simulated Osteoporosis in Maxillae Using Radiographic Texture Analysis*. IEEE Transactions on Biomedical Engineering, Vol. 43, Issue 2, (1996) 123-132.

Teahan, W. J., Harper, D. J.: *Using Compression Based Language Models for Text Categorization*. J. Callan, B. Croft and J. Lafferty (eds.): Workshop on Language Modeling and Information Retrieval, ARDA'2001, 83-88, 2001.

Welch, T. A.: *A Technique for High Performance Data Compression*, IEEE Computer, vol. 17, issue 6, pp. 8-19, 1984.

# APÊNDICES

# Apêndice A

Tabelas com os valores dos intervalos usados no processo de segmentação dos mosaicos com texturas de Brodatz.

**Tabela 8 - Razões de compressão máxima e mínima alcançadas quando amostras de diferentes tamanhos foram comprimidas pelos seus respectivos modelos.**

Imagem	Tamanho do Bloco	Intervalo
Grass (D9)	64x64	1.085209003215434 e 1.154751397469844
	32x32	1.157718120805369 e 1.2584134615384615
	16x16	1.3521739130434782 e 1.5674157303370786
	8x8	2.0161290322580645 e 3.081081081081081
Bark (D12)	64x64	1.1253041362530414 e 1.2439974042829332
	32x32	1.180622009569378 e 1.3639846743295019
	16x16	1.4090909090909092 e 1.8176795580110496
	8x8	2.0677966101694913 e 3.1818181818181817
Straw (D15)	64x64	1.0474162407722885 e 1.1524466750313676
	32x32	1.3521739130434782 e 1.5674157303370786
	16x16	1.416289592760181 e 1.683168316831683
	8x8	2.192982456140351 e 2.875
Herringbone weave (D15)	64x64	1.107750472589792 e 1.160077705767984
	32x32	1.2108585858585859 e 1.3160690571049136
	16x16	1.5365853658536586 e 1.8461538461538463
	8x8	2.339622641509434 e 3.1111111111111111
Woolen cloth (D19)	64x64	1.1158201229375606 e 1.1584158415841583
	32x32	1.2171717171717171 e 1.2978142076502732
	16x16	1.5263157894736843 e 1.761658031088083
	8x8	2.450980392156863 e 3.6875
Pressed calf leather (D24)	64x64	1.097634022162324 e 1.150625
	32x32	1.1848341232227488 e 1.2760290556900726
	16x16	1.485981308411215 e 1.6748768472906403
	8x8	2.2142857142857144 e 3.05
Beach sand (D29)	64x64	1.105263157894737 e 1.1643207855973814
	32x32	1.1776649746192893 e 1.3289124668435013
	16x16	1.4976076555023923 e 1.8222222222222222
	8x8	2.30188679245283 e 3.1818181818181817
Water (D38)	64x64	1.2955735364112329 e 1.4258645191852202
	32x32	1.3400735294117647 e 1.5630885122410547
	16x16	1.7241379310344827 e 2.255639097744361
	8x8	2.9047619047619047 e 4.516129032258065
Wood grain (D68)	64x64	1.414612281488122 e 1.6527638190954774
	32x32	1.4720893141945774 e 1.8382978723404255
	16x16	1.757396449704142 e 2.558139534883721
	8x8	2.5208333333333335 e 5.0
Raffia (D84)	64x64	1.107523510971787 e 1.1532152230971129
	32x32	1.1805728518057286 e 1.306684141546527
	16x16	1.5217391304347827 e 1.8181818181818181
	8x8	2.2142857142857144 e 3.238095238095238
Pigskin (D92)	64x64	1.1327433628318584 e 1.1810461956521738
	32x32	1.2588235294117647 e 1.3510928961748634
	16x16	1.642512077294686 e 1.8681318681318682

