ANA CLÁUDIA PARIS

**Análise da Eficiência de Recuperação por Conteúdo de
Imagens Médicas, utilizando Extratores de Textura baseados
em Wavelet e Wavelet Packet**

Dissertação apresentada à Escola de Engenharia de São Carlos da
Universidade de São Paulo, como parte dos requisitos para
obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Processamento de Sinais e Instrumentação
Orientador: Prof. Dr. Adilson Gonzaga

São Carlos

2008

*Dedico este trabalho a minha família e aos verdadeiros
amigos que me auxiliaram nesta caminhada.*

AGRADECIMENTOS

A Deus, criador e misericordioso, que sem dúvidas foi o grande facilitador para esta trajetória, abrindo os caminhos em direção ao sucesso e possibilitando que eu encontrasse as pessoas certas para me auxiliar nesta jornada.

Ao meu querido orientador Prof. Dr. Adilson Gonzaga, a quem tenho grande estima por sua paciência, amizade, compreensão e pelos preciosos conhecimentos compartilhados.

À minha família, em especial obviamente à minha mãe Amélia, uma grande mulher e vencedora que é um dos alicerces de uma família saudável e feliz.

Ao meu namorado Armando, com quem sempre posso contar verdadeiramente, uma pessoa especial que sempre me apoiou e incentivou em várias decisões de minha vida.

Aos amigos e amigas, cuja colaboração revelou-se essencial durante a caminhada. Em especial às amigas Renata e Ana Carolina pela grande amizade e companheirismo, experiências, dicas e acima de tudo pelas deliciosas gargalhadas que demos juntas. E ao amigo Sérgio pelos conselhos e persistência demonstrada.

Ao Hospital Amaral Carvalho da cidade de Jaú, em especial ao Dr. Ricardo C. Brandão, diretor da Fundação Amaral Carvalho que possibilitou acesso aos dados essenciais para o desenvolvimento deste trabalho.

Aos professores e funcionários do Programa de Pós Graduação em Engenharia Elétrica da Universidade de São Paulo, sempre prestativos e atenciosos.

“Ter problemas na vida é inevitável, ser derrotado por eles é opcional!” (Roger Crawford) “É justamente a possibilidade de realizar um sonho que torna a vida interessante” (Paulo Coelho).

RESUMO

PARIS, A. C. **Análise da Eficiência de Recuperação por Conteúdo de Imagens Médicas, utilizando Extratores de Textura baseados em Wavelet e Wavelet Packet.** 2008. 228 f. Dissertação (Mestrado) - Escola de Engenharia Elétrica de São Carlos, Universidade de São Paulo, 2008.

Aplicações computacionais voltadas para o auxílio ao diagnóstico (*Computer-Aided Diagnosis* – CAD) estão se tornando cada vez mais freqüentes. O objetivo dessas aplicações é fornecer ao profissional da área médica ferramentas que auxiliem na detecção precoce de patologias diversas. Nesse contexto, algoritmos que satisfaçam o interesse do usuário em encontrar imagens semelhantes a um caso específico podem ser desenvolvidos. Essas buscas devem ser feitas por similaridade, considerando a informação visual da imagem e não utilizando os recursos do processo convencional de busca textual, o qual compara parâmetros fornecidos pelo usuário com valores de atributos armazenados. As técnicas que permitem esse desenvolvimento são descritas na literatura como Recuperação de Imagens Baseada em Conteúdo (*Content-Based Image Retrieval* – CBIR). O maior desafio nessa abordagem é determinar o conjunto de características que descrevem o conteúdo da imagem adequadamente. No presente trabalho foram implementados algoritmos para extrair as características das imagens médicas utilizando as Transformadas *Wavelet* e *Wavelet Packet*. A Transformada *Wavelet Packet* tem maior capacidade para distinguir as freqüências quando comparada com a Transformada *Wavelet* “tradicional”. Esse estudo explora tal propriedade e analisa o desempenho dessas abordagens matemáticas na recuperação das imagens médicas por conteúdo. Ao final do estudo pôde-se estabelecer um comparativo entre os resultados obtidos com os vetores gerados a partir dos dados extraídos por ambas transformadas. Considerando-se que na área médica a precisão na obtenção das informações tem importância fundamental, a Transformada *Wavelet Packet* revelou vantagens relevantes sobre os métodos tradicionais que aplicam a Transformada *Wavelet*. Gráficos *Recall* x *Precision* e *Confusion Matrix* forneceram medidas da eficácia de recuperação.

Palavras-chave: *Wavelet*, *Wavelet Packet*, *Best Tree*, CBIR, Imagens Médicas.

ABSTRACT

PARIS, A. C. **Efficiency Analysis of Content-based Medical Image Retrieval, using Texture Extractors based on Wavelet e Wavelet Packet.** 2008. 228 f. M.Sc Dissertation - São Carlos Engineering School– Electrical Engineering Department, University of São Paulo, 2008.

Computer-Aided Diagnosis (CAD) applications are becoming more frequent each day. This application's objective is to provide tools for the medical professional that help in the precocious detection of different pathologies. On this context, algorithms that satisfy the user interest to find similar images related to a singular case can be developed. Such searches must be done considering the visual information instead of using common resources employed in textual conventional processes searches, which compares parameters provide by the user to attribute's values stored. The techniques that admit such development are depicted in the literature as Content-Based Image Retrieval (CBIR). The great challenge here is to define the features that represent the image appropriately. In the present research were implemented algorithms to extract the images features using the Wavelet Transform and Wavelet Packet Transform. A Wavelet Packet Transform distinguish frequencies better than the "tradicional" Wavelet Transform. Therefore this study explores such properties and analyze the both mathematics approaches performance in the medical images retrieval. A comparative can be established between the results obtained with the vectors produced using extracted data in both transforms. Considering that in the medical area the precision to obtain informations has fundamental importance, the Wavelet Packet Transform revealed relevant advantages compared to the traditional methods that use the Wavelet Transform. Recall x Precision graphs and Confusion Matrix provides retrieval efficiency measures.

Palavras-chave: *Wavelet, Wavelet Packet, Best Tree, CBIR, Medical Images.*

LISTA DE FIGURAS

Figura 2.1: Figura ilustrativa para indicar similaridade e dissimilaridade entre objetos.	27
Figura 2.2: (a) Identificação das extremidades usando formas regulares (b) Massa Encefálica.	34
Figura 2.3: Imagem monocromática.	37
Figura 2.4: A partir de um pixel central X estabelece-se a relação aos seus oito vizinhos.....	38
Figura 2.5(a) e (b): Agrupamento de dados (JAIN; MURTY; FLYNN, 1999).	40
Figura 2.6: Dendograma.....	41
Figura 2.7: Consulta kNN: Dado uma imagem de exame de CT do paciente X, encontre as 3 mais parecidas com o exame original (TRAINA; TRAINA JR, 2005).	42
Figura 2.8: Métrica Minkowski (AKLEMAN; JIANER, 1999).	46
Figura 2.9: Técnica de validação do método aplicado: <i>Recall x Precision</i>	51
Figura 2.10: Exemplo de Gráfico <i>Recall x Precision</i>	52
Figura 3.1: Sinal Estacionário.	56
Figura 3.2: Sinal não-estacionário.	57
Figura 3.3: <i>Short Time Fourier Transform</i> (adaptado de MATHWORKS, 2004).	58
Figura 3.4: Representação Tempo x Frequência da análise do sinal da figura 3.2 utilizando a STFT (adaptado de POLIKAR, 2001).	59
Figura 3.5: (a) Janelas usadas na TW. (b) Janelas usadas na STFT.	60
Figura 3.6: Representação Translação x Escala da análise de um sinal, utilizando a Transformada <i>Wavelet</i> (adaptado de POLIKAR, 2001).	65
Figura 3.7: Sinal e as <i>Wavelets</i> constituintes de diferentes escalas e posições.	68
Figura 3.8: Localização de <i>Wavelets</i> Discretas no espaço Tempo x Escala sobre um Grid Dyadic, onde S indica escala e τ indica translação.	69
Figura 3.9: Decomposição <i>Wavelet</i> discreta (PARRAGA, 2002 pp. 51).	71

Figura 3.10: Decomposição e subsampling do sinal (adaptado de POLIKAR, 2001).	72
Figura 3.11: Árvore de Decomposição <i>Wavelet</i>	73
Figura 3.12: A <i>Wavelet</i> de Haar, ψ	75
Figura 3.13: A função escala, ϕ , associada a <i>Wavelet</i> de Haar (LIMA, 2002).	75
Figura 3.14: Decomposição <i>Wavelet</i> de um sinal bidimensional.	77
Figura 3.15: Sinal bidimensional com dois níveis de decomposição.	78
Figura 3.16: Decomposição padrão de um sinal bidimensional.	79
Figura 3.17: Decomposição não-padrão de um sinal bidimensional.	80
Figura 3.18: Decomposição <i>Wavelet Packet</i> Unidimensional (MATHWORKS, 2004).	82
Figura 3.19: Decomposição <i>Wavelet Packet</i> Bidimensional.	82
Figura 3.20: Diagrama de Blocos da Transf. <i>Wavelet Packet</i> (PARRAGA, 2002, pp. 59).	84
Figura 3.21: Algoritmo <i>Best Basis</i> : os nós finais são “marcados” para iniciar o processo de análise das entopias dos nós filhos (WICKERHAUSER, 1991, pp.57).	86
Figura 5.1: (a) Imagem de RM Original. (b) TW com 2 níveis de decomposição. (c) TWP com 2 níveis de decomposição.	108
Figura 5.2: (a) Transf. <i>Wavelet</i> Discreta. (b) Transf. <i>Wavelet Packet</i>	110
Figura 5.3: Exemplo de uma série de Imagens de CT de Abdômen Superior em Corte Axial.	112
Figura 5.4: (a) Cintilografia Pulmonar. (b) Cintilografia do Esqueleto – Análise do Fluxo Sangüíneo Ósseo.	113
Figura 5.5: Exemplo de uma série de Imagens de CT de Abdômen Superior em Corte Axial.	114
Figura 5.6: Amostra de imagens de um exame de CT de Crânio.	115
Figura 5.7: Amostra de imagens das 13 classes selecionadas (primeiro conjunto de testes).	115
Figura 5.8: Amostra de imagens das 12 classes selecionadas (segundo conjunto de testes).	116

Figura 5.9: (a) Imagem Original. (b) Convolução com Máscara 3x3. (c) Convolução com Máscara 5x5.....	124
Figura 6.1: Decomposição <i>Wavelet</i> em dois níveis.	127
Figura 6.2: Eficiência de recuperação usando vetores com coeficientes <i>Wavelets</i> (TW).....	129
Figura 6.3: Matriz de confusão – TW com 6 níveis, coeficientes de aproximação.....	130
Figura 6.4: Matriz de confusão – TW com 6 níveis, CA normalizados.	131
Figura 6.5: Matriz de confusão – TW com 6 níveis, CA uniformizados.....	131
Figura 6.6: <i>Recall x Precision</i> comparativo entre as <i>Wavelets</i> de Haar e <i>Biorthogonal</i>	132
Figura 6.7: Filtros da <i>Wavelet Biorthogonal</i> 1.1 (LE-TIEN; CHIEN, 2004).....	133
Figura 6.8: Matriz de confusão da <i>Biorthogonal</i> 1.1 com 6 níveis de decomposição.....	134
Figura 6.9: (a) Imagem Original. (b) Filtro de Sobel.....	135
Figura 6.10: Matriz de confusão gerada a partir das 13 Características de Haralick.	136
Figura 6.11: Matriz de confusão resultante da aplicação do algoritmo não-supervisionado.	139
Figura 6.12: Desempenho das métricas de dissimilaridade.	140
Figura 6.13: Dendograma de agrupamento das classes.	142
Figura 6.14: Melhores resultados por nível sem alterar os dados.	149
Figura 6.15: Melhores resultados por nível: valores uniformizados.	149
Figura 6.16: Melhores resultados por nível: valores normalizados.....	150
Figura 6.17: (a) RxP: dados sem manipulação. (b) RxP: dados uniformizados.....	151
Figura 6.18: <i>Recall x Precision</i> do melhor resultado nas buscas com características extraídas após aplicação da <i>Wavelet Packet</i>	155
Figura 6.19: Melhores resultados por nível: <i>Wavelet Packet</i>	156
Figura 6.20: Desempenho considerando o máximo versus o mínimo número de elementos no vetor por nível de decomposição.	157
Figura 6.21: Árvore <i>Wavelet Packet</i> após algoritmo <i>Best Tree</i>	159

Figura 6.22: <i>Recall x Precision</i> – algoritmo <i>Best Tree</i>	160
Figura 6.23: Matriz de confusão do melhor resultado com a TW.	161
Figura 6.24: Matriz de confusão do melhor resultado com a TWP.....	162
Figura 6.25: Matriz de confusão do melhor resultado com a TWP – <i>Best Tree</i>	162
Figura 6.26: Imagem 1111.dcm (CT – cardíaca).....	163
Figura 6.27: Recuperação das 20 imagens mais similares à 1111.dcm	165

LISTA DE TABELAS

Tabela 5.1 – Quantidade de Subimagens geradas após a decomposição.....	109
Tabela 5.2 – Classes de Imagens	116
Tabela 5.3 – Classes de Imagens	117
Tabela 5.4 – Vetor gerado com o segundo nível de decomposição da TW	119
Tabela 5.5 – Vetor gerado com o segundo nível de decomposição da TWP.....	119
Tabela 5.6 – Dimensão dos subespaços em cada nível de decomposição	120
Tabela 6.1 – Número de Elementos no Vetor: Coeficientes Wavelets.....	128
Tabela 6.2 – Média de Acertos em cada Classe usando CA, CH, CD ou CV no vetor.....	137
Tabela 6.3 – Recuperação da Imagem 31 usando Vetor com Diferentes Coeficientes	138
Tabela 6.4 – Agrupamentos gerados de acordo com o método de ligação.....	141
Tabela 6.5 – Discriminação dos elementos em cada cluster	142
Tabela 6.6 – Composição dos Vetores de Características: Transf. Wavelet.....	143
Tabela 6.7 –Comparativo das médias de eficiência de recuperação usando as distâncias City-block e Euclidiana para cálculo da dissimilaridade entre vetores com valores “puros”, obtidas a partir de matrizes de confusão.	146
Tabela 6.8 – Comparativo das médias de eficiência de recuperação usando a distância City-block para cálculo da dissimilaridade entre vetores com valores “puros” e uniformizados, obtidas a partir de matrizes de confusão.	146
Tabela 6.9 – Comparativo das médias de eficiência de recuperação usando a distância City-block para cálculo da dissimilaridade entre vetores com valores “puros” e normalizados, obtidas a partir de matrizes de confusão	147
Tabela 6.10 – Número de subespaços no último nível de decomposição da TWP	152
Tabela 6.11 – Composição dos Vetores de Características: Transf. Wavelet Packet.....	152

Tabela 6.12 – Comparativo das médias de eficiência de recuperação usando vetores de características obtidos com a Transf. Wavelet Packet.....	154
Tabela 6.13 – Dez melhores resultados: Transf. Wavelet Packet	155
Tabela 6.14 – Uniformização x Normalização – Transf. Wavelet Packet.....	158
Tabela 6.15 – Resultados obtidos com o algoritmo Best Tree.....	161
Tabela 6.16 – Tempo Médio de Processamento.....	164

LISTA DE SIGLAS

ACR	<i>American College of Radiology</i>
BD	<i>Bhattacharya Distance</i>
CBIR	<i>Content-based Image Retrieval</i>
CBVIR	<i>Content-Based Visual Information Retrieval</i>
CA	Coeficientes de Aproximação
CD	Coeficientes de Detalhes Diagonais
CH	Coeficientes de Detalhes Horizontais
CT	<i>Computer Tomography</i>
CV	Coeficientes de Detalhes Verticais
CWT	<i>Continuous Wavelet Transform</i>
DB	<i>Daubechie</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DWT	<i>Discrete Wavelet Transform</i>
ED	<i>Euclidian Distance</i>
FD	<i>Fisher Distance</i>
FT	<i>Fourier Transform</i>
FWT	<i>Fast Wavelet Transform</i>
GUI	<i>Graphical User Interface</i>
GLCM	<i>Grey Level Co-Occurrence Matrix</i>
GLDM	<i>Grey Level Difference Method</i>
HIS	<i>Hospital Information System</i>
HM	<i>Histograma Métrico</i>
HSI	<i>Hue, Saturation, Intensity</i>
IA	Inteligência Artificial

KL	<i>Kullback-Leibler Distance</i>
k-NNQ	<i>k-Nearest Neighbor Query</i>
LDA	<i>Linear Discriminant Analysis</i>
LVQ	<i>Learning Vector Quantization</i>
MAE	Método de Acesso Espacial
MAENP	Método de Acesso Espacial Não Pontual
MAEP	Método de Acesso Espacial Pontual
MAM	Métodos de Acesso Métrico
MR	<i>Magnetic Resonance</i>
MRA	<i>Multiresolution Analysis</i>
MVE	Média, Variância e Energia
NEMA	<i>National Electrical Manufacturers Association</i>
PACS	<i>Picture Archiving and Communication Systems</i>
PCA	<i>Principal Component Analysis</i>
QBIC	<i>Query by Image Content</i>
QMF	<i>Quadrature Mirror Filter</i>
RIS	<i>Radiology Information System</i>
RGB	<i>Red, Blue, Green</i>
ROI	<i>Region of Interest</i>
R_q	<i>Range Query</i>
RLM	<i>Run Length Method</i>
RxP	<i>Recall x Precision</i>
SGBDR	Sistema Gerenciador de Banco de Dados Relacional
SGLDM	<i>Spatial Grey Level Dependence Method</i>
SRIS-HC	Sistema de Recuperação de Imagens Similares – Hospital das Clínicas

STFT	<i>Short Time Fourier Transform</i>
TW	<i>Transformada Wavelet</i>
TWP	<i>Transformada Wavelet Packet</i>
XA	<i>X-ray Angiography</i>
WMV	<i>Weighted-Mean -Variance</i>

SUMÁRIO

Capítulo 1	20
Introdução	20
1.1 Considerações Gerais	20
1.2 Motivação	22
1.3 Objetivos	22
1.4 Organização do Trabalho	23
Capítulo 2	26
Aspectos Gerais da Recuperação de Imagens baseada em Conteúdo	26
2.1 Considerações Iniciais	26
2.2 Sistemas de Recuperação de Imagem baseados em Conteúdo	28
2.3 Extração de Características	30
2.4 Atributos da Imagem	32
2.4.1 Atributo Cor	32
2.4.2 Atributo Textura	33
2.4.3 Atributo Forma	34
2.5 Vetor de Características e Caracterização da Imagem	35
2.6 Seleção de Características	35
2.6.1 Características para Descrição de Textura de Haralick	36
2.6.2 Pré-processamento da Imagem e Algoritmos Supervisionados e Não-supervisionados.	39
2.6.3 Análise de Agrupamentos.	40
2.7 Consultas por Similaridade	41
2.8 Função de Distância	43

2.9 Indexação	47
2.10 Avaliação dos Resultados	50
2.10.1 Gráficos <i>Recall</i> x <i>Precision</i>	51
2.10.2 Matrizes de Confusão (<i>Confusion Matrix</i>)	52
2.11 Considerações Finais	53
Capítulo 3	54
<i>Transformada Wavelet e Wavelet Packet</i>	54
3.1 Considerações Iniciais	54
3.2 Evolução das Wavelets	55
3.3 Histórico	62
3.4 Transformada Wavelet	63
3.4.1 Transformada <i>Wavelet</i> Contínua	67
3.4.2 Transformada <i>Wavelet</i> Discreta	68
3.5 Wavelet de Haar	74
3.6 Wavelets em Processamento de Imagens Digitais	75
3.7 Transformada Wavelet Packet	81
3.8 Considerações Finais	86
Capítulo 4	88
<i>Recuperação de Imagens na Área Médica</i>	88
4.1 Considerações Iniciais	88
4.2 Sistemas de Informação na Área Médica	89
4.2.1 Sistemas de Informação Hospitalar	90
4.2.2 Sistemas de Informações Radiológicas	90
4.2.3 Sistemas de Comunicação e Arquivamento de Imagem	90

4.3 Padrão DICOM	91
4.4 Áreas de Aplicação	94
4.5 Estado da Arte	95
4.6 Considerações Finais	104
Capítulo 5	106
Metodologia do Trabalho Desenvolvido	106
5.1 Introdução	106
5.2 Transformada Wavelet e Transformada Wavelet Packet	107
5.3 Conjunto de Dados	111
5.4 Conjunto de Imagens Teste	114
5.5 Conjunto de Características	118
5.6 Normalização e Uniformização dos Dados	120
5.7 Função de Distância	121
5.8 Técnicas Auxiliares	123
5.8.1 Características para Descrição de Textura de Haralick	123
5.8.2 Pré-processamento da Imagem e Algoritmos Supervisionados e Não-supervisionados.	123
5.9 Materias	125
Capítulo 6	126
Resultados e Conclusões	126
6.1 Considerações Iniciais	126
6.2 Análise do Nível de Decomposição	127
6.3 Resultados obtidos com a Normalização e Uniformização dos Dados	130
6.4 Análise da Wavelet Biorthogonal	131

6.5 Resultados obtidos com Imagens pré-processadas	134
6.6 Análise utilizando as Características de Haralick	135
6.7 Algoritmo Não supervisionado	137
6.8 Análise de Métricas para Cálculo da Dissimilaridade	139
6.9 Ampliação da Base de Testes	140
6.10 Recuperação das Imagens usando a Transformada Wavelet	142
6.11 Recuperação das Imagens usando a Transformada Wavelet Packet	151
6.12 Wavelet Packet vinculada ao algoritmo Best Tree	158
6.13 Comparativo entre a TW, TWP e a TWP com Best Tree	161
6.14 Tempo de Processamento	163
6.15 Conclusões	165
6.16 Contribuições	171
6.17 Trabalhos Futuros	172
Referências Bibliográficas	174
APÊNDICE A	184
APÊNDICE B	185
APÊNDICE C	186
APÊNDICE D	189
APÊNDICE E	222
APÊNDICE F	225

Introdução

1.1 Considerações Gerais

Aquisição de imagens digitais para fins relacionados à Medicina tem se tornado muito comum atualmente. Com isso, a quantidade de informação gerada em centros médicos provenientes das diversas modalidades de exames tem crescido exponencialmente. Técnicas mais recentes como Tomografia Computadorizada (*Computer Tomography* – CT) e Ressonância Magnética (*Magnetic Resonance* – MR) geram dezenas ou até centenas de imagens para um único exame.

A difusão das imagens médicas e dos sistemas que as manipulam culminou no desenvolvimento de padrões cujos principais representantes são os PACS (*Picture Archiving and Communication Systems*) e as imagens em padrão DICOM (*Digital Imaging and Communications in Medicine*) (FIGUEIREDO *et al.*, 2004).

O objetivo dos sistemas de recuperação de imagens na área médica é disponibilizar a informação necessária de forma precisa, contribuindo para a qualidade e eficiência dos diagnósticos. Encontrar imagens com a mesma patologia, mesma modalidade de exame, mesma região anatômica, pode ser essencial no processo de decisões clínicas (EAKINS; GRAHAM, 1999).

Na técnica CBIR (*Content-based Image Retrieval*) ao invés de se utilizar anotações textuais para representar as imagens, elas são indexadas com base em seu conteúdo visual através de características de cor, textura ou forma, por exemplo, que são as chamadas características primitivas da imagem. Os métodos de acesso visuais além de beneficiar os diagnósticos, também auxiliam o ensino e a pesquisa na área médica.

Uma alternativa para indexar imagens por conteúdo é a indexação pelo domínio da transformada, devido a efetiva caracterização das propriedades locais da imagem (CASTAÑÓN, 2003), campo no qual as Transformadas *Wavelets* tem se destacado como excelentes ferramentas. Elas possibilitam gerar os vetores de características para representar uma imagem utilizando poucas informações obtidas com base nos coeficientes gerados.

Nas últimas décadas a teoria *Wavelet* tem emergido como um *framework* matemático que fornece uma análise formal, sólida e unificada para imagens. Mais recentemente Coifman e Wickerhauser (1991) generalizaram as funções base *Wavelets* para incluir uma biblioteca modulada de *waveforms* ortonormais chamada *Wavelet Packets*. Desde então as transformadas *Wavelet* e *Wavelet Packet* têm sido implementadas eficientemente com algoritmos estruturados em árvore, onde altas e baixas frequências são subdivididas. Os valores ou coeficientes gerados capturam as características essenciais para análise e discriminação de texturas (HIREMATH; SHIVASHANKAR, 2006).

1.2 Motivação

Em aplicações na área das imagens médicas, encontrar o grau de similaridade entre duas imagens, ou seja, realizar comparações entre duas imagens para descobrir quão parecida elas são é sem dúvida de grande utilidade. Em imagens médicas a utilização do atributo textura para caracterização das imagens tem se destacado como um dos mais apropriados, pois órgãos, tecidos e anomalias têm texturas específicas que os delimitam e separam e nesse campo de pesquisa a Transformada *Wavelet* tem apresentado resultados promissores. Já sua variação, a Transformada *Wavelet Packet* não tem sido utilizada com frequência para caracterização das imagens médicas, motivo pelo qual se optou por utilizá-la, a fim de investigar suas propriedades nesse contexto. Além disso, dependendo da modalidade de exame utilizado para gerar as imagens pode fazer com que as informações mais significantes se concentrem nas altas frequências. A decomposição obtida com a Transformada *Wavelet Packet* enfatiza tanto características contidas nas baixas quanto nas altas frequências, diferentemente da Transformada *Wavelet* que parte do pressuposto que as baixas frequências contêm mais informações do que as altas frequências, decompondo em todos os níveis a imagem resultante da convolução com filtros passa-baixa. Esta capacidade da Transformada *Wavelet Packet* pode enfatizar detalhes únicos em cada imagem, destacando-a das demais imagens contidas no banco de imagens médicas.

1.3 Objetivos

O objetivo deste trabalho é desenvolver um conjunto de algoritmos que gere vetores de características para cada imagem armazenada na base, usando as Transformadas *Wavelet* e *Wavelet Packet* através de uma análise multiresolução e compará-los utilizando uma medida de dissimilaridade para recuperar as imagens mais semelhantes à imagem de entrada.

A Transformada *Wavelet Packet* é uma generalização da Transformada *Wavelet*, que obtém uma análise mais detalhada da imagem, sendo que não apenas os coeficientes de aproximação são subdivididos, mas também os coeficientes de detalhes. Este trabalho, analisa e compara o desempenho na recuperação das imagens utilizando essa segunda abordagem além de verificar se os resultados são mais precisos nas buscas, mesmo sendo a Transformada *Wavelet Packet* mais custosa computacionalmente que a Transformada *Wavelet*.

Para atingir os objetivos deste trabalho, foi criado de um banco de imagens médicas devidamente laudadas para validar os resultados obtidos com as transformadas matemáticas. A montagem dessa base faz-se necessária, pois devido a natureza particular dos dados contidos nos exames médicos tais bases dificilmente são públicas como ocorre com base de imagens de faces humanas, texturas, etc.

1.4 Organização do Trabalho

Este primeiro capítulo apresentou uma visão geral do trabalho proposto descrevendo algumas considerações iniciais e definindo os objetivos. Foram apresentadas a contextualização do estudo e a motivação para o seu desenvolvimento.

No capítulo 2 serão apresentados os principais aspectos envolvidos em um sistema de Recuperação de Imagens por Conteúdo, destacando a importância das fases de extração e seleção de características para geração dos vetores de características, além da definição adequada da função de distância para o cálculo de dissimilaridade entre as imagens.

O capítulo 3 abordará os conceitos relacionados à teoria das Transformadas *Wavelet* e *Wavelet Packet*, partindo de sua contextualização na teoria de processamento de sinais e fatores que geraram seu desenvolvimento, com destaque para sua capacidade de análise multiresolução, propriedade na qual está embasado o presente trabalho para geração dos vetores de características.

O capítulo 4 descreve a contextualização dos sistemas de Recuperação de Imagens baseado em Conteúdo e de aplicações que fazem uso das vantagens da Transformada *Wavelet* no âmbito das imagens médicas.

No capítulo 5 está descrita a metodologia utilizada na elaboração deste projeto de mestrado e no capítulo 6 são apresentados os resultados e as conclusões.

Aspectos Gerais da Recuperação de Imagens baseada em Conteúdo

2.1 Considerações Iniciais

Os sistemas de Recuperação de Imagens Baseados em Conteúdo (*Content-Based Image Retrieval – CBIR*) tentam minimizar a complexidade envolvida na análise computacional dos dados visuais que representam uma imagem. Nesse contexto, é importante destacar que duas representações binárias com consideráveis diferenças podem representar duas imagens visualmente muito semelhantes. O principal objetivo em um sistema CBIR é transformar a informação pictórica em dados numéricos e/ou textuais para gerar um conjunto de dados adequado, contendo informações o mais próximo possível da semântica envolvida na imagem.

Para atingir esse objetivo, algoritmos de processamento de imagens são aplicados para extrair características intrínsecas da imagem e montar o vetor de características, que será

comparado com vetores da base por meio de medidas de dissimilaridade para recuperação das imagens mais semelhantes à imagem de consulta ou também chamada imagem de referência. É importante também fazer uma breve explicação sobre similaridade e dissimilaridade. A figura 2.1 pode ser usada como base para a indagação: “Quais desses objetos são similares e quais são diferentes?” A resposta depende de quais características ou conjunto de características estão sendo consideradas (tamanho, cor, forma, etc).

Figura 2.1: Figura ilustrativa para indicar similaridade e dissimilaridade entre objetos.

Similaridade é a medida que reflete a intensidade do relacionamento entre dois objetos ou dois conjuntos de características. O valor da similaridade geralmente varia de -1 a 1 ou de 0 a 1 quando normalizada. A similaridade entre as características de textura do objeto i e do objeto j é denotada por S_{ij} .

A dissimilaridade mede a discrepância entre dois objetos com base em um conjunto de características. Dissimilaridade também pode ser vista como uma medida da desordem entre dois objetos. Essas características podem ser representadas como coordenadas do objeto em um espaço de características. O relacionamento entre similaridade e dissimilaridade pode ser definido da seguinte forma: considere uma dissimilaridade normalizada entre o objeto i e o objeto j , denotada por δ_{ij} . O relacionamento é dado por $S_{ij} = 1 - \delta_{ij}$. Para similaridade delimitada entre 0 e 1, quando a similaridade é igual a 1 (ou seja, exatamente similar), a dissimilaridade é 0 e quando a similaridade é 0 (ou seja, muito diferente), a dissimilaridade é 1.

Em muitos casos, medir a dissimilaridade, ou seja, a distância entre os objetos, é mais fácil do que medir a similaridade. No entanto, uma vez medida a dissimilaridade, pode-se

facilmente normalizá-la e convertê-la em uma medida de similaridade (TEKNOMO, 2006). O presente trabalho está focado na análise da dissimilaridade entre as imagens.

2.2 Sistemas de Recuperação de Imagem baseados em Conteúdo

O termo Recuperação de Imagem baseada em Conteúdo (*Content-Based Image Retrieval* – CBIR), começou a ser utilizado na literatura em 1992, por Kato (1992), para descrever seu experimento sobre recuperação automática de imagens de uma base de dados usando as características de cor e de forma. A partir desse trabalho, o termo passou a ser amplamente usado para descrever o processo de recuperação de imagens baseado em um conjunto de características, extraídas das próprias imagens (EAKINS; GRAHAM, 1999).

Pesquisas e sistemas envolvendo Recuperação de Informação Visual baseada em Conteúdo (*Content-Based Visual Information Retrieval* – CBVIR) ou Recuperação de Imagem baseada em Conteúdo (CBIR) têm sido desenvolvidos desde o início da década de 80. Desde então, e principalmente nos últimos 10 anos, recuperação de imagens baseada em conteúdo tem se destacado como uma das áreas de pesquisas mais ativas no campo da Visão Computacional e conseqüentemente em Processamento de Imagens. No entanto, a maioria dessas pesquisas ainda se restringe ao campo acadêmico. Em (MÜLLER *et al.*, 2004; MOURA *et al.*, 2003), pode ser encontrada uma revisão de alguns sistemas comerciais e acadêmicos conhecidos, como o sistema QBIC¹ (*Query by Image Content*) da IBM, que pode ser citado como o primeiro sistema comercial nessa área.

Grande parte das técnicas atuais mais usadas para recuperação da informação envolve anotações que visam descrever a semântica da imagem. Esses textos são a base para a pesquisa sobre as imagens, usando as ferramentas já desenvolvidas para pesquisa em texto. Contudo, existem muitos problemas nessa abordagem. Pode-se dizer que a principal

¹ <http://www.qbic.almaden.ibm.com>, acessado em 20/01/2007.

deficiência reside na subjetividade implícita nas anotações, a qual pode interferir no processo de recuperação, pois esses dados além de variar de usuário para usuário também variam para o mesmo usuário no decorrer do tempo. Diferentes pessoas podem fornecer informações diferentes sobre a mesma imagem, gerando respostas não confiáveis para pesquisas sobre esses assuntos. Outro ponto a ser considerado nas abordagens textuais é o custo dispensado para se fazer anotações em grandes bancos de dados de imagens.

Dessa forma, dentre os desafios a serem superados nos sistemas CBIR, o principal refere-se ao gargalo existente entre a informação semântica de alto nível do usuário e a informação de baixo nível gerada pelos algoritmos de processamento de imagens. Esse problema é descrito na literatura como “*gap* semântico”. Uma alternativa para superá-lo seria mesclar características visuais de baixo nível com características textuais de alto nível (EAKINS; GRAHAM, 1999).

Para a obtenção de bons resultados nas buscas por conteúdo é necessário possuir uma codificação e busca de imagens eficientes, baseadas no conteúdo semântico das imagens. Uma abordagem utilizada para se obter uma caracterização eficiente da semântica da imagem é através de vetor de características (OLIVEIRA *et al.*, 2000), descrito na seção 2.5.

Alguns trabalhos optam por dicionários de sinônimos, utilizando palavras-chaves, as quais podem ser geradas por processamento, reconhecimento de voz, ou outras técnicas (ZHOU; HUANG, 2002). Também é possível mapear conceitos semânticos para comandos SQL, por exemplo, “traga uma imagem de uma lesão cerebral ‘grande’”, onde o atributo tamanho seja maior que um valor pré-definido (MIAO *et al.*, 2004).

Outro fator importante a ser considerado em um sistema CBIR é o tratamento do domínio das imagens, isto é, o contexto no qual a imagem é utilizada e processada, sendo que, um domínio pode ter sub-domínios e esses podem ter outros sub-domínios. A determinação

do domínio a partir do contexto de uso é a principal influência sobre os requisitos semânticos que podem existir em cada processamento.

Um sistema CBIR visa descrever da forma mais adequada o conteúdo das imagens, com base em suas propriedades locais. Para isto, algoritmos de processamento de imagens são aplicados como detectores de bordas, técnicas de segmentação automáticas ou baseada em ROI (Região de Interesse demarcada pelo Usuário – *Region of Interest*), transformações de domínio, entre outras metodologias, a fim de extrair as informações visuais da imagem de consulta que servirão como parâmetros para o processamento, bem como das imagens armazenadas na base. As características da imagem de consulta são enviadas para o cálculo de similaridade com as demais imagens cadastradas. As imagens resultantes desse cálculo são apresentadas ao usuário no final do processo (FIGUEIREDO, 2005).

2.3 Extração de Características

Uma etapa muito importante no processo de Visão Computacional é a extração de características da imagem, pois elas sintetizam as suas propriedades inerentes (GATO; NUNES; SCHIABEL, 2004).

O objetivo nessa etapa é expressar em números as propriedades da imagem, sendo que a maior dificuldade é conseguir expressar com valores semelhantes as propriedades de imagens consideradas semanticamente semelhantes.

Em geral, as pesquisas utilizam características visuais classificadas como primitivas, tais como cor, forma e textura. Há também características classificadas como lógicas, que tratam da identificação do objeto e características classificadas como abstratas, que tratam do contexto da cena descrita (EAKINS; GRAHAM, 1999). No entanto, o usuário geralmente pensa em termos de conceitos semânticos, o que faz com que em um primeiro momento ele não esteja interessado nas características de baixo nível da imagem, desafiando os

pesquisadores a encontrarem alternativas para diminuir o chamado “*gap* semântico” entre a aplicação e o usuário, conforme mencionado na seção anterior.

As características de baixo nível podem ser usadas tanto em nível global sobre a imagem quanto em nível local sobre partes da imagem, visando à segmentação. Nesse caso, o atributo forma pode ser empregado, posteriormente, como um mecanismo para descrever as partes segmentadas (EAKINS; GRAHAM, 1999). Independente das características usadas: simples ou compostas, muitas vezes é necessário um processo de normalização. Simples se for considerado apenas um atributo (textura) e composta se considerado mais de um atributo (cor e textura).