	8x8	2.413793103448276 e 3.4146341463414633
Brick wall (D94)	64x64	1.1661880832735103 e 1.2733551435841513
	32x32	1.1251646903820818 e 1.459090909090909
	16x16	1.4263157894736842 e 2.035928143712575
	8x8	2.1228070175438596 e 3.4358974358974357
Plastic bubbles (D112)	64x64	1.1510747805025734 e 1.2325273269294468
	32x32	1.2012422360248447 e 1.3461538461538463
	16x16	1.4325581395348836 e 2.115702479338843
	8x8	2.1403508771929824 e 6.5

**Tabela 9 - Intervalos de razões de compressão obtidas quando amostras de diferentes tamanhos foram comprimidas pelos seus respectivos modelos e as razões máxima e mínima alcançadas foram desprezadas.**

<b>Imagem</b>	<b>Tamanho do Bloco</b>	<b>Intervalo</b>
Grass (D9)	64x64	1.0864231948703653 e 1.1351429396477044
	32x32	1.1677704194260485 e 1.2479435957696827
	16x16	1.3624454148471616 e 1.5235849056603774
	8x8	2.0833333333333335 e 2.5925925925925926
Bark (D12)	64x64	1.1453879047037263 e 1.2114579980688767
	32x32	1.2129186602870814 e 1.3501896333754742
	16x16	1.4366197183098592 e 1.7525773195876289
	8x8	2.1403508771929824 e 3.1818181818181817
Straw (D15)	64x64	1.0617993676343778 e 1.134820867379007
	32x32	1.1312217194570136 e 1.2591715976331361
	16x16	1.4246575342465753 e 1.683168316831683
	8x8	2.1964285714285716 e 2.857142857142857
Herringbone weave (D15)	64x64	1.111531190926276 e 1.158393207054213
	32x32	1.2196969696969697 e 1.311023622047244
	16x16	1.553921568627451 e 1.8279569892473118
	8x8	2.3461538461538463 e 3.1111111111111111
Woolen cloth (D19)	64x64	1.1178208073514933 e 1.1571622539035982
	32x32	1.220505617977528 e 1.2965340179717586
	16x16	1.5414364640883977 e 1.761658031088083
	8x8	2.46 e 3.4
Pressed calf leather (D24)	64x64	1.0997603355302576 e 1.147531051196607
	32x32	1.1883194278903457 e 1.275609756097561
	16x16	1.4906542056074767 e 1.6666666666666667
	8x8	2.2142857142857144 e 2.978723404255319
Beach sand (D29)	64x64	1.1103938024531956 e 1.161056105610561
	32x32	1.2002567394094994 e 1.3194070080862534
	16x16	1.5566502463054188 e 1.8181818181818181
	8x8	2.3207547169811322 e 3.1111111111111111
Water (D38)	64x64	1.3361462728551337 e 1.4252601702932828
	32x32	1.3663551401869158 e 1.5606060606060606
	16x16	1.7291666666666667 e 2.1954887218045114
	8x8	2.9285714285714284 e 4.375
Wood grain (D68)	64x64	1.4591659426585577 e 1.6367476240760295
	32x32	1.4810344827586206 e 1.8359375
	16x16	1.8089171974522293 e 2.5483870967741935
	8x8	2.5208333333333335 e 4.827586206896552
Raffia (D84)	64x64	1.112671560804341 e 1.1518238580348341
	32x32	1.1964956195244054 e 1.3026666666666666
	16x16	1.5245098039215685 e 1.8172043010752688
	8x8	2.2777777777777777 e 3.1818181818181817
Pigskin (D92)	64x64	1.1341305753070459 e 1.1800753166723725
	32x32	1.2627450980392156 e 1.3351206434316354
	16x16	1.6923076923076923 e 1.8659217877094971

	8x8	2.456140350877193 e 3.255813953488372
Brick wall (D94)	64x64	1.1716115981119353 e 1.2428884026258207
	32x32	1.1385281385281385 e 1.4401772525849335
	16x16	1.4408602150537635 e 2.0118343195266273
	8x8	2.2181818181818183 e 3.4146341463414633
Plastic bubbles (D112)	64x64	1.162111801242236 e 1.1991566655854686
	32x32	1.2095959595959596 e 1.3459119496855345
	16x16	1.4575471698113207 e 1.8043478260869565
	8x8	2.1551724137931036 e 3.892857142857143