No caso das imagens médicas, normalmente imagens provenientes do mesmo tipo de exame possuem as mesmas propriedades. Exames de CT, por exemplo, usualmente possuem tamanhos de 512x512 e codificação de 12 bits. Mas ao utilizar histogramas, por exemplo, para extrair características de cor, se as imagens possuírem tamanhos diferentes ou codificações de níveis de cinza diferentes (uma pode estar com 12 bits e outra com 8 bits), uma normalização pode ser necessária (FIGUEIREDO, 2005).

Assim, a parte crítica do processo de recuperação de imagens é definir o espaço de características a ser utilizado para realizar a correlação entre atributos similares. O espaço de características é a representação dos dados que serão usados no processo de recuperação de imagens por conteúdo e define o que será comparado, mediante uma métrica de similaridade no momento da busca de imagens (CASTAÑÓN, 2003).

Na fase de extração de características, técnicas de IA (Inteligência Artificial) e reconhecimento de padrões podem ser usadas, para evitar a tarefa exaustiva de detectar qual técnica é melhor para qual imagem e/ou parte da imagem. Técnicas de redução de dimensionalidade também muitas vezes são requeridas, devido a grande quantidade de características extraídas das imagens. O uso de espaço de características em alta

dimensionalidade tem mostrado causar problemas e exige grande atenção na escolha da medida de dissimilaridade para obter resultados significativos (MÜLLER *et al.*, 2004). Os problemas com a definição de similaridade em espaços de características de alta dimensionalidade são conhecidos como a “maldição da alta dimensionalidade” (FIGUEIREDO, 2005).

2.4 Atributos da Imagem

Os trabalhos em CBIR podem ser divididos em três grandes grupos dentro do conjunto de características chamadas primitivas, pois muitos sistemas de recuperação utilizam cor, textura e forma para representar uma imagem e a recuperação está baseada na similaridade das características derivadas delas (EAKINS; GRAHAM, 1999).

2.4.1 Atributo Cor

Existem diferentes representações de cores que incluem desde o tradicional RGB (*Red, Green, Blue*), até o HSI (*Hue, Saturation, Intensity*). Muitos trabalhos em sistemas CBIR utilizam distribuição de cores (ROSA *et al.*, 2002; MOURA *et al.*, 2003; MÜLLER *et al.*, 2004). Uma das técnicas mais populares são os histogramas de cor ou brilho das imagens. Os histogramas apresentam baixo custo computacional e indicam a distribuição das tonalidades, além de serem invariantes à translação e rotação das imagens, sendo que, com a normalização dos histogramas se obtêm também a invariância à escala.

Já os histogramas em imagens coloridas apresentam algumas dificuldades para manipulação devido ao seu caráter não invariante e se a imagem contém um grande número de cores, então o vetor de características será maior e a indexação de vetores com alta dimensão torna-se problemática. No caso das imagens médicas, estas normalmente são

apresentadas em tons de cinza, o que pode viabilizar a utilização de histogramas para extração das características.

Um ponto a ser considerado refere-se ao fato de que o histograma produz uma representação ambígua da mesma, visto que duas imagens diferentes podem ter o mesmo histograma. Por outro lado, os histogramas podem fornecer uma rápida pré-seleção para sistemas de recuperação de imagens, e o resultado da pré-seleção pode ser posteriormente refinado por técnicas mais elaboradas e complexas, e conseqüentemente mais caras (BALAN *et al.*, 2004).

2.4.2 Atributo Textura

Textura pode ser caracterizada por variações locais dos valores de pixels que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem (ROCHA, 2007). Uma região em uma imagem tem textura constante se um conjunto de estatísticas locais ou outras propriedades locais são constantes, variam suavemente ou são aproximadamente periódicas (SKALANSKY, 1978). A textura é uma das mais importantes características usadas para classificar e reconhecer objetos e cenas em várias áreas como automação industrial, processamento de imagens de sensoriamento remoto e biomédicas. A análise da textura tem por objetivo estabelecer o relacionamento de vizinhança dos elementos e seu posicionamento em relação aos demais (conectividade), o número de elementos por unidade espacial (densidade) e a sua regularidade (homogeneidade) (TRAINA, 2001).

Uma das dificuldades no uso do atributo textura reside na alta dimensionalidade do vetor de características. Nos sistemas CBIR voltados para a área médica, as características de textura são muito úteis, pelo fato de que a maioria das superfícies naturais exibem texturas e, através desse atributo, é possível identificar órgãos e regiões específicas dentro desses órgãos, anomalias, patologias, entre outras peculiaridades pertinentes às imagens médicas.

2.4.3 Atributo Forma

A utilização do atributo forma exige o desenvolvimento de técnicas que concedam uma descrição total da borda do objeto ou que descrevam as características morfológicas de uma região. Em sistemas CBIR, o atributo forma é a abordagem que apresenta maior dificuldade, pois há a necessidade de segmentar e reconhecer o tamanho dos objetos contidos na imagem. Esse ponto é fundamental em imagens médicas, onde variações na forma podem indicar estruturas sadias ou com patologia, por exemplo. As estruturas dos objetos existentes em imagens médicas não seguem o padrão de classificação para formas geométricas (regulares e irregulares). Na área médica quando um objeto é classificado como oval, por exemplo, ele possui variações com relação a forma normal de um objeto oval, devido a existência de pequenas concavidades na estrutura do objeto, conforme pode ser observado na figura 2.2, que exibe uma imagem de uma massa encefálica, acompanhado de um método para identificação das extremidades do objeto usando formas regulares. Por outro lado a análise de estruturas convexas também dificulta a classificação de um objeto com forma irregular. Determinar a área do objeto e identificar os limites de sua estrutura pode ser um dos pontos que requer atenção ao se trabalhar com o atributo forma (WANGENHEIM, 2005).

Figura 2.2: (a) Identificação das extremidades usando formas regulares (b) Massa Encefálica.

2.5 Vetor de Características e Caracterização da Imagem

O vetor de características (*feature vector*) pode ser definido como uma representação numérica da imagem, caracterizando medidas dos aspectos representativos do objeto. Essa nova representação da imagem obtida através do vetor de características deve atender a três considerações: reduzir a dimensionalidade dos dados, ressaltar aspectos da imagem para facilitar a percepção humana e ser invariante às transformações da imagem.

Devido à dificuldade de se manipular a grande quantidade de informações contida na imagem, surge a necessidade de se gerar vetores de características. Assim, a geração do vetor de características é um processo que calcula novas variáveis, a partir da imagem original. Esse processo visa extrair informações contidas na imagem que permitirão codificá-la adequadamente (CASTAÑÓN; TRAINA, 2002). O uso das *Wavelets* para extrair as características tem se tornado uma prática muito comum devido à boa caracterização que pode ser obtida da imagem (OLIVEIRA *et al.*, 2000).

A análise multiresolução das *Wavelets* é uma estratégia que se mostra bastante adequada para extração das características, pois com poucos coeficientes é possível obter uma boa representação da imagem. Os coeficientes praticamente não dependem da resolução da imagem e a transformada possui custo linear (BIANCHI, 2006).

2.6 Seleção de Características

O campo de pesquisa que se refere à extração e seleção de características é muito amplo. Muitos estudos têm sido realizados nos últimos anos visando encontrar o espaço de características mais representativo ao domínio das imagens, para permitir a recuperação de maneira mais eficiente. Extração e seleção de características adequadas são extremamente importantes. A tarefa de calcular as características mais relevantes é tão importante quanto a

tarefa de calcular as características redundantes. No entanto, o segundo estudo não recebe tanto enfoque quanto o primeiro.

Dentre algumas técnicas que podem ser usadas para seleção estão os algoritmos genéticos, escolha ponderada, seleção sequencial de propriedades, fractais e técnicas de aprendizado de máquinas. Outras técnicas como Transformada de Fourier e Transformada *Wavelets* aplicam transformações no domínio de dados ao invés de transformações lineares (FIGUEIREDO, 2005). Frequentemente o processo de seleção é precedido pela extração, de forma que inicialmente as características são extraídas a partir dos dados de entrada e a seguir um algoritmo de seleção elimina os atributos menos relevantes segundo um determinado critério, reduzindo a dimensionalidade.

No entanto, a redução excessiva de dimensionalidade pode prejudicar a discriminação dos elementos. Por outro lado, a alta dimensionalidade dos dados pode trazer alguns efeitos incômodos como, por exemplo, fazer com que os algoritmos de manipulação fiquem na ordem quadrática em relação ao número de elementos do conjunto, ou pode representar ruídos ou informações redundantes. Há ainda o efeito da esparsidade, fazendo com que a distância entre elementos próximos não seja discriminada. Assim, é importante analisar a variação do comportamento da discriminação ao aplicar algoritmos para selecionar e reduzir a dimensionalidade do conjunto de características, visando estimar a dimensionalidade ideal.

2.6.1 Características para Descrição de Textura de Haralick

Através da análise do atributo textura pode-se identificar padrões como uniformidade, densidade, aspereza, regularidade e intensidade. Há na literatura 3 métodos principais para descrever a textura: espectrais, estruturais e estatísticos. O método espectral é baseado na análise de espectros de frequências, obtidos através de transformadas como a *Wavelet*, que foi empregado nos testes desse trabalho, destacando a existência de padrões periódicos ou semi-

periódicos. O método estatístico é baseado na extração de um conjunto de medidas estatísticas de uma imagem através da relação entre seus níveis de cinza (luminância). Método que apresenta bons resultados principalmente quando as texturas a serem analisadas não possuem boa regularidade.

Pode-se realizar uma análise estatística de primeira ordem extraindo-se características como média, variância, desvio padrão, simetria, achatamento, energia e entropia. Porém, essa abordagem não leva em consideração uma informação muito importante que é a relação do pixel com a sua vizinhança, ou seja, a sua distribuição espacial. A figura 2.3 apresenta duas imagens com características visualmente distintas. Uma análise estatística de primeira ordem pode gerar valores semelhantes para ambas as imagens. Assim, uma análise estatística de segunda ordem que leva em consideração a relação de cada pixel da imagem com a sua vizinhança, ou seja, avalia o posicionamento espacial relativo a ocorrência dos níveis de cinza na imagem pode superar essa deficiência.

Figura 2.3: Imagem monocromática.

Existem basicamente três métodos que aplicam respectivamente a análise de estatísticas de segunda ordem, são eles: o Método de Dependência Espacial de Nível de Cinza – **SGLDM** (*Spatial Grey Level Dependence Method*), o Método da Diferença de Nível de Cinza – **GLDM** (*Grey Level Difference Method*) e o Método de Comprimento de Sequências de Níveis de Cinza – **RLM** (*Run Length Method*).

O método SGLDM calcula a probabilidade de ocorrer qualquer transição de nível de cinza entre dois pixels da imagem separados por uma dada orientação espacial. O método GLDM calcula a probabilidade de existência de uma dada diferença específica de nível de

cinza entre dois pixels (valor fixo), separados por uma dada orientação espacial. Por fim, o método RLM calcula a probabilidade de existência de seqüências de pixels idênticos, para um dado comprimento e, ao longo de uma dada orientação.

Dentre esses métodos o que apresenta melhor resultado é o método SGLDM para caracterizar texturas. Este método é também conhecido como Método das Matrizes de Co-ocorrência – GLCM (*Grey Level Co-Occurrence Matrix*), o qual foi primeiramente apresentado por Haralick.

A estatística de segunda ordem é calculada pela probabilidade de um determinado par de níveis de cinza i e j , numa determinada distância δ e uma direção θ (0° , 45° , 90° e 135°) ocorrer, ou seja, a GLCM pode ser denominada como sendo um histograma bidimensional que fornece a frequência de ocorrência $P(i, j, \delta, \theta)$, conforme ilustrada a figura 2.4. Esses quatro direcionamentos geram quatro matrizes diferentes que são ordenadas e normalizadas. Haralick definiu 13 características que podem ser extraídas dessas matrizes para descrição de textura (energia, ou momento angular, entropia, contraste ou variância, homogeneidade local, correlação, entre outras) (HARALICK; SHANMUGAN; DINSTEIN, 1973).

Figura 2.4: A partir de um pixel central X estabelece-se a relação aos seus oito vizinhos.

A maioria dos trabalhos encontrados na Literatura não identificam todas as 13 características definidas por Haralick. Xue *et al.* (2007) empregam 4 características (contraste, correlação, homogeneidade e energia) para recuperar imagens cervicográficas visualmente similares e com patologia relevante. Silva, Carvalho e Gattas (2004) aplicam contraste,

homogeneidade local, segundo momento angular, entropia, variância e correlação para auxiliar no diagnóstico de nódulos pulmonares em imagens de CT.

2.6.2 Pré-processamento da Imagem e Algoritmos Supervisionados e Não-supervisionados.

Alguns trabalhos interessantes também podem ser encontrados na literatura desenvolvendo técnicas que auxiliam no processo de extração de características. Moura *et al.* (2003) acrescentam uma fase de pré-processamento nas etapas de um sistema CBIR, onde algoritmos para realce de contraste, remoção de ruídos, isolamento de regiões podem ser aplicados, visando melhorar a imagem de forma a aumentar as chances de sucesso na etapa final de recuperação.

Outros autores trabalham com algoritmos supervisionados e não-supervisionados para apurar os resultados das buscas. Uma técnica chamada realimentação por relevância (*relevance feedback*) pode ser empregada para refinar os resultados. Nela o usuário interage em tempo real com o algoritmo julgando os resultados trazidos e filtrando-os através da seleção de regiões da imagem, *range* de cores, forma, texturas ou mesmo parâmetros de movimento (EAKINS; GRAHAM, 1999). Mas, a aposta em algoritmos não-supervisionados que refinem os resultados também é forte. Nessa linha pode-se citar Kim e Kang (2007) que decompõem imagens de textura usando *Wavelet Packet*, em seguida aplicam um algoritmo não-supervisionado para classificar e recuperar as imagens. Dy *et al.* (2003) aplica um algoritmo não-supervisionado para extração de características que usa uma abordagem chamada de consultas-customizadas, a qual trabalha com múltiplos vetores de características. A primeira busca é realizada normalmente, já a segunda busca recupera as imagens de pulmão mais similares a de uma classe pré-selecionada na primeira busca usando características customizadas que distinguem subclasses dentro dessa classe.

2.6.3 Análise de Agrupamentos.

Análise de agrupamentos é uma técnica para criar grupos de objetos (*clusters*) de maneira que os perfis dos objetos em um mesmo *cluster* sejam muito similares e os perfis de objetos em diferentes *clusters* sejam muito distintos. É um método de classificação não-supervisionada, onde o número de *clusters* é desconhecido antes da análise. O agrupamento é baseado na similaridade, assim para um conjunto de dados de entrada como o exemplificado na figura 2.5(a) e desejável um agrupamento de acordo com o exibido na figura 2.5(b).

Figura 2.5(a) e (b): Agrupamento de dados (JAIN; MURTY; FLYNN, 1999).

Esse agrupamento é realizado analisando-se as distâncias entre os objetos e considerando-se uma relação entre esses objetos que é chamada de método de ligação (*linkage method*). Existem vários métodos de ligação como a “ligação simples” que é definida como a distância entre os vizinhos mais próximos, a “ligação completa” definida como a distância entre os vizinhos mais distantes, a “ligação média” definida como a média de todas as distâncias entre dois *clusters*, “centróide” definida como a distância entre os centros gravitacionais de cada *cluster*, etc.

Outra alternativa para investigar o conjunto de dados em uma análise de *cluster* (grupos), é o método de agrupamento hierárquico (*Hierarchical Clustering*), que permite analisar os dados simultaneamente em várias escalas. Nesse método, *clusters* de um nível

inferior são combinados com *clusters* de um nível superior, gerando um diagrama em formato de árvore chamado Dendograma que também usa um método de ligação para definir os agrupamentos, ilustrado na figura 2.6.

Inicialmente todos os indivíduos são considerados como *clusters* de um único objeto. Dois objetos com distâncias menores são combinados para formar um novo *cluster*. Computa-se novamente as distâncias desse novo *cluster* para os demais objetos para formar um novo agrupamento. A cada passo desse processo o número de objetos sem agrupamento diminui. O algoritmo finaliza quando todos os objetos pertencerem a um *cluster*.

Figura 2.6: Dendograma.

Obviamente na maioria das vezes não se deseja encontrar um único agrupamento, assim “corta-se” o dendograma para obter vários clusters. Essa hierarquia em multi escala permite decidir qual nível ou escala de agrupamento é mais apropriada para cada aplicação (YANG; TREWN, 2004), (JAIN; MURTY; FLYNN, 1999).

2.7 Consultas por Similaridade

Cálculos de similaridade são altamente dependentes das características selecionadas. As consultas por conteúdo envolvem, na maioria das vezes, consultas por vizinhos mais próximos (*kNN*) ou consultas por abrangência (*Rq*). Consultas por vizinhos mais próximos

visam encontrar quais são os n vizinhos mais próximos da imagem de consulta, conforme ilustra a figura 2.7. Um exemplo seria encontrar as 5 imagens mais semelhantes a do paciente em questão. Já uma consulta por abrangência busca todas as imagens que estão dentro de um raio r de distância da imagem de consulta. Uma consulta ilustrativa seria encontrar todas as imagens que estão a uma distância de 10 unidades da imagem do paciente pesquisado.

Figura 2.7: Consulta kNN: Dado uma imagem de exame de CT do paciente X, encontre as 3 mais parecidas com o exame original (TRAINA; TRAINA JR, 2005).

Consultas aos k -Vizinhos Mais Próximos (k -Nearest Neighbor Query – kNN): expressa pelo predicado $kNN(s_q)$, recupera os k objetos mais próximos ao objeto de referência s_q , no qual $s_q \in S$. Formalmente, pretende-se encontrar o subconjunto $A \subseteq S$ que atenda a:

$$kNN(s_q) = A = \{a \mid a \in S, \forall s_i \in S - A, d(s_q, a) \leq d(s_q, s_i), |A| = k\} \quad (2.1)$$

Consultas por Abrangência ($Range$ Query – R_q): expressa pelo predicado $range$ $R_q(s_q, r)$, recupera objetos que se encontram a uma distância máxima r (raio de busca), a partir do objeto de referência s_q (objeto de busca), onde $s_q \in S$. Formalmente, pretende-se encontrar o subconjunto $A \subseteq S$ que atenda a (FIGUEIREDO, 2005):

$$Rq(s_q, r) = A = \{a \mid a \in S, d(s_q, a) \leq r\} \quad (2.2)$$

2.8 Função de Distância

A base de características normalmente é formada por um conjunto de vetores que são tratados como dados multidimensionais, o qual pode ser indexado utilizando um método de acesso espacial. Outra alternativa é criar uma função de dissimilaridade, que possibilite definir a distância entre dois conjuntos de características, o que permite indexar a base utilizando um método de acesso métrico.

A consulta e recuperação estão baseadas na similaridade semântica entre as imagens, sendo que apenas imagens do mesmo tipo devem ser pesquisadas. Por exemplo, dada uma imagem de abdômen de uma classe, outras imagens desse órgão devem ser recuperadas e exibidas como resposta ao usuário.

A análise da similaridade de dados multidimensionais é conseguida através de funções de distâncias que são a chave para recuperação de imagens por conteúdo (ZHANG; LU, 2003) e algoritmos de agrupamento. No caso de dados adimensionais como palavras e imagens utiliza-se o conceito de espaço métrico que pode ser definido por $\{P, d()\}$, onde P é o conjunto de elementos do domínio e d é a distância entre os elementos (FIGUEIREDO, 2005).

Dessa forma, sejam dois objetos S e Q pertencentes a um mesmo domínio, a distância (ou dissimilaridade) entre os dois objetos é denotada por $d(S, Q)$. Se vetores de características de igual tamanho representam os dois objetos, a distância $d()$ poderá ser a Distância Euclidiana entre eles, conforme equação 2.3:

$$d(S, Q) \equiv \left(\sum_{i=1} (S[i] - Q[i])^2 \right)^{1/2} \quad (2.3)$$

Onde, S e Q são os objetos, $S[i]$ e $Q[i]$ correspondem ao valor de i -ésima dimensão de S e Q respectivamente (CASTAÑÓN, 2003).

Toda função de distância no espaço métrico deve obedecer às seguintes propriedades (TRAINA; TRAINA JR, 2005):

Simetria $\rightarrow d(x, y) = d(y, x)$

Não negatividade $\rightarrow 0 < d(x, y) < \infty$ se $x \neq y$ e $d(x, x) = 0$

Desigualdade triangular $\rightarrow d(x, y) \leq d(x, z) + d(z, y)$

A escolha da função de distância adequada para o domínio dos objetos é de extrema importância. No entanto, não existem métodos definidos, e a função é identificada por meio de heurísticas dependentes das características dos dados. Para espaços vetoriais de baixas dimensões as mais usadas são: L_1 ou Manhattan ou city-block, L_2 ou Euclidiana, L_∞ ou Chebychev. No entanto, essas distâncias são mais suscetíveis ao aumento da dimensionalidade. Assim, para dados que possuem alta dimensionalidade, a distância Euclidiana, por exemplo, pode não ser a mais adequada, pois nesse caso a distância de um ponto até seu vizinho mais próximo ou mais distante tende a ser muito similar e quase insignificante. Funções fracionárias como a Mahalanobis, podem ser usadas então, pois há estudos que indicam que elas são mais adequadas para identificar agrupamentos em alta dimensionalidade. As funções fracionárias são parecidas com as Normas Minkowski, exceto que o valor do expoente p é positivo, mas menor que um (FRANCOIS; WERTZ; VERLEYSEN, 2005).

A questão principal é *qual distância usar?* Considerando tal indagação e os inúmeros trabalhos existentes na literatura que analisam a função de distância mais adequada foi desenvolvida uma análise nesse sentido para as imagens médicas estudadas no presente trabalho, cujos resultados serão detalhados na seção 6.8.

A Distância Euclidiana é uma métrica utilizada para comparar os desvios individualizados e identificar o comportamento mais próximo entre eles, ou seja, a menor distância, sendo que as observações serão agregadas de acordo com essas distâncias. A distância do Cosseno computa a distância em direção, independente do tamanho do vetor, a distância é dada pelo ângulo entre dois vetores. Essas medidas de distâncias somente levam

em conta a correspondência de cada dimensão e não fazem uso da informação através das dimensões. Já distâncias quadráticas consideram essa informação (ZHANG; LU, 2003). A distância Mahalanobis, por exemplo, usa a covariância de cada coordenada no conjunto de dados. Ela utiliza os desvios de cada valor observado para um único ponto, o centróide e ressalta a variabilidade através da matriz de covariância, agregando grupos de menor variância em contraposição aos de expressiva variabilidade.

Analisar a distribuição dos dados também pode auxiliar na escolha da medida de distância mais adequada. Segundo Yu *et al.* (2006), a distância Euclidiana (soma das diferenças dos quadrados ou $L2$) é justificada quando o conjunto de características é uma distribuição Gaussiana. Já o uso da distância City-block (soma das diferenças absolutas ou $L1$) pode ser empregada quando há uma distribuição exponencial. Muitos trabalhos assumem que a distribuição é Gaussiana ($L2$), Exponencial ($L1$) ou Cauchy, porém há muitas outras distribuições. Yu *et al.* (2006) propõe usar um critério baseado na *Maximum Likelihood Theory* (Máxima Verossimilhança) para encontrar a métrica ideal para cada modelo de distribuição. Considerando esse critério tem-se que a métrica $L2$ corresponde a média aritmética enquanto que a métrica $L1$ corresponde a mediana. Esse trabalho investiga uma nova métrica sem considerar qualquer tipo de distribuição para o conjunto de dados e a compara com as mais populares.

Vários outros trabalhos analisam o desempenho das métricas para recuperação de imagens. Em (KOKARE; CHATTERJI; BISWAS, 2003) nove métricas são analisadas para recuperação de imagens de textura: Manhattan ($L1$), *Weighted-Mean -Variance* (WMV), Euclidiana ($L2$), Chebychev (Lm), Mahalanobis, Canberra, Bray- Curtis, Squared Chord e Squared Chi-Squared. As imagens de textura são derivadas do álbum de Brodatz², cujas características foram extraídas usando *Wavelet* de Gabor. Para os vetores de características foi

² Brodatz é um álbum público de imagens de textura.

considerado a média e o desvio padrão de cada imagem filtrada. Em seu estudo as métricas Canberra e Bray-Curtis apresentaram melhor desempenho quando comparadas as tradicionais Euclidiana e Mahalanobis. Já Lui *et al.* (2008) vão além e avalia o desempenho de 14 métricas para recuperação de imagens.

Em François, Wertz, Verleysen (2005) as métricas Minkowski foram o foco do estudo, a qual tem sido usada com sucesso quando a distribuição dos dados não é Gaussiana. As normas de Minkowski (também chamadas de Normas L_p) são uma família de normas parametrizadas pelo seu expoente ($1 \leq p \leq \infty$). Quando $p = 2$, tem-se a norma Euclidiana, quando $p = 1$, induz-se a métrica Manhattan, o limite para $p \rightarrow \infty$ induz-se a métrica Chebychev, conforme ilustra a figura 2.8. O artigo também analisa normas fracionárias, as quais embora não possam ser chamadas de normas, pois em geral a desigualdade triangular não é assegurada, ainda assim, são usadas nas buscas pelo vizinho mais próximo. Como os dados envolvidos no estudo contém ruído parte-se da tese que essas métricas funcionam melhor do que as métricas tradicionais.

Figura 2.8: Métrica Minkowski (AKLEMAN; JIANER, 1999).

Qiao *et al.* (2005) fazem uma comparação entre a distância Canberra e a City-block normalizada para recuperar imagens de textura extraídas do álbum de Brodatz, considerando vetores de características contendo média e desvio padrão calculados após a decomposição das imagens com a *Wavelet Spline*. Em seus testes a City-block apresentou melhores

resultados, o mesmo ocorre no estudo desenvolvido por Zhang e Lu (2003) onde a distância City-block apresentou desempenho superior as demais distâncias, inclusive a Euclidiana.

Seguindo essa linha de pesquisa de analisar qual a melhor medida de distância para os dados estudados e avaliar a necessidade de normalizar ou uniformizar as características extraídas desses dados, muitos outros artigos podem ser encontrados na literatura.

2.9 Indexação

Transformando as características em um vetor, os dados podem ser diretamente processados usando estruturas de índices para espaços métricos, onde as estruturas são organizadas com base nas distâncias métricas.

A análise do comportamento dos dados é importante para a escolha da função de distância. É necessário também utilizar algum método de acesso que organize os dados e facilite seu armazenamento. Dados podem ser armazenados em SGBDs (Sistemas Gerenciadores de Banco de Dados), que conseguem armazenar grande quantidade de dados e fornecem respostas rápidas para a recuperação dos mesmos. Nesse ponto, o método de acesso vinculado às estruturas de indexação é que define a velocidade de consulta às informações.

Alguns métodos têm seu desempenho deteriorado quando se trata de inclusão de dados. Bons métodos de acesso permitem alcançar dados com o menor número possível de acessos no momento da consulta (STASIU, 2003).

Métodos de acesso hierárquicos são muito usados em geral, pois dependendo do tipo de árvore, um nó pode possuir uma ou mais ligações para nós inferiores. Outro aspecto importante refere-se a distribuição dos dados, que utiliza sempre parâmetros para determinar qual dos nós inferiores será acessado.

Dentre os métodos de acessos são as árvores binárias e balanceadas como a AVL, B-Tree e suas variações B+-Tree e B*-Tree, que tem bom desempenho para dados

unidimensionais. Porém, quando se trabalha com dados multidimensionais ou adimensionais, a relação de ordem total para efeitos de comparação (igual, maior que, menor que) no domínio não existe, como ocorre nos unidimensionais, inviabilizando a utilização desses métodos.

Para superar essa deficiência, foram criados os métodos espaciais e métricos. Os MAEs (Método de Acesso Espacial) resolvem o problema de organizar dados multidimensionais, contudo, dependem de propriedades dos elementos e se apresentam inadequados para espaços de alta dimensionalidade, além de não suportarem dados adimensionais como palavras e imagens. Os métodos MAEs existentes podem ser classificados como MAEP (Método de Acesso Espacial Pontual), que consideram os dados como pontos em um espaço e MAENP (Método de Acesso Espacial Não Pontual), que tratam os dados como regiões de cobertura que determinam a distribuição dos dados (FIGUEIREDO, 2005).

As conseqüências da alta dimensionalidade nos MAEs e o fato dos mesmos não suportarem o tratamento de dados adimensionais culminaram no desenvolvimento de Métodos de Acesso Métrico (MAM), que funcionam de forma a selecionar no conjunto de dados o(s) elemento(s) representante(s) e, a partir deles calculam as distâncias para os outros elementos, ou seja, o parâmetro de comparação passa a ser a distância do elemento para o(s) representante(s). Dessa forma, quando um novo elemento é inserido, sua distância para cada um dos representantes é medida e dependendo do valor o elemento é posicionado em um local específico (subárvore).

Os Métodos de Acesso Métrico (MAM), organizam um amplo conjunto de dados métricos permitindo inserções, exclusões, buscas e suportam consultas por similaridade, com base nos vetores de características (ROSA *et al.*, 2002).

Dentro desse contexto, os MAMs realizam suas comparações (ou buscas) através do cálculo da similaridade entre os elementos. Portanto, em uma consulta por similaridade, o descarte (poda) de elementos é realizado utilizando a desigualdade triangular. Essa

propriedade reduz sensivelmente a quantidade de cálculos de distância, além disso, esse tipo de funcionamento permite ao método ser independente da métrica, como se a métrica funcionasse como uma caixa preta para o método de acesso (FIGUEIREDO, 2005). Os estudos desenvolvidos por Burkhard e Keller, em 1973 (BURKHARD; KELLER, 1973), podem ser considerados como as primeiras propostas de se utilizar apenas a distância como parâmetro de indexação de dados em espaços métricos.

A partir desse, vários MAMs foram desenvolvidos, dentre eles o MAM Slim-Tree (TRAINA JR. *et al.*, 2000), tem se apresentado como uma eficiente estrutura métrica. O MAM Slim-Tree é uma árvore dinâmica para organização de conjunto de dados métricos em páginas de tamanhos fixos. Ela é uma árvore balanceada e dinâmica que cresce de baixo para cima, das folhas para a raiz. Da mesma forma que em outras árvores métricas, os objetos são agrupados em páginas de disco de tamanho fixo, cada página correspondente a um nó-árvore. Os objetos são armazenados nas folhas. O intuito principal é organizar os objetos em uma estrutura hierárquica usando um elemento representante como o centro de cada região de fronteira mínima, a qual cobre os objetos em uma subárvore. A distância para um nó representativo pode ser usada combinada com a desigualdade triangular para podar uma entrada sem qualquer cálculo extra de distância. As regiões que correspondem a cada nó na Slim-Tree podem se sobrepor entre si. O aumento da sobreposição aumenta o número de caminhos a serem percorridos quando uma consulta é disparada, o que também aumenta o número de cálculos de distância para responder a consulta. A Slim-Tree foi projetada para reduzir a sobreposição entre regiões de cada nível, além de minimizar o número de acessos a disco, tornando o sistema todo mais rápido.

A Slim-Tree possui funcionamento semelhante ao método M-Tree, porém permite que a taxa de sobreposição dos nós seja medida e que a partir dessa medida a árvore seja otimizada, usando um algoritmo chamado Slim Down (FIGUEIREDO, 2005). Conhecer o

comportamento dos dados é muito importante para o uso adequado de um MAN, que visa agilizar as consultas. Um ambiente que disponibilize o uso de MANs deve possibilitar que seus diversos parâmetros sejam ajustados para atender os requisitos, ou seja, função de distância, conjunto de características, por exemplo. Uma possibilidade é permitir que o usuário selecione a melhor projeção a ser realizada no momento da consulta, tornando a utilização do contexto semântico inevitável. Devido aos objetivos estabelecidos e ao pequeno volume de imagens utilizadas, a indexação não faz parte do escopo deste trabalho.

2.10 Avaliação dos Resultados

Há várias técnicas para validar os resultados obtidos. Algumas aplicações visam buscas exatas, porém a maioria não demanda uma resposta muito precisa. Quanto ao fato das consultas gerarem resultados imprecisos, há dois conceitos importantes. Um dado é considerado **falso negativo** se deveria estar no conjunto de respostas, mas o processo de busca o descartou. Por outro lado, um dado **falso positivo** é aquele que deveria ser descartado, mas foi incluído na resposta.

Outra possibilidade de validação é utilizar medidas estatísticas para avaliar os algoritmos desenvolvidos, como por exemplo, sensibilidade e especificidade (EAKINS; GRAHAM, 1999).

$$\text{sensibilidade} = \frac{\text{itens_positivos_classificados_como_positivos}}{\text{todos_os_itens_positivos}}$$

$$\text{especificidade} = \frac{\text{itens_negativos_classificados_como_negativos}}{\text{todos_os_itens_negativos}}$$

No entanto, a técnica de avaliação mais comum em sistemas CBIR são os gráficos *Precision x Recall* (MÜLLER *et al.*, 2004).

Também é ideal que um especialista na área valide as respostas fornecidas pelas técnicas de recuperação implementadas, pois o conhecimento do profissional pode garantir que os resultados obtidos estão próximos ao esperado na prática.

2.10.1 Gráficos *Recall* x *Precision*

Os gráficos *Recall* x *Precision* (BAEZA-YATES, RIBEIRO-NETO, 1999), constituem uma abordagem simples e bastante difundida para avaliar os resultados obtidos na recuperação das imagens médicas.

Nessa abordagem, dado um conjunto de dados, sobre o qual serão feitas as consultas, alguns valores (figura 2.9) são definidos como TR, que corresponde ao número total de objetos Relevantes, ou seja, o número de imagens pertencentes à mesma classe que a imagem de consulta, TRO, que corresponde ao número total de objetos relevantes recuperados na consulta e TO, que corresponde ao número total de objetos recuperados na consulta, independente da classe a que pertencem (TRAINA; TRAINA JR, 2005).

Figura 2.9: Técnica de validação do método aplicado: *Recall* x *Precision*.

A precisão (*precision*) representa a porção de imagens recuperadas que são relevantes à consulta. Já a revocação (*recall*) corresponde a porção de imagens relevantes que foram recuperadas. Na prática, uma curva mais próxima do alto do gráfico representa maior eficácia na recuperação (BALAN *et al.*, 2004), conforme gráfico exibido na figura 2.10.

Figura 2.10: Exemplo de Gráfico *Recall x Precision*.

2.10.2 Matrizes de Confusão (*Confusion Matrix*)

Outro método comum para avaliar as saídas geradas por um sistema classificador são as matrizes de confusão. As matrizes de confusão tem por objetivo mostrar a quantidade de amostras classificadas corretamente para cada classe, portanto mede a eficiência. Através dela também pode ser verificado, no caso de percentual de classificação incorreta, com qual classe houve a confusão. A média da diagonal dessa matriz gera uma medida da eficiência do algoritmo aplicado.

Ela é uma ferramenta de visualização onde cada coluna da matriz representa a instância em uma classe pré-definida, enquanto que cada linha representa as instâncias em uma classe atual. Um dos benefícios da matriz de confusão é que é possível de maneira rápida e fácil identificar se o sistema está confundindo as classes ou está separando-as corretamente.

2.11 Considerações Finais

Neste capítulo foram apresentados os principais pontos a serem observados em um sistema de Recuperação de Imagens por Conteúdo. Além dos conceitos gerais, foi comentado sobre as principais técnicas para extração de características considerando-se atributos classificados como primitivas da imagem (cor, textura e forma). No contexto das imagens médicas o atributo textura é fundamental e a Transformada *Wavelet*, a qual será apresentada no próximo capítulo, tem apresentado resultados importantes para a geração do vetor de características.

Alguns desafios devem ser superados como os efeitos da alta dimensionalidade e a redução do *gap* semântico. A escolha de uma função de distância adequada aliada a um bom método de indexação, pode apresentar resultados mais eficientes em termos de precisão e desempenho das consultas.

Transformada *Wavelet* e *Wavelet Packet*

3.1 Considerações Iniciais

As *Wavelets* destacam-se por conseguirem representar uma imagem com uma quantidade mínima de valores, considerando uma escala menor, possibilitando a montagem de um vetor de características “enxuto” para sua representação.

Por se tratar de um estudo envolvendo processamento digital será dado maior ênfase às *Wavelets* Discretas e, pela sua simplicidade para implementação e baixo custo computacional, uma atenção especial será atribuída à *Wavelet* de Haar que, apesar de não ser suave, é amplamente usada em muitas aplicações, especialmente em processamento de imagens digitais (LIMA, 2002).