**Tabela 10 - Intervalos de razões de compressão obtidas quando amostras de diferentes tamanhos foram comprimidas pelos seus respectivos modelos e as duas maiores e as duas menores razões alcançadas foram desprezadas.**

Imagem	Tamanho do Bloco	Intervalo
Grass (D9)	64x64	1.1331795906601325 e 1.0864545198535625
	32x32	1.2429577464788732 e 1.1722222222222223
	16x16	1.5118483412322274 e 1.3755458515283843
	8x8	2.5531914893617023 e 2.0847457627118646
Bark (D12)	64x64	1.2096111286753082 e 1.1538461538461537
	32x32	1.3491048593350383 e 1.2178098676293623
	16x16	1.7435897435897436 e 1.4619047619047618
	8x8	3.1818181818181817 e 2.175438596491228
Straw (D15)	64x64	1.1195952161913523 e 1.071240105540897
	32x32	1.2512626262626263 e 1.1414027149321266
	16x16	1.6666666666666667 e 1.4311926605504588
	8x8	2.8 e 2.2142857142857144
Herringbone weave (D15)	64x64	1.1561181434599157 e 1.1137667304015297
	32x32	1.3070866141732282 e 1.220532319391635
	16x16	1.8085106382978724 e 1.5671641791044777
	8x8	3.1111111111111111 e 2.3653846153846154
Woolen cloth (D19)	64x64	1.1543026706231454 e 1.1228406909788868
	32x32	1.2947232947232947 e 1.2208121827411167
	16x16	1.7525773195876289 e 1.5517241379310345
	8x8	3.3055555555555554 e 2.46
Pressed calf leather (D24)	64x64	1.1457317073170732 e 1.1151975683890578
	32x32	1.2717391304347827 e 1.1956782713085234
	16x16	1.6585365853658536 e 1.5
	8x8	2.978723404255319 e 2.2545454545454544
Beach sand (D29)	64x64	1.1577225130890052 e 1.1116520610191496
	32x32	1.3169761273209548 e 1.2068527918781726
	16x16	1.8085106382978724 e 1.5671641791044777
	8x8	3.1111111111111111 e 2.3461538461538463
Water (D38)	64x64	1.4188998589562765 e 1.3395773294908742
	32x32	1.5495327102803738 e 1.4040590405904059
	16x16	2.1777777777777776 e 1.7569444444444444
	8x8	4.25 e 2.9285714285714284
Wood grain (D68)	64x64	1.6347646145887222 e 1.4832123411978222
	32x32	1.832 e 1.4947368421052631
	16x16	2.5478260869565217 e 1.8493975903614457
	8x8	4.821428571428571 e 2.574468085106383
Raffia (D84)	64x64	1.1494363929146538 e 1.1151765828825961
	32x32	1.3011889035667108 e 1.2167919799498748
	16x16	1.797872340425532 e 1.5247524752475248
	8x8	3.1111111111111111 e 2.2777777777777777
Pigskin (D92)	64x64	1.179296346414073 e 1.1400597411218054
	32x32	1.3347050754458163 e 1.270481144343303

	16x16	1.8651685393258426 e 1.7085427135678393
	8x8	3.255813953488372 e 2.5090909090909093
Brick wall (D94)	64x64	1.230684730867814 e 1.1723300970873787
	32x32	1.4328571428571428 e 1.1612903225806452
	16x16	1.9883040935672514 e 1.4494949494949494
	8x8	3.375 e 2.2181818181818183
Plastic bubbles (D112)	64x64	1.1965949245101188 e 1.1668781725888324
	32x32	1.3333333333333333 e 1.2206235011990407
	16x16	1.7516778523489933 e 1.4784688995215312
	8x8	3.6666666666666665 e 2.1785714285714284

# Apêndice B

As cinco bandas das imagens de satélite usadas.



**Figura 29 - Banda 1**



**Figura 30 - Banda 2**



**Figura 31 - Banda 3**



**Figura 32 - Banda 4**



**Figura 33 - Banda 5**