As operações envolvendo a Transformada *Wavelet* são reversíveis, significando que a qualquer momento pode-se reverter o processo de decomposição e reconstruir a imagem inicial. Porém, esse tópico particular está fora do escopo do presente trabalho.

3.2 Evolução das *Wavelets*

As *Wavelets* são funções que satisfazem certos requisitos matemáticos e são usadas na representação de dados ou de outras funções. Elas apresentam os dados contidos em diferentes componentes de frequência e estudam cada componente com uma resolução relacionada a sua escala (SILVA; EYNG, 2002). O objetivo fundamental por trás das *Wavelets* é analisar de acordo com a escala (GRAPS, 1995).

A idéia de funções que utilizam o conceito de aproximação usando a superposição de funções, não é nova. Sua origem baseia-se no trabalho de Joseph Fourier, que no século XIX descobriu que poderia utilizar senos e co-senos para representar outras funções. A diferença em relação a Transformada de Fourier é que a análise *Wavelet* não é feita segundo a frequência, mas sim segundo a escala. Os algoritmos *Wavelet* processam dados em diferentes escalas e resoluções, permitindo que sejam vistos tanto o global quanto os detalhes (SILVA; EYNG, 2002). Isso torna as *Wavelets* úteis para inúmeras aplicações (GRAPS, 1995).

Segundo Lima (2002), apesar da funcionalidade da Transformada de Fourier (*Fourier Transform* – FT), especialmente no que diz respeito à obtenção da análise espectral de um sinal estacionário, ilustrado na figura 3.1, cuja frequência não varia no tempo, existem muitas falhas nessa técnica, o que a torna inadequada em algumas aplicações. Uma dessas falhas é a incapacidade da Transformada de Fourier em representar funções que têm componentes não periódicos. Outra deficiência é a incapacidade em fornecer informações sobre a dependência do tempo de um sinal, visto que ela faz a média sobre todo o tempo de duração do sinal. Além disso, as funções senos e co-senos usadas na análise de Fourier não são locais e, portanto, apresentam desempenho muito pobre na aproximação de sinais muito localizados.

Figura 3.1: Sinal Estacionário.

A informação de tempo é importante, porque normalmente existe uma correlação direta entre a frequência característica de um dado segmento do sinal e a duração temporal desse segmento. Os segmentos com pequenas frequências tendem a durar por um intervalo de tempo maior, enquanto os segmentos do sinal com frequências altas ocorrem, em geral, durante um pequeno intervalo de tempo. “Os sinais da fala humana são exemplos típicos: as vogais têm frequências médias relativamente baixas e duram bastante, enquanto que as consoantes contêm um espectro extenso de frequências, mas são breves” (LIMA, 2002). Nesses casos, a análise de Fourier padrão é inadequada, pois ela perde toda a informação sobre a localização temporal de uma dada componente da frequência. Além disso, a análise de Fourier é instável em relação à perturbação, devido ao seu caráter global. Por exemplo, se for adicionado um termo extra, com uma amplitude muito pequena, o sinal será modificado ligeiramente e o espectro de Fourier será completamente perturbado (LIMA, 2002).

Em muitas aplicações práticas é importante obter a informação de localização da componente de frequência no tempo. Considere-se, por exemplo, um exame de Eletro-Encefalograma. Nesses exames, conhecer a latência de um potencial evento relacionado é fundamental, pois é a resposta do cérebro a um estímulo específico e a latência dessa resposta é a quantidade de tempo decorrida entre o início do estímulo e a resposta do cérebro (POLIKAR, 2001).

Sintetizando, pode-se dizer que a Transformada de Fourier gera uma representação Amplitude x Frequência do sinal, uma vez que ela fornece exclusivamente quais componentes

de frequência estão presentes no sinal. Esta informação é independente de onde esses componentes aparecem no tempo, ou seja, ela diz simplesmente se uma componente de frequência existe ou não. Sua relação com o domínio temporal é inexistente, o que a torna inadequada para sinais cujas frequências variam no tempo, os chamados sinais não-estacionários como ilustrado na figura 3.2 (VALENS, 1999; OLIVEIRA, 2003).

Figura 3.2: Sinal não-estacionário.

Por todos esses motivos, os analistas de sinais voltaram-se para uma representação Tempo x Frequência. A idéia é que são necessários dois parâmetros: um caracteriza a frequência e o outro, indica a posição no sinal (LIMA, 2002).

Assim, surgiu uma versão revisada da FT, conhecida como Transformada de Fourier Janelada (*Windowed Fourier Transform* – WFT ou *Short Time Fourier Transform* – STFT), a qual considera um sinal não-estacionário, como sendo composto por porções de sinais estacionários. Visualiza-se o sinal não-estacionário de janelas limitadas e aplica-se a FT nas porções, conforme ilustrado na figura 3.3.

Figura 3.3: *Short Time Fourier Transform* (adaptado de MATHWORKS, 2004).

Na STFT o sinal é subdividido em segmentos pequenos o suficiente para serem considerados como estacionários. Para esse propósito uma função janela é escolhida, cuja largura deve ser igual ao segmento do sinal onde é assumido como estacionário. Existem diversas escolhas para a janela, sendo a mais comum uma janela Gaussiana. Essa função janela é localizada inicialmente em $t = 0$ e multiplicada pelo sinal; em seguida, obtêm-se a FT dessa porção de sinal e desloca-se a função janela, repetindo-se o processo até o final do sinal. Dessa forma, uma representação Tempo x Freqüência será obtida, fornecendo a informação de quais componentes de freqüência estão presentes no sinal e onde elas estão localizadas no tempo conforme ilustrado na figura 3.4. É importante notar que uma vez escolhida uma janela, a resolução tempo-freqüência é fixa para todo o plano, pois é usada a mesma janela para todas as freqüências (SOARES, 1997; OLIVEIRA, 2003).

Figura 3.4: Representação Tempo x Frequência da análise do sinal da figura 3.2 utilizando a STFT (adaptado de POLIKAR, 2001).

A deficiência da STFT reside no chamado Princípio da Incerteza de Heisenberg, cuja formulação original afirma que o “*momentum*” e a posição de uma partícula em movimento não podem ser conhecidos simultaneamente. Essa teoria aplicada a sinais, indica que as informações de tempo e frequência para um ponto exato no plano Tempo x Frequência, não podem ser simultaneamente conhecidas, ou seja, não se pode saber qual componente ocorre em um determinado instante de tempo. Esse fato gera um problema de resolução, pois quanto mais precisão exige-se no tempo, menor será a precisão na frequência.

Este foi o principal motivo dos pesquisadores terem substituído a STFT pela Transformada *Wavelet* (TW), pois a STFT fornece uma resolução fixa para todos os tempos, enquanto que a Transformada *Wavelet* fornece uma resolução variável. Altas frequências são melhor resolvidas no tempo, isto é, podem ser melhor localizadas no tempo do que uma componente de baixa frequência, por outro lado, baixas frequências são melhor resolvidas na

freqüência, isto é, podem ser melhor localizadas na freqüência do que componentes de alta freqüência (SOARES, 1997).

O problema da resolução está relacionado a largura da função janela usada, o que é conhecido como suporte da janela. Se a função janela é limitada, isso é conhecido como suporte compacto, terminologia freqüentemente usada na teoria de *Wavelets*.

Na FT tem-se uma resolução de freqüência perfeita, pois o comprimento da janela usada é infinito, mas não se tem informação de tempo. Na STFT, a largura da função janela é fixa e se for usada uma janela estreita, ter-se-á boa resolução de tempo, porém resolução de freqüência mais pobre. Se for usada uma janela expandida, ter-se-á boa resolução de freqüência, porém resolução de tempo mais pobre. Pode-se dizer que a precisão relacionada a informação de quando e em qual freqüência ocorreu um evento no sinal é limitada pelo tamanho da janela (PARRAGA, 2002).

Assim, a TW foi desenvolvida para superar o problema de resolução da STFT, eliminando o dilema de qual tamanho de janela usar, pois ela permite analisar um sinal usando a abordagem chamada de Análise Multiresolução (*Multiresolution Analysis* – MRA), fornecendo boa resolução de tempo, para altas freqüências, com janelas mais estreitas e boa resolução de freqüência, para baixas freqüências, com janelas expandidas (DAUBECHIE, 1992). No entanto, a área das janelas permanece inalterada, conforme observado na figura 3.5.

Figura 3.5: (a) Janelas usadas na TW. (b) Janelas usadas na STFT.

Embora a análise da TW seja similar a análise da STFT, no sentido de que o sinal é multiplicado por uma função, há importantes diferenças a serem destacadas. A largura da função janela muda conforme a transformada é aplicada. Ela possui propriedades de localização no tempo e na frequência, por meio de translações e dilatações, respectivamente, de uma função base intitulada *Wavelet*-mãe, a qual está descrita na seção 3.4.

A análise temporal é realizada com uma versão de alta-frequência da *Wavelet*-mãe, enquanto que a análise de frequência é realizada por uma versão dilatada (baixa frequência) da mesma. A TW não possui um único conjunto de funções base, como acontece com a FT, que utiliza apenas as funções senos e co-senos; seu conjunto de funções base é infinito. As funções individuais *Wavelets* estão localizadas no tempo, possibilitando inúmeras aplicações e vantagens sobre o tradicional método de Fourier e sua derivada STFT, principalmente em situações onde há descontinuidades ou picos no sinal (LIMA, 2004).

Por causa de suas propriedades únicas, as *Wavelets* se desenvolveram nos campos da Matemática, Engenharia, Física Quântica. Atualmente são usadas em compressão de dados (por exemplo, o padrão *JPEG2000*³ *Still Image Compression* e o padrão do FBI para armazenamento de impressões digitais – *FBI Wavelet/Scalar Quantization Fingerprint Image Compression Standard*⁴), detecção de características em imagens, remoção de ruídos, reconhecimento de padrões, acústica, astronomia, engenharia nuclear, neurofisiologia, ótica, música, fractais, processamento de geometria digital, na solução de vários problemas de física, biologia, medicina, previsão de terremotos, aplicações matemáticas puras, como na resolução de equações diferenciais parciais, singularidades ou oscilações locais de funções, e muitas outras (LIMA, 2004; OLIVEIRA, 2003).

³ <http://www.jpeg2000.org>

⁴ <http://www.ccs3.lanl.gov/~brislawn/FBI/FBI.html>

3.3 Histórico

As Transformadas *Wavelets* foram introduzidas pela Escola Francesa (Morlet, Grossmann, Meyer, Battle, Lemarié, Cohen, Mallat, Coifman, Rioul, etc.), originária de estudos de curta duração associada a pacotes de ondas acústicas sísmicas (OLIVEIRA, 2003). Daubechie afirma que “em resumo o desenvolvimento das *Wavelets* é um exemplo de idéias de diferentes áreas juntadas para formar um todo que é maior do que a soma das partes” (DAUBECHIE, 1996).

A primeira menção às *Wavelets* apareceu no apêndice da tese de Alfred Haar, em 1909. Uma das propriedades da *Wavelet* de Haar é que ela tem suporte compacto, o que significa que ela tende a zero fora de um intervalo finito (LIMA, 2002 apud HAAR, 1910). As *Wavelets* de Haar ficaram no anonimato por muitos anos até que na década de 30, vários grupos trabalhando independentemente, pesquisaram a representação de funções usando uma base variando a escala. Naquela ocasião, usando a base da *Wavelet* de Haar, Paul Levy investigou o movimento Browniano. Ele mostrou que as funções da base de Haar eram melhores do que as da base de Fourier para estudar os pequenos e complicados detalhes do movimento Browniano. Outra pesquisa desenvolvida nessa época, por Littlewood, Paley e Stein usando *Wavelets*, envolvia a computação da energia de uma função $f(x)$. Eles perceberam que o cálculo produzia resultados diferentes se a energia estava concentrada em torno de poucos pontos ou distribuída sobre um grande intervalo, o que indicava que a energia podia não estar sendo conservada, chamando a atenção dos cientistas. Então, os pesquisadores descobriram uma função que podia variar em escala e conservar a energia. Esse trabalho foi relevante para as pesquisas de David Marr, no início da década de 80, que visava desenvolver um algoritmo para processamento de imagens (LIMA, 2002).

Por um período muito longo, as *Wavelets* de Haar continuaram a ser a única base ortonormal de *Wavelets* conhecida, até sua teoria ser efetivamente formalizada, na década de

80. O termo “*Wavelets*” é atribuído a Norman Ricker (1940) em seu trabalho sobre sismologia, mas foi introduzido por J. Morlet e sua base matemática formalizada pelo físico teórico A. Grossmann. Os dados sísmicos estudados por Morlet (GROSSMAN; MORLET, 1984) exibiam conteúdos de frequências que mudavam rapidamente ao longo do tempo, além disso, mostraram que qualquer tipo de sinal pode ser analisado em termos de escala e translações de uma simples função *Wavelet*-mãe.

Em 1985, Stephane Mallat deu às *Wavelets* um grande impulso através de suas pesquisas e inspirado nos resultados de Mallat, Yves Meyer construiu a primeira *Wavelet* não-trivial (suave). Ao contrário das *Wavelets* de Haar, as *Wavelets* de Meyer são continuamente diferenciáveis; contudo, elas não têm suporte compacto. Em 1988, Mallat e Meyer desenvolveram a teoria denominada Análise Multiresolução (*Multiresolution Analysis* – MRA), a qual pode ser vista simplesmente como uma forma de algoritmos piramidais. Poucos anos mais tarde, Ingrid Daubechies usou os trabalhos de Mallat para construir um conjunto de bases ortonormais de *Wavelets* suaves, com suportes compactos. Os trabalhos de Daubechies são os alicerces das aplicações atuais de *Wavelets* (LIMA, 2002; GRAPS, 1995).

3.4 Transformada *Wavelet*

O termo *Wavelet* significa pequena onda. Pequena, porque se refere ao fato da função janela ter largura finita, ou seja, suporte compacto. Onda, porque se refere a condição de que essa função é oscilatória.

As Transformadas *Wavelets* podem ser vistas como mecanismos para dissecar ou quebrar sinais nas suas partes constituintes, permitindo analisar os dados em diferentes domínios de frequências com a resolução de cada componente amarrada a sua escala. Funções que estão contidas em regiões finitas podem ser usadas, tornando-as convenientes na aproximação de dados com descontinuidades agudas. *Wavelets* constituem uma ferramenta

matemática para decompor funções hierarquicamente, permitindo que uma função seja descrita de forma mais grosseira, gerando uma visão global, ou enfatizando detalhes mais finos (LIMA, 2002). Elas permitem recuperar os detalhes que seriam perdidos com a diminuição de resolução quando se passa de uma escala para a escala seguinte, ou seja, elas medem as flutuações entre duas escalas consecutivas (LIMA, 2004).

As *Wavelets* são usadas nos casos em que o resultado da análise de um problema particular deve conter não somente a relação de suas frequências típicas (escalas), mas também o conhecimento das coordenadas locais onde essas propriedades são importantes. Portanto, análise e processamento de diferentes classes de sinais não-estacionários (no tempo) ou não-homogêneos (no espaço) constituem o principal campo de aplicações da análise de *Wavelets*. (LIMA, 2002).

Para isto, a análise *Wavelet* adota uma função protótipo ψ , chamada de *Wavelet*-mãe, ou seja, uma função com diferentes regiões de suporte que são usadas no processo de transformação. Essa função possui dois parâmetros representando a translação (τ) e a escala (ϕ). A translação é a localização da janela no decorrer do sinal e está relacionada com a informação de tempo. A escala, termo este, que substitui o termo frequência na análise *Wavelet*, é inversamente proporcional a frequência. Seu conceito pode ser empregado de forma semelhante ao uso em mapas, onde baixas escalas permitem uma visão detalhada, ou seja, visualiza-se as altas frequências e altas escalas permitem uma visão global, referindo-se às baixas frequências (DAUBECHIE, 1992). Fazendo uma simples analogia, é como se variando a escala fosse possível visualizar a floresta em uma escala mais alta e suas árvores em uma escala mais baixa (POLIKAR, 2001). Com relação a representação gerada pela análise *Wavelet*, exemplificado na figura 3.6, normalmente usa-se os termos Tempo x Escala ou Translação x Escala, uma vez que o termo frequência especificamente é reservado para a FT e STFT (VALENS, 1999).

Figura 3.6: Representação Translação x Escala da análise de um sinal, utilizando a Transformada *Wavelet* (adaptado de POLIKAR, 2001).

Para calcular os coeficientes na análise *Wavelet*, versões comprimidas ou dilatadas e deslocadas da *Wavelet*-mãe são usadas, distinguindo características globais e locais de todo o objeto de estudo. As *Wavelets* mais usadas formam um sistema ortonormal de funções com suporte compacto (anulam-se completamente fora do intervalo finito de tempo). Diz-se que uma função f tem suporte compacto, se existe um intervalo fechado e limitado, fora do qual $f(x) = 0$ (LIMA, 2003). Em síntese pode-se dizer que uma *Wavelet* é dita ter suporte compacto se a maioria da energia dessa *wavelet* está restrita a um intervalo finito, ou seja, se a função é exatamente zero fora desse intervalo.

Em *Wavelets* tem-se um conjunto de funções base, usadas para análise e reconstrução, cuja conceituação parte da abordagem matemática usada em vetores, onde um vetor bi-dimensional (x, y) é uma combinação dos vetores $(1, 0)$ e $(0, 1)$, os quais são os vetores base para (x, y) , tal que multiplicando x por $(1, 0)$, tem-se $(x, 0)$ e multiplicando y por $(0, 1)$,

obtem-se $(0, y)$, cuja soma é igual a (x, y) . A melhor base de vetores é aquela cujos vetores são perpendiculares, ou ortogonais, sendo que $(1,0)$ e $(0,1)$ satisfazem esse critério, neste caso (GRAPS, 1995). Uma base de um vetor V é um conjunto de vetores linearmente independentes, tal que qualquer vetor v em V pode ser escrito como uma combinação linear desses vetores base. Esses conceitos podem ser generalizados para funções, substituindo os vetores base b_k pela função base ϕ_k e o vetor v pela função $f(t)$, conforme equação 3.1:

$$v = \sum_k V^k b_k \rightarrow f(t) = \sum_k \mu_k \phi_k(t) \quad (3.1)$$

Escolhendo-se a combinação apropriada de funções, cujo produto interno é igual a zero, obtém-se uma base **ortogonal**. Dois vetores v e w são ditos ortogonais se o produto interno deles é igual a zero. Similarmente, duas funções são ditas ortogonais se o produto interno delas é igual a zero:

Assim, na TW as funções ψ (wavelet) e ϕ (escala) devem ser ortogonais entre si. No espaço vetorial, se existe uma base ortogonal composta de vetores normalizados, a base é chamada **ortonormal**.

Bases ortonormais podem não ser válidas para todo tipo de aplicação, nesse caso, uma versão generalizada, definida como **base bi-ortogonal**, pode ser usada, onde o termo bi-ortogonal refere-se a duas bases diferentes, que são ortogonais entre si, mas cada uma não forma um conjunto ortogonal (DAUBECHIE, 1992).

Necessariamente, toda *Wavelet*-mãe satisfaz $\int_{-\infty}^{\infty} \psi(x) dx = 0$, ou seja, ela tem o momento de ordem zero nulo $M_0 = 0$, que corresponde a condição de admissibilidade. Frequentemente as *Wavelets* são classificadas em famílias de acordo com o número de momentos nulos (*vanishing moments*), onde $M_n = \int_{-\infty}^{\infty} t^n \psi(t) dt$ é o momento de ordem n da *Wavelet*-mãe. Uma *Wavelet* é dita ser N momentos nulos se $M_n = \Psi^{(n)}(w)|_{w=0} = \Psi^{(n)}(0)$. Sob

o ponto de vista prático, quanto mais momentos nulos uma *Wavelet* possuir, menores serão os coeficientes de *Wavelets* correspondentes às partes de f que são suaves, ou seja, os coeficientes de *Wavelets* serão apreciáveis onde f não for suave, o que permite usar *Wavelets* para detectar singularidades de f . Pode-se dizer que o cálculo dos coeficientes *Wavelets* refere-se à proximidade do sinal para a *Wavelet* na escala atual. Em contrapartida, uma função escala ϕ , satisfaz necessariamente $\int_{-\infty}^{\infty} \phi(x)dx \neq 0$. A vantagem de uma *Wavelet* ψ ter vários momentos nulos conduz a uma alta compressividade, porque os coeficientes *Wavelets* das escalas mais finas de uma função são essencialmente nulos onde a função é suave. Em alguns casos, também é desejável que a função escala tenha momentos nulos.

Em 1989, Coifman sugeriu a Daubechies a construção de uma base ortogonal de *Wavelets* onde não somente ψ , como também ϕ , tivesse momentos nulos, as quais foram denominadas de *Coiflets*. A escolha de uma *Wavelet* específica seja ela discreta ou contínua, depende do sinal a ser analisado ou do problema a ser resolvido (LIMA, 2002; OLIVEIRA, 2003).

3.4.1 Transformada Wavelet Contínua

A Transformada *Wavelet* Contínua (*Continuous Wavelet Transform* – CWT) é definida como a soma sobre todos os tempos do sinal multiplicado por uma versão escalada e deslocada da *Wavelet*-mãe. Supõe-se sempre que $\psi \in L^2\Re$ (DAUBECHIE, 1992).

$$CWT_x^\psi(\tau, s) = \Psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \psi^* \left(\frac{t-\tau}{s} \right) dt \quad (3.2)$$

Na equação (3.2) $x(t)$ é o objeto de estudo, $*$ denota o conjugado complexo, τ e s são os parâmetros translação e escala respectivamente, da *Wavelet*-mãe $\psi(t)$. O resultado da

integral é multiplicado por um valor constante, para normalização da energia através das diferentes escalas (VALENS, 1999).

Ao final da Transformada *Wavelet* Contínua obtêm-se muitos coeficientes. Multiplicando cada coeficiente pela *Wavelet* escalada e deslocada apropriadamente produz-se as *Wavelets* constituintes do sinal original, conforme ilustrado pela figura 3.7 (MATHWORKS, 2004).

Figura 3.7: Sinal e as *Wavelets* constituintes de diferentes escalas e posições.

Obter os coeficientes *Wavelets* em cada escala possível requer uma grande quantidade de cálculo, tornando o trabalho muito “custoso” computacionalmente, pois na Transformada *Wavelet* Contínua, a função *wavelet* é deslocada suavemente sobre todo o domínio da função analisada, calculando a correlação entre as duas. Esse processo gera uma enorme quantidade de informação altamente redundante. Essa redundância requer significativa quantidade de tempo e recurso computacional. Dessa forma, algoritmos rápidos capazes de explorar o poder da TW são necessários. E é justamente, a existência desses algoritmos que colocam as *Wavelets* em destaque nos dias atuais.

3.4.2 Transformada *Wavelet* Discreta

A Transformada *Wavelet* Discreta (*Discrete Wavelet Transform* – DWT) escolhe um subconjunto de escala e translações sobre os quais realiza os cálculos (intervalos discretos). A Transformada *Wavelet* Discreta fornece informação suficiente tanto para análise ou

decomposição quanto para síntese ou reconstrução do sinal, com significativa redução do tempo computacional. Ela é considerada mais fácil para implementar quando comparada com a Transformada *Wavelet* Contínua (VALENS, 1999), e pode ser aplicada recursivamente sobre diferentes escalas, através de rápidos algoritmos. Quando *Wavelets* com suporte compacto são utilizadas, a Transformada *Wavelet* Discreta requer somente $O(N)$ operações, sendo mais rápida que a Transformada Rápida de Fourier (SAARBRÜCKEN; KAISERSLAUTERN, 1994).

Na Transformada *Wavelet* Discreta escalas e posições são escolhidas baseadas em potência de dois, geralmente as chamadas escalas e posições *dyadic*, conforme ilustrado na figura 3.8; então, a análise será muito mais eficiente no sentido de aumentar o desempenho do algoritmo, mantendo a exatidão (MALLAT, 1998).

Normalmente escolhe-se um fator de dois (2) para a escala, que corresponde ao eixo da frequência, e um fator de um (1) para a translação, que corresponde ao eixo do tempo, obtendo uma amostragem *dyadic* em ambos os casos (VALENS, 1999).

Figura 3.8: Localização de *Wavelets* Discretas no espaço Tempo x Escala sobre um Grid Dyadic, onde S indica escala e τ indica translação.

Dentro da Transformada *Wavelet* Discreta distinguem-se duas abordagens: sistemas redundantes discretos, chamados *frames* e o ortonormal. A segunda abordagem considera a estratégia de análise multiresolução, a qual será considerada no presente estudo.

Uma maneira eficiente de implementar esse esquema é através do uso dos filtros desenvolvidos por Mallat em 1986. Os algoritmos de Mallat são um esquema clássico conhecido pela comunidade de processamento de sinais como Análise Multiresolução (*Subband Code* ou *Two-Channel Subband Coder*) (MALLAT, 1998).

Quando Mallat trabalhou com *Wavelets* de Meyer pela primeira vez, ele estava trabalhando com análise de imagens, onde a idéia de se estudar imagens em várias escalas simultaneamente era popular. Isso o estimulou a ver bases ortonormais de *Wavelets* como uma ferramenta para descrever matematicamente o “incremento na informação” necessário para se ir de uma aproximação grosseira para uma aproximação com maior resolução.

Formulada em 1986 por Mallat e Meyer, fornece um *framework* natural para entendimento das bases *Wavelet* e para a construção de novos exemplos (DAUBECHIE, 1992). A análise de multiresolução, inicialmente visando tornar-se uma ferramenta para compressão de dados (SAARBRÜCKEN; KAISERSLAUTERN, 1994), é uma seqüência, $\{V_j\}_{j \in \mathbb{Z}}$ de espaços fechados de $L^2(\mathbb{R})$, representando os sucessivos níveis de resoluções. Todos os espaços estão relacionados por escala a um mesmo espaço, e quanto maior j , mais fina é a resolução obtida (LIMA, 2002). Segundo Daubechie (1992), a idéia básica da MRA consiste de uma seqüência de sucessivos espaços V_j de aproximação, mais precisamente subespaços fechados que satisfazem a:

$$\dots V_2 \subset V_1 \subset V_0 \subset V_{-1} \subset V_{-2} \subset \dots \quad (3.3)$$

$$\text{com, } \overline{\bigcup_{j \in \mathbb{Z}} V_j} = L^2(\mathbb{R}) \quad (3.4)$$

$$\bigcap_{j \in \mathbb{Z}} V_j = \{0\} \quad (3.5)$$

Mas, o aspecto multiresolução é uma consequência de requisitos adicionais, onde todos os espaços são versões escaladas do espaço V_0 central, sendo então necessária uma função escala ($\phi \in V_0$) e a invariância de V_0 sob uma translação inteira. Para todo $j \in \mathbb{Z}$ define W_j como sendo o complemento ortogonal de V_j em V_{j+1} , tem-se: $V_{j+1} = V_j \oplus W_j$, sendo que o espaço W_j herda as propriedades de escala de V_j (DAUBECHIE, 1992).

Na MRA um algoritmo piramidal baseado em convoluções com um par de filtros digitais (*Quadrature Mirror Filter* – QMF) extrai a diferença de informação entre a aproximação do sinal na resolução 2^{j+1} e 2^j (MALLAT, 1989). Esses algoritmos de filtragem práticos produzem a Transformada Wavelet Rápida (*Fast Wavelet Transform* – FWT). Pode-se compará-los a uma caixa por onde o sinal passa e é convertido em coeficientes *Wavelets* de detalhe e aproximação, conforme representado na figura 3.9 (MATHWORKS, 2004).

Figura 3.9: Decomposição *Wavelet* discreta (PARRAGA, 2002 pp. 51).

O par de filtros digitais utilizados na Transformada *Wavelet* Discreta em multiresolução tem como característica filtrar e decimar o sinal, respectivamente. Decimação é uma operação que diminui a taxa de amostragem do sinal. Em outras palavras, significa eliminar dados ou pontos intercalados.

A resolução, que é uma medida da quantidade de detalhes e está relacionada a quantidade de informação, é afetada pelas operações de filtragem.

A escala, por sua vez, é modificada pelas operações de aumento da taxa de amostragem (*Upsampling*) e pelas operações de redução da taxa de amostragem (*Downsampling* ou *Subsampling*) (POLIKAR, 2001). Efetuar um *Subsampling* por um fator n , reduz o número de amostras n vezes. Decimar um sinal pelo fator 2, significa que a cada 2 pontos, um é eliminado (sub-amostrado por um fator de 2), obtendo-se metade do sinal original. No processo de decimação, aumenta-se o tamanho do período de amostragem do sinal, e conseqüentemente, diminui-se a taxa de amostragem (PARRAGA, 2002).

Esse processo de filtrar e amostrar pode ser repetido várias vezes. A cada nível de filtragem e *subsampling* tem-se metade do número de amostras e conseqüentemente metade da resolução de tempo, uma vez que agora somente metade do número de amostras caracteriza o sinal. Entretanto, tem-se o dobro de resolução de frequência, uma vez que após o *subsampling* metade do número de amostras torna-se redundante. A figura 3.10 ilustra esse processo, onde $x[n]$ é o sinal a ser decomposto e $h[n]$ e $g[n]$ são os filtros passa-alta e passa-baixa respectivamente.

Figura 3.10: Decomposição e subsampling do sinal (adaptado de POLIKAR, 2001).

Mallat (1989) afirma que a MRA é muito efetiva para analisar a informação contida na imagem, podendo ser aplicada com sucesso para discriminação de textura, que é um dos objetivos desse trabalho. A função *Wavelet* $\psi(t)$ está relacionada a um filtro passa-alta, o qual produz os coeficientes de detalhes da imagem. Há uma função adicional que está relacionada ao filtro passa-baixa, chamada de função de escalonamento $\phi(t)$ (*scaling functions*), que produz os coeficientes de aproximação da imagem na decomposição *Wavelet* (PARRAGA, 2002). No caso discreto os filtros passa-alta analisam as altas frequências e os filtros passa-baixa analisam as baixas frequências. O banco de filtros lineares usado serve para suavizar ou realçar detalhes da imagem, ou ainda minimizar efeitos de ruído. No filtro passa-baixa, as altas frequências, que correspondem às transições abruptas são atenuadas, ou seja, as informações de altas frequências são removidas, mas a escala permanece inalterada. A suavização tende a minimizar ruídos, porém pode apresentar o efeito de “borramento” da imagem. No filtro passa-alta os detalhes são realçados (bordas, linhas curvas, etc). As transições entre regiões diferentes tornam-se mais nítidas. Porém pode porventura, enfatizar o ruído existente na imagem.

A implementação pode ser introduzida como uma decomposição em subbandas, ou seja, o processo é iterativo com sucessivas decomposições nos coeficientes de aproximação. Dessa forma, obtém-se a árvore de decomposição da *Wavelet* (PARRAGA, 2002), apresentada na figura 3.11. Como essas operações são invertíveis, pode-se inverter o processo de decomposição e reconstruir a imagem inicial.

Figura 3.11: Árvore de Decomposição *Wavelet*.

Onde, S representa o sinal, A corresponde aos coeficientes de aproximação e D corresponde aos coeficientes de detalhes.

Existem várias famílias *Wavelets* dentre as quais destacam-se de forma sintética:

- **Haar:** é a primeira e a mais simples de todas. É descontínua e equivale a *Wavelet* de Daubechies de ordem 1 (db1).
- **Daubechies:** são *Wavelets* ortonormais com suporte compacto.
- **Biortogonal:** apresentam a propriedade de fase linear, que é necessária na reconstrução de sinais e imagens. Utiliza duas *Wavelets*, uma para decomposição e outra para reconstrução, o que gera propriedades interessantes.
- **Coiflets:** possuem a função *Wavelet* com $2N$ momentos iguais a zero e a função escala tem $2N-1$ momentos iguais a zero.
- **Symlets:** são *Wavelets* simétricas. Foi proposta como uma modificação da família Daubechies pela própria, possuindo características similares às desta família.
- **Morlet:** não possui função escala.
- **Mexican Hat:** também não possui função escala.
- **Meyer:** a *Wavelet* e a função escala estão definidas no domínio de frequência.

3.5 Wavelet de Haar

A *Wavelet* de Haar é a única com suporte compacto para a qual se tem uma forma analítica fechada. As *Wavelets* de Daubechies também têm suportes compactos e podem ser tomadas tão suaves e com quantos momentos nulos quanto desejados. Entretanto, elas são calculadas numericamente e não se conhece uma forma analítica fechada para as mesmas.

A *Wavelet* de Haar (figura 3.12) pode ser vista como um caso particular das *Wavelets* de Daubechies quando $N = 1$ (LIMA, 2002) e é definida como:

$$\psi(x) = \begin{cases} 1, & \text{se } x \in [0, \frac{1}{2}) \\ -1, & \text{se } x \in [\frac{1}{2}, 1) \\ 0, & \text{caso contrário} \end{cases} \quad (3.6)$$

Figura 3.12: A Wavelet de Haar, ψ .

A figura 3.13 mostra a função escala (ϕ) associada a Wavelet de Haar

$$\phi(x) = \begin{cases} 1, & 0 \leq x < 1 \\ 0, & \text{caso contrário} \end{cases} \quad (3.7)$$

Figura 3.13: A função escala, ϕ , associada a Wavelet de Haar (LIMA, 2002).

3.6 Wavelets em Processamento de Imagens Digitais

Em Visão Computacional é difícil analisar a informação contida na imagem diretamente da intensidade dos níveis de cinza dos pixels da imagem, pois os valores dependem das condições de iluminação da cena. Mais importantes são as variações locais de intensidade da imagem. A MRA permite ter uma interpretação da imagem invariante à escala. Em diferentes resoluções, os detalhes de uma imagem geralmente caracterizam diferentes estruturas físicas da cena. Em uma resolução mais grosseira, esses detalhes correspondem a estruturas maiores que fornecem o “contexto” da imagem. É natural analisar primeiro os

detalhes da imagem em uma resolução mais grosseira e ir gradualmente aumentando a resolução. Assim, uma estratégia de análise “grosseira a fina” é útil para algoritmos de reconhecimento de padrões (MALLAT, 1989).

A imagem digital é uma equação $f(x, y)$ discretizada tanto em coordenadas espaciais quanto em brilho. Uma imagem digital pode ser considerada como sendo uma matriz cujos índices de linhas e colunas identificam um ponto na imagem, e o correspondente valor do elemento da matriz identifica o nível de cinza naquele ponto. Os elementos dessa matriz digital são chamados de elementos da imagem ou simplesmente “*pixels*”, proveniente da abreviação de *Picture Elements* (GONZALEZ; WOODS, 2000).

Quando se considera uma imagem digital (bi-dimensional), para se calcular seus coeficientes *Wavelets*, o sinal passa a ser uma função de energia finita $f(x, y) \in L^2(\mathbb{R}^2)$ (MALLAT, 1989) e suas linhas e suas colunas são tratadas como se fossem “imagens unidimensionais” (LIMA, 2002). Dada uma função f no espaço V_0 , ela pode ser escrita de maneira única como:

$$f(x) = \sum_k a_{0,k} \phi(x - k) \quad (3.8)$$

Dada uma imagem digital unidimensional, em preto e branco, com 2^l *pixels*, onde l é um inteiro não-negativo, sejam $\{a_{0,k}\}_{k=0,\dots,2^l-1}$ os valores de cada um de seus *pixels*. Associa-se a essa imagem a seguinte função em V_0 : $f(x) = \sum_k a_{0,k} \phi(x - k)$. Com tal definição, usando algoritmos apropriados, pode-se calcular os coeficientes *Wavelets* de f , $d_{j,k}$, $j = 1, \dots, J = 2^l$ e os coeficientes $a_{j,k}$. Ao projetar-se f sob um dos subespaços V_j o que se está fazendo é obter uma versão de baixa resolução de f , reduzindo a resolução por um fator de 2^j e ao passar de V_j para V_{j+1} perde-se a resolução por um fator de 2 e os detalhes que se perderiam são representados por Δ_j . O que se obtém então ao decompor f é uma versão da imagem

onde todos os *pixels* possuem o mesmo valor, que é a “média” de todos os *pixels*, mais detalhes correspondentes às escalas intermediárias (LIMA, 2004).

Assim, sob o ponto de vista computacional, considerando inicialmente uma imagem unidimensional com 2^l *pixels*, armazenada em um vetor A , com 2^l posições, ao se decompor esta referida imagem, no primeiro passo, passa-se de V_0 para V_1 , gerando-se 2^{l-1} coeficientes de aproximação e detalhes. Com isso, tem-se uma imagem de baixa resolução, $f_1 \in V_1 \subset V_0$, com resolução diminuída por fator de dois, armazenada nas primeiras 2^{l-1} posições do vetor A , nas posições seguintes estão os detalhes, correspondentes à passagem de V_0 para V_1 que é a projeção de f sobre W_1 . Esse processo pode ser repetido l vezes. Sendo que, cada passo nesse processo pode ser implementado por uma matriz invertível (ortogonal), o que significa que a imagem pode ser reconstruída.

No caso de uma imagem colorida, os coeficientes $a_{j,k}$ e $d_{j,k}$ serão necessários vetores com três componentes e o procedimento, nesse caso, será aplicado a cada componente, separadamente (LIMA, 2004). Assim, a decomposição de um sinal bidimensional em seus coeficientes *Wavelet*, quando efetuada em uma única escala (nível), produz o resultado mostrado na figura 3.14 (LIMA, 2002).

Figura 3.14: Decomposição *Wavelet* de um sinal bidimensional.

Quando a decomposição é efetuada em mais de um nível, há duas formas diferentes para obtê-la. A forma chamada de convencional consiste na tomada da TW das linhas seguida pela TW das colunas. A maior desvantagem dessa forma é a mistura entre as diferentes escalas. Outra forma, chamada de não convencional, é obtida pela decomposição alternada de linhas e colunas a cada nível.

Cada nível de decomposição j é um novo grupo de quatro subespaços denominados aproximação, detalhe horizontal, detalhe vertical e detalhe diagonal, ou simplesmente, A_j, H_j, V_j, D_j , conforme esquema com dois níveis de decomposição ilustrado na figura 3.15.

Figura 3.15: Sinal bidimensional com dois níveis de decomposição.

Considerando uma imagem com $2^l \times 2^l$ pixels, a qual pode ser armazenada em uma matriz quadrada A , de ordem 2^l , nesse caso, cada linha ou coluna é tratada como se fosse uma imagem unidimensional.

Na **decomposição padrão**, no primeiro passo, associa-se a cada linha da imagem uma função em V_0 , conforme descrito acima, em seguida, para cada linha calcula-se os coeficientes *Wavelets*. A seguir, associa-se a cada uma das colunas transformadas no processo anterior uma função em V_0 e aplica-se o mesmo processo às mesmas e obtém-se os respectivos coeficientes *Wavelets*. A figura 3.16 ilustra esse processo (LIMA, 2004).

Figura 3.16: Decomposição padrão de um sinal bidimensional.

Na **decomposição não-padrão**, aplica-se operações em linhas e colunas alternadamente. Associa-se à cada linha da imagem uma função em V_0 . A seguir, decompõe-se cada linha aplicando-se apenas um passo no processo descrito na passagem⁵ de V_0 para $V_1 \oplus W_1$, depois cada coluna resultante é tratada como se fosse uma função em V_0 que são decompostas, como feito no passo anterior, onde as linhas foram substituídas pelas colunas. No passo seguinte, toma-se a versão de baixa resolução da imagem original a qual está armazenada em uma submatriz, de A , restrita aos $A[i, j]$ com $i, j = 0, \dots, 2^{l-1} - 1$ (nas demais posições tem-se os coeficientes *Wavelets*). A seguir, o processo é repetido para a versão de

⁵ A decomposição gerará W_1 que é o complemento ortogonal resultante da passagem de V_0 para V_1

baixa resolução da imagem obtida no passo anterior, gerando uma submatriz de A , restrita a $A_1[i, j]$ com $i, j = 0, \dots, 2^{l-2} - 1$, na qual está uma nova versão de baixa resolução da imagem (nas demais posições estão os coeficientes *Wavelets*). Prosseguindo dessa forma, após, l passos, encontra-se uma submatriz de A , formada por $A[0;0]$ contendo a “média” de todos os *pixels* e nas demais posições estarão os coeficientes *Wavelets*, conforme ilustrado na figura 3.17 (LIMA., 2004).

Figura 3.17: Decomposição não-padrão de um sinal bidimensional.

A decomposição padrão é considerada mais simples para implementar, enquanto que a decomposição não-padrão apresenta-se como levemente mais eficiente para calcular.

3.7 Transformada *Wavelet Packet*

Uma outra abordagem para a decomposição *Wavelet* em mais de um nível é a chamada Transformada *Wavelet Packet* (*Wavelet Packet Transform* – WPT), também descrita na literatura como *Pacotes Wavelet*, que foi proposta por Coifman e Wickerhauser em 1992, sendo uma generalização do conceito da Transformada *Wavelet* Clássica. Coifman e Wickerhauser (1992) a definem como uma coleção de “*waveforms*” moduladas que corresponde em linhas gerais a cobertura do espaço de frequências. Essa biblioteca de bases *Wavelet Packet* é composta de funções de bases ortonormais na forma $W_n(2^l x - k)$, onde $l, k \in \mathbb{Z}, n \in \mathbb{N}$, sendo que l é o parâmetro escala, k é o parâmetro localização e n é o parâmetro oscilação.

Na *Wavelet Packet* a resolução tempo-frequência pode ser escolhida de acordo com o sinal, oferecendo uma análise mais rica em detalhes. Isso é feito dentro dos limites do Princípio de Incerteza de Heisenberg (GARCIA; ZIKOS; TZIRITAS, 2000).

A decomposição usando *Wavelet Packet* não se limita ao subespaço de aproximação nas sucessivas decomposições. Nesse ponto reside a principal diferença entre os *frameworks* apresentados. A análise *Wavelet Packet* oferece maior complexidade e uma análise mais flexível, pois tanto os coeficientes de detalhes quanto os coeficientes de aproximações são subdivididos, conforme ilustrado na figura 3.18.

Figura 3.18: Decomposição *Wavelet Packet* Unidimensional (MATHWORKS, 2004).

O sinal é decomposto em forma de árvore binária, gerando a chamada *Árvore Wavelet Packet*. Na raiz tem-se o sinal a ser analisado e nas folhas ou nós tem-se os subespaços. Essa vertente é explorada devido ao particionamento mais homogêneo obtido, ideal para distribuição uniforme de tarefas em paralelo (LOUREIRO *et al.*, 2005).

Em duas dimensões, a transformada continua sendo aplicada nos subespaços de detalhes horizontais, verticais e diagonais, gerando assim uma quantidade de 4^j subespaços contra os $1 + 3j$ alcançados pela Transformada *Wavelet*, conforme ilustrado na figura 3.19.

Figura 3.19: Decomposição *Wavelet Packet* Bidimensional.

Em relação à Transformada *Wavelet* padrão (TW), a Transformada *Wavelet Packet* (TWP) fornece a possibilidade de dar *zoom* em qualquer faixa de frequência desejada. É utilizada como uma ferramenta para extrair características relevantes de uma ou duas dimensões, melhorando a performance dos classificadores ao extrair características relativas

através da decomposição em diferentes bandas de frequências. Alguns autores concluem que a análise da imagem utilizando a *Wavelet Packet* fornece excelente descrição de textura e sua implementação é muito rápida (PARRAGA, 2002).

Ao contrário da Transformada *Wavelet* Discreta, que é função de duas variáveis (escalamento e translação), a Transformada *Wavelet Packet* é uma função de três variáveis, incluindo a variável f que corresponde a um índice de frequência da *Wavelet*, conforme equação 3.8 (GRAPS, 1995; WICKERHAUSER, 1994).

$$\lambda_{sf}(p) \stackrel{def}{=} \left\langle x, w_{sfp} \right\rangle = \int_{\mathfrak{R}} x(t) \cdot 2^{-s/2} w_f(2^{-s}t - p) dt \quad (3.9)$$

onde, $\lambda_{sf}(p)$ são coeficientes da expansão de x nas funções *Wavelet Packet*, $w_{sfp}(t)$ são as funções *Wavelet Packet* básicas, s é o índice de escala (ou dilatação), p é o índice de posição (ou translação), f é o índice de frequência.

Diferentemente da Transformada *Wavelet* Discreta, a Transformada *Wavelet Packet* utiliza mais filtros passa-alta (H) em cada nível de dilatação. A decomposição com múltiplas escalas também é possível e pode ser implementada aplicando-se os filtros passa-baixa (G) e passa-alta na sequência de coeficientes λ_{sf} da equação 3.9, satisfazendo a relação recursiva, ou seja, a decomposição *Wavelet Packet* é construída com um algoritmo *Wavelet* recursivo usando mais filtros passa-alta, conforme esquema de decomposição unidimensional ilustrado na figura 3.20, onde x é o sinal a ser analisado, H e G são o par de filtros de quadratura (*Quadrature Mirror Filters* - QMF).

Figura 3.20: Diagrama de Blocos da Transf. Wavelet Packet (PARRAGA, 2002, pp. 59).

Uma única decomposição *Wavelet Packet* fornece muitas bases admissíveis, das quais pode-se escolher a melhor representação com relação ao objetivo do projeto. Assim, para representar um sinal ou uma imagem, existem mais de um conjunto de funções possíveis que formam uma base.

As áreas retangulares em cinza na figura 3.20 constituem um conjunto de bases particular para a representação do sinal x . Esse conjunto é uma representação mínima na qual a sequência x pode ser exatamente reconstruída. No entanto, existem outros subconjuntos de bases disponíveis que representam a decomposição completa do sinal original.

Devido às propriedades de ortogonalidade, a qual é consequência das condições dos filtros QMF, existem muitos conjuntos de *Wavelet Packet* que constituem bases ortogonais. Da árvore completa da *Wavelet Packet* pode-se escolher diferentes subconjuntos de nós que possam formar uma base ortogonal. Diferentes escolhas de nós fornecem diversos subconjuntos de bases ortogonais.

Uma vez que existem diferentes possíveis bases para a representação do objeto de estudo, um subconjunto de funções que melhor se adapte a um problema em particular pode

ser escolhido segundo algum método de seleção. O método de seleção da melhor base é chamado de algoritmo *Best Basis*, o qual seleciona a melhor entre essas bases, também chamada de representação ótima, conforme algum critério de escolha embutido em uma função custo (PARRAGA, 2002).

O algoritmo *Best Basis* emprega o conceito de custo de informação, ou custo para armazenar a representação escolhida. Podem ser definidos diversos tipos de função custo de informação, mas os mais usados são aqueles que medem concentração ou número de coeficientes necessários para descrever a seqüência. Isso significa que o valor da função custo tem que ser grande quando os elementos da seqüência são basicamente do mesmo tamanho e pequeno quando quase todos são negligenciáveis. Alguns exemplos de função custo de informação são: *Threshold*, Entropia, Concentração em l^p , Logaritmo da energia. Um mapa M de seqüências $\{x_i\}$ para $\Re$ é chamado função de informação de custo se $M(0) = 0$ e $M(\{x_i\}) = \sum_i M(x_i)$ (COIFMAN, WICKERHAUSER, 1992).

O critério baseado na Entropia, particularmente Entropia de Shannon é geralmente um dos mais usados para selecionar o nível mais profundo da árvore, enquanto mantém a informação mais significativa (GARCIA; ZIKOS; TZIRITAS, 2000).

Em linhas gerais pode-se descrever o funcionamento do algoritmo *Best Basis* da seguinte forma: calcula-se a entropia de todos os nós durante a decomposição, a árvore é analisada recursivamente de baixo para cima, os nós finais são identificados e então compara-se a entropia de cada par adjacente com a entropia da união desses pares. Escolhe-se a expansão de entropia mais baixa e continua-se o processo. Em síntese quando a informação de custo do nó-pai é menor que a informação de custo dos nós-filhos, marca-se o pai. Se os filhos tem informação de custo mais baixa, o pai não é marcado, mas atribui-se a informação de custo total mais baixa dos filhos ao pai, conforme ilustra a figura 3.21. (WICKERHAUSER, 1991).

Figura 3.21: Algoritmo *Best Basis*: os nós finais são “marcados” para iniciar o processo de análise das entropias dos nós filhos (WICKERHAUSER, 1991, pp.57).

Comparações são sempre realizadas entre as gerações adjacentes da árvore binária. Consequentemente, a complexidade da busca das melhores bases é proporcional ao número de nós da árvore. Esta complexidade é dominada pelo cálculo do custo de todos os coeficientes para todas as bases na biblioteca, o que leva para $O(N \log N)$ para as *Wavelet Packets*.

3.8 Considerações Finais

A Transformada *Wavelet* Discreta é uma operação linear, cujas funções individuais *Wavelets* estão localizadas no espaço quando se considera uma decomposição bidimensional. Essa característica de localização, junto com a localização de frequência, faz muitas funções e operadores que usam *Wavelets* esparsos quando transformados em domínios *Wavelet*. A característica de ser esparsa resulta em um número de aplicações úteis, como compressão de dados, remoção de ruídos e também voltados para detecção de características em imagens e reconhecimento de padrões (SILVA; EYNG, 2002).

Neste capítulo foi apresentada a teoria *Wavelet* considerando sua evolução a partir da Transformada de Fourier. É importante notar que a Transformada *Wavelet* permite a análise local, devido às funções base de suporte compacto. O uso das *Wavelets* demonstra grande

potencial no que se refere a extração de características para sistemas CBIR, relacionados às imagens médicas, pelo fato destas apresentarem regiões com texturas (CASTAÑÓN, 2003).

Dependendo da função ψ escolhida é possível extrair bordas ou descontinuidades, auxiliar no reconhecimento de padrões ou armazenar de forma eficiente uma versão comprimida do objeto de estudo (SAARBRÜCKEN; KAISERSLAUTERN, 1994).

Por fornecer uma análise mais minuciosa as *Wavelet Packets* ampliam as vantagens dessa poderosa e consagrada ferramenta matemática: as *Wavelets*. Essa peculiaridade tem propiciado destaque as *Wavelets Packets* recentemente.

Recuperação de Imagens na Área Médica

4.1 Considerações Iniciais

Atualmente é cada vez mais constante o uso de tecnologias computacionais na área da saúde. Essa inovação tecnológica que a princípio começou de maneira gradativa, é hoje considerada uma das ferramentas mais importantes e indispensáveis (NETO; OLIVEIRA; VALERI, 2004).

A área da Informática aplicada à Saúde está em constante expansão devido a grande variedade de informações e tipos de dados. Requisitos de processamento, armazenamento, visualização e transmissão colocados pelas diversas áreas e aspectos da Medicina impõem constantes desafios aos pesquisadores interessados no desenvolvimento de soluções duradouras que sejam ao mesmo tempo tecnológica, segura, confiável e eticamente fundamentais para satisfazer as necessidades decorrentes do desejo de se informatizar a atividade relacionada à saúde (WANGENHEIM, 2005).

Uma das razões para o desenvolvimento de aplicações de CBIR na área médica é devido ao crescente volume de informações geradas, tornando o acesso cada vez mais complexo (MÜLLER *et al.*, 2004).

O processo de recuperação de imagens baseado nas características ou no conteúdo das imagens apresenta variações de possibilidade de estruturação, pois o processo de recuperação pode ser baseado em diferentes características visuais como cor, forma, textura, identidades dos objetos, entre outras. A idéia central do conceito de recuperação baseada no conteúdo das imagens é poder localizar uma imagem ou grupo de imagens semelhantes a uma imagem passada como parâmetro. Devido às diversas possibilidades de embasamento dentro desse contexto, várias técnicas foram propostas no decorrer dos anos (WANGENHEIM, 2005).

4.2 Sistemas de Informação na Área Médica

As imagens proporcionam uma interpretação direta e cada vez mais precisa. Assim, sistemas que armazenam e gerenciam imagens médicas de forma automatizada, tem proporcionado grandes benefícios para a medicina, os quais são de extrema importância para centros de diagnósticos por imagens (NETO; OLIVEIRA; VALERI, 2004).

Com a inovação da tecnologia da informação na área da medicina, visando melhorar a qualidade dos serviços e o atendimento dos pacientes, hospitais e clínicas de pequeno, médio e grande porte estão realizando a integração de seus sistemas de informações para tecnologias utilizadas mundialmente como *Hospital Information System – HIS*, *Radiology Information System – RIS* e *Picture Archiving and Communication System – PACS*.

Essa integração possibilita o gerenciamento e armazenamento de imagens, permitindo que as informações dos pacientes e suas respectivas imagens sejam compartilhadas, recuperadas e visualizadas localmente e/ou remotamente (BUENO *et al.*, 2002).

4.2.1 Sistemas de Informação Hospitalar

Os Sistemas de Informação Hospitalar (*Hospital Information Systems – HIS*), consistem no estudo e desenvolvimento de metodologias de informatização para hospitais. Os Sistemas de Informações Hospitalares armazenam as informações relativas aos pacientes destacando-se, entre elas, seu estado de saúde, os exames realizados e os procedimentos médicos adotados.

4.2.2 Sistemas de Informações Radiológicas

Os Sistemas de Informações Radiológicas (*Radiological Information Systems – RIS*), consistem no estudo e desenvolvimento de metodologias de gerência e intercâmbio de imagens radiológicas e também estratégias de integração destas ao prontuário eletrônico do paciente, definindo *interfaces* padrão entre sistemas (NETO; OLIVEIRA; VALERI, 2004).

4.2.3 Sistemas de Comunicação e Arquivamento de Imagem

Sistemas de Comunicação e Arquivamento de Imagem (*Picture Archiving and Communications System - PACS*), são sistemas compostos por aparelhos de diagnóstico médico (fornecedores de imagens digitais), computadores (estações de trabalho para visualização e análise das imagens) e servidores de dados (responsáveis pelo armazenamento e gerenciamento das imagens) interconectados entre si através de redes lógicas (local ou remota) sendo acessíveis por diferentes clientes (programas de diferentes computadores). (WANGENHEIM, 2005).

Os PACS são sistemas para armazenar e acessar a grande quantidade de dados visuais usados nos departamentos médicos. O acesso a esses sistemas é geralmente baseado na identificação do paciente ou características do estudo (MÜLLER *et al.*, 2004).

Com a introdução dos sistemas PACS cresceu o interesse por integrar em um único sistema todas as informações dos pacientes (textos, imagens, gráficos, dados temporais, etc). Além disso, o custo operacional dos exames de imagens diminuiu quando se utiliza tecnologia de radiologia sem filme, o que permite direcionar investimentos maiores para a área de diagnóstico (SIEGEL, 1999). A tecnologia de radiologia sem filme (*Filmless*) refere-se a um hospital ou um amplo ambiente de rede no qual o filme é substituído completamente ou parcialmente por um sistema eletrônico que adquire, armazena, comunica e exibe imagens (ROSA *et al.*, 2002) reduzindo, de maneira significativa, o custo da manutenção desses exames.

No entanto, os sistemas PACS infelizmente não tem sido utilizados como se esperava pelas inúmeras instituições que trabalham com diagnósticos por imagem. Determinado fato ocorre porque sistemas de armazenamento de imagens são considerados por muitos como sistemas que envolvem grandes investimentos para implantação e manutenção (NETO; OLIVEIRA; VALERI, 2004).

4.3 Padrão DICOM

Com o aumento da utilização das tecnologias computacionais para auxiliar no diagnóstico clínico dos pacientes, possibilitada pelos RIS, principalmente após o surgimento da *Computer Tomography* (CT), na década de 70, diversos equipamentos foram desenvolvidos por diferentes fabricantes.

O PACS tem como objetivo principal realizar a integração e comunicação eficiente de vários equipamentos médicos que trabalham com imagens como Raio X, Tomografia Computadorizada, Ressonância Magnética, Ultra-som, entre outros.

Com o início do processo de informatização dos diagnósticos surgiram os primeiros problemas de interoperabilidade entre esses equipamentos. (WANGENHEIM, 2005; NETO; OLIVEIRA; VALERI, 2004).

Para solucionar esse problema de interoperabilidade, o ACR (*American College of Radiology*) e o NEMA (*National Electrical Manufacturers Association*), em 1983, organizaram um comitê para elaboração de um padrão de dados e imagens, para comunicação dos diversos equipamentos de RIS.

Esse padrão foi inicialmente publicado em 1985, chamado de ACR/NEMA 1.0. Após algumas atualizações, em 1986 surgiu o ACR/NEMA 2.0. Em 1988, após duas revisões foi publicada a versão 3.0 do padrão denominado DICOM⁶ (*Digital Imaging and Communication in Medicine*) usado atualmente pela maioria dos equipamentos.

Esse padrão visa facilitar a interoperabilidade entre os equipamentos de imagens médicas, pois especifica um conjunto de protocolos para comunicação em rede; a sintaxe e semântica dos comandos e as informações associadas que podem ser trocadas usando os protocolos; um conjunto de serviços para o meio de armazenamento, bem como um formato de arquivo e uma estrutura de diretório médico para facilitar o acesso às imagens e informações armazenadas (NEMA, 2004).

De forma sintética, o padrão DICOM define o armazenamento e transmissão de imagens médicas e informações associadas de maneira padronizada. Também visa promover a comunicação de informações de imagens digitais, sem levar em consideração os fabricantes dos aparelhos, por fim, facilitar o desenvolvimento e expansão dos sistemas PACS (NETO; OLIVEIRA; VALERI, 2004; POLIKAR, 2001; ROSA *et al.*, 2002).

Assim, o DICOM é o padrão internacionalmente aceito para sistemas PACS e usado por diversas modalidades de equipamentos de imagens médicas (WANGENHEIM, 2005).

⁶ <http://dicom.nema.org/>

Uma das principais vantagens em utilizar o padrão DICOM reside no fato de que esse padrão é diferente dos demais formatos conhecidos comercialmente como (JPEG, TIF, BMP e outros), pois permite que as informações dos pacientes sejam armazenadas, de forma estruturada, juntamente com a imagem, isto é, elas são armazenadas utilizando ponteiros, conhecidos como *tags* que identificam e limitam as informações textuais (NETO; OLIVEIRA; VALERI, 2004).

Um arquivo imagem no formato DICOM é composto de duas partes distintas. Um cabeçalho contendo informações diversas sobre a imagem, o paciente, o equipamento, estudo e série, organizadas em *tags*. Cada estudo contém uma ou mais séries. Séries são seqüências de imagens ou cortes de imagens (ROSA *et al.*, 2002). A outra parte de um arquivo DICOM contém a imagem propriamente dita, com informações sobre os *pixels* que a compõem (NEMA, 2004).

Na área médica, normalmente, o objetivo ultrapassa uma simples busca pelo nome do paciente ou modalidade. No caso dos arquivos DICOM, seus cabeçalhos são preenchidos com diversas informações médicas, como nome do paciente, modalidade do exame, data de aquisição, parâmetros de regulação dos aparelhos de aquisição, entre outras. Essas informações podem ser utilizadas em fases posteriores à recuperação para aprimorar o resultado da busca, pois outras informações além das pictóricas podem ser necessárias e úteis como a anatomia, posição do paciente ou a modalidade do exame. Considerando que uma característica é qualquer informação adicional à presente nos *pixels*, também pode-se considerar como características as informações contidas nos cabeçalhos dos arquivos no formato DICOM, o que possibilita desenvolver um mecanismo de busca que mescle informações textuais e visuais (FIGUEIREDO, 2005).

Dessa forma, o padrão DICOM permite realizar consultas textuais baseadas nas informações do cabeçalho, baseado nas informações do diagnóstico e consultas baseada no conteúdo das imagens.

4.4 Áreas de Aplicação

As aplicações CBIR, além de auxiliar nos diagnósticos, contribuem para o ensino e a pesquisa na área médica.

No ensino, o professor pode buscar em uma grande base de imagens casos de interesse para apresentar aos estudantes, considerando a região anatômica ou o diagnóstico. Essa idéia está sendo colocada em prática atualmente através de um sistema de ensino eletrônico em Radiologia, no Instituto do Coração do Hospital das Clínicas (SANTOS; FURUIE, 2006). As características visuais permitem tanto a recuperação de casos com diagnósticos similares, quanto a recuperação de casos com similaridade visual, mas com diagnósticos diferentes. Sistemas CBIR podem se transformar em uma ferramenta para ajudar professores e estudantes da área médica, na exploração de repositórios de imagens educacionais e permitir inspecionar visualmente os resultados encontrados, ampliando a qualidade educacional. Especialmente em ensino à distância, que usam tecnologias baseadas na Internet, novas possibilidades podem ser exploradas com as técnicas baseadas em conteúdo que possibilitam investigar as bases de dados e comparar diagnósticos, sem grandes dificuldades de implementação.

Na pesquisa, os dados visuais podem ser analisados com o auxílio de técnicas de mineração de dados em busca de padrões de interesse que podem levar a novas descobertas, as quais podem inclusive contribuir para a cura de doenças.

No auxílio ao diagnóstico, onde atualmente está concentrada a maior parte das pesquisas, há duas idéias principais: a primeira é fornecer ao profissional da área médica casos que apresentem similaridade visual. Isso pode fornecer uma segunda opinião e o

profissional pode desenvolver seu raciocínio baseado nos vários casos apresentados pelo sistema de recuperação, considerando a opção mais vantajosa e adequada para o paciente. Outra idéia é a criação de bases de imagens contendo casos sem patologia (normais) e comparar a distância de um novo caso com os casos existentes fazendo dessa forma, recuperação da dissimilaridade ao contrário da recuperação da similaridade (distância para a normalidade) (EAKINS; GRAHAM, 1999).

4.5 Estado da Arte

A área de Recuperação de Imagens por Conteúdo aplicado à Medicina, tem crescido muito recentemente. Esse crescimento é atribuído à disseminação dos produtos tecnológicos e a necessidade de administrar grandes quantidades de dados e imagens (CAMPO; TRAINA, 2003).

A variedade de equipamentos, procedimentos e pessoal técnico que os manuseiam tornam o processo de aquisição de imagens uma das partes mais delicadas, pois dependendo de como a imagem foi adquirida ela pode se tornar mais escura (menos brilho) ou mesmo saturada (brilho em demasia). Tais variações dificultam a recuperação e comparação entre imagens. Os principais sistemas de Recuperação de Imagens por Conteúdo baseados em cor em geral, não suportam essas variações, não recuperando de maneira eficiente a mesma imagem que tenha sofrido variações de brilho e/ou contraste.

As técnicas descritas na literatura em sua maioria não tratam de maneira eficiente a questão da variação de brilho, porém há estudos nesse sentido, como é o caso do estudo apresentado em Bueno *et al.* (2002) que visa preencher essa lacuna. Essa invariância às transformações de brilho é muito importante, porque imagens de mesmo paciente e exame ao serem adquiridas em situações diferentes tendem a variar o brilho (CAMPO; TRAINA, 2003) e Bueno *et al.* (2002) apresentam uma nova abordagem de extração de características com

respeito a tais restrições de transformações de brilho sobre as imagens, baseada em intensidade de cor. É utilizado o Histograma Métrico (HM), o qual conserva a curva original do histograma de brilho de uma imagem sem perda considerável da sua informação e reduz o número de *bins*⁷ reduzindo, assim, o custo computacional na busca. Um histograma normalizado é composto por um número específico de *bins*. Esse número depende da resolução de intensidades (luminosidade) da imagem, sendo dessa maneira um número fixo. Em um histograma métrico, o equivalente ao *bin* do histograma é chamado de *bucket*. Cada *bucket* corresponde a uma linha na aproximação do histograma normalizado.

Seguindo uma outra vertente, vários artigos focam seus estudos no atributo textura para classificar, segmentar e reconhecer imagens. E muitos desses artigos avaliam o poder das *Wavelet* para esse fim. Bhalerao e Rajpoot (2003), por exemplo, aplicam *Wavelet Packet* usando Daubechie com 8 filtros com dois níveis de decomposição e o esquema *Wilson-Spann* para 3 e 5 níveis (semelhante aos filtros Gabor), para classificar imagens de textura extraídas do álbum de Brodatz⁸. Para reduzir a dimensionalidade dos dados eles utilizam os métodos PCA e LDA. Um algoritmo para classificação supervisionada de textura foi implementado empregando o classificador *k-means* para separar as imagens em duas classes. Foram realizados experimentos com variadas medidas de distância (*Kullback-Leibler* - KL, *Fisher Distance* - FD, *Bhattacharya Distance* - BD, *Euclidian Distance* - ED), sendo que para selecionar características das subbandas da TWP as medidas BD e FD apresentaram melhores resultados e para as subbandas do domínio de Fourier (*Wilson-Spann*), BD foi a melhor, mas a KL pode se destacar mais quando a distribuição de energia é periódica. Rajpoot (2003) ainda faz um estudo comparativo selecionando as características com *Wavelet*, *Wavelet Packet Full* e *Wavelet Packet Adaptativa*.

⁷ Em um histograma ocorre um agrupamento de acordo com a escala de valores dos elementos. Cada grupo é mostrado como um *bin*.

⁸ Brodatz é um álbum público de imagens de textura.

Seguindo essa linha de estudo, a respeito das imagens médicas, acredita-se que as características baseadas em textura e forma obtidas das regiões da imagem podem discriminá-las e separá-las de modo mais apurado, pois os objetos (órgãos, tecidos e anomalias) têm, na maioria das vezes, forma e textura específicas que podem ser empregadas para a delimitação dos mesmos (BALAN *et al.*, 2004).

Em Balan *et al.* (2004) é apresentada uma abordagem singular de extração de características da imagem. A técnica consiste em segmentar automaticamente a imagem com base em textura utilizando um algoritmo estocástico baseado nos campos aleatórios de Markov. O método de segmentação empregado é um algoritmo iterativo que implementa um processo estocástico de otimização, cujo objetivo é minimizar o número previsto de *pixels* classificados erroneamente. O método utilizado nesse estudo é não-supervisionado, onde os parâmetros assumem valores iniciais aleatórios e são ajustados durante o processo de segmentação. Assim, somente o número de classes previstas para a segmentação precisa ser informado inicialmente.

Após a imagem ter sido segmentada automaticamente em um número de classes pré-definido, várias medidas são extraídas das regiões de textura homogênea, como o centro da massa da região, a massa da região, que é o tamanho em número de *pixels* da região que foram classificados como sendo de uma determinada classe, uma medida denominada dispersão, a média e a variância da região. As três primeiras características (massa, centro de massa e dispersão) são computadas diretamente sobre a imagem segmentada, sendo que a média e variância são medidas da imagem original considerando-se a segmentação obtida. O vetor de características proposto é construído utilizando-se essas cinco características para cada classe e a distância Euclidiana é usada para a comparação desses vetores. Para validar a técnica, gráficos de *Recall* x *Precision* (Revocação x Precisão), foram utilizados.

O artigo de Huang e Aviyente (2006) também enfatiza a importância do atributo textura para classificar imagens. Para isto as imagens são decompostas usando *Wavelet Packet* de Haar e Daubechie. Valores estatísticos são extraídos da matriz de coeficientes *Wavelets*, como energia, média e desvio padrão. Uma atenção especial é atribuída ao valor de energia obtido a partir dos coeficientes das diferentes subimagens, o qual segundo os autores tem importantes propriedades para discriminação de imagens de textura. Como a TWP gera um grande número de representações possíveis é proposto um algoritmo para escolha de subimagens independentes para gerar uma representação esparsa das imagens de textura, com base na utilização de uma função de custo que analisa a dependência dos valores de energia das diferentes subimagens.

Watanabe e Traina (2005) exploram o atributo textura de imagens médicas em suas pesquisas, através da transformada *Wavelet* de Haar em um nível de resolução e da extração de características de cada subespaço das imagens através do cálculo de coeficientes estatísticos de média, variância e energia e da dimensão fractal, para a construção de vetores de características. As imagens utilizadas no trabalho correspondem a exames de Ressonância Magnética (MR) e Angiograma de 8 bits, resultando em 256 tons de cinza, com dimensões de 256 x 256. Para realização dos testes, foi preparado um conjunto com 210 imagens de vários tipos de exames realizados no Hospital das Clínicas de Ribeirão Preto. Esse conjunto foi dividido em 7 classes, com 30 imagens cada, de acordo com a região do corpo examinada e o tipo de corte tomado: Angiograma, Axial MR Bacia, Axial MR Cabeça, Coronal, Abdômen, Coronal MR Cabeça, Sagital MR Cabeça e Sagital MR Coluna. Foi implementado o método de busca aos vizinhos mais próximos, *k*-NNQ e os resultados foram avaliados através de gráfico *Recall x Precision*, os quais mostraram que a união dos atributos gera melhores resultados que atributos isolados, alcançando pelo menos 80% de exatidão.

Em Castañón e Traina (2002) é descrita uma abordagem para um banco de imagens médicas, que é orientada a extração de características para um sistema CBIR baseada na decomposição multiresolução *Wavelet*, aplicando filtros Daubechies e Gabor. Essas novas características da imagem foram indexadas e testadas utilizando uma estrutura de indexação métrica (Slim-Tree). O enfoque é caracterizar as imagens aproveitando os espaços *Wavelets* gerados após aplicar os filtros da transformada e mediante medidas estatísticas desses espaços, montar o vetor de características. Já Parraga (2002) utilizou a Transformada *Wavelet Packet* como extrator de características para gerar os vetores e auxiliar no diagnóstico de patologias da laringe. Qureshi *et al.*(2006), decompõe em 4 níveis imagens de tumor cerebral benigno nas meninges usando a *Wavelet Packet* com Daubechie-4 filtros. Uma pseudo função de densidade de probabilidade (PDF) é obtida para cada subbanda usando a energia normalizada dos coeficientes e a distância Hellinger é usada como função de custo no processo de seleção da *Best Basis*. Devido a alta dimensionalidade, medidas estatísticas são obtidas das subbandas: curtose, entropia, energia e média e passam a ser utilizados como vetores de entrada para treinamento da rede neural LVQ (*Learning Vector Quantization*).

A recuperação de imagens baseada na descrição textual e a baseada em conteúdo são abordagens independentes e ortogonais. No entanto, de forma prática, podem ser integradas em um único sistema a fim de proporcionar um maior poder de recuperação em Sistemas de Informação Hospitalar (HIS) ou em Sistemas de Comunicação e Arquivamento de Imagens (PACS) (BALAN *et al.*, 2004).

A integração de métodos de recuperação baseados em conteúdo com PACS facilitam o gerenciamento dos dados clínicos. Integrar CBIR com PACS tem sido proposto e desejável, pois é um ponto decisivo para o uso clínico de forma efetiva dos sistemas de recuperação (MÜLLER *et al.*, 2004).

Em Rosa *et al.* (2002), é apresentado o SRIS-HC – Sistema de Recuperação de Imagens Similares, para uso no Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto da Universidade de São Paulo HC-FMRP/USP. O SRIS-HC atua como um recurso adicional de um sistema PACS. As imagens foram indexadas, utilizando o método de acesso métrico (MAM) Slim-Tree e recuperadas através de características extraídas por histograma tradicional e o histograma métrico.

Dentro do contexto de incorporar aos PACS as funcionalidades dos sistemas de buscas por conteúdo, existem algumas peculiaridades dos PACS que em geral, não são tratadas pelos sistemas CBIR, como por exemplo, as informações contidas nos cabeçalhos dos arquivos DICOM, que são informações adicionais às informações pictóricas da imagem em si, porém relevantes para o usuário especialista. Outro ponto é o tratamento do domínio, que nesse caso está relacionado com as diversas modalidades médicas e suas respectivas técnicas de aquisição, por exemplo, imagens de Tomografia Computadorizada (CT) junto com Ressonância Magnética (MR), ou de pélvis com cérebro, órgãos sadios com órgãos com patologia. Um exemplo da falta de tratamento de domínios nos PACS é que a inclusão de uma imagem de CT em um conjunto de imagens de MR é permitida pelo sistema sem que nenhum tipo de validação automática ocorra, ficando essa validação muitas vezes a cargo do usuário (FIGUEIREDO *et al.*, 2004).

Devido a essas peculiaridades encontram-se na literatura vários estudos em sistemas CBIR descritos, que em geral trabalham com domínios específicos visando aprimorar os resultados. Em Gato, Nunes e Schiabel (2004), por exemplo, a proposta é realizar buscas por conteúdo aos vizinhos mais próximos, em imagens mamográficas, baseado na densidade e na área da mama. Uma varredura na área pertencente à mama é realizada e calculada a média de níveis de cinza referente aos *pixels* que pertenciam apenas à mama. O fundo da imagem é descartado através de um algoritmo que recorta a área que efetivamente contém estruturas

mamárias. A área da mama é calculada considerando-se a quantidade de *pixels* da área segmentada através do algoritmo de eliminação do fundo.

O uso de tecnologias vinculadas à Internet, também podem auxiliar para integrar métodos de recuperação com outras aplicações. A integração das tecnologias *Web* com os diversos equipamentos médicos torna possível a visualização de imagens em qualquer parte do mundo a custo acessível. Assim padrões mundiais como o DICOM, tornam-se imprescindíveis (NETO; OLIVEIRA; VALERI, 2004).

Essa vertente está sendo explorada em nosso grupo de pesquisa através do trabalho de pesquisa de mestrado de Ana Carolina Nicolosi da Rocha Gracioso, que desenvolveu um sistema de recuperação de imagens médicas por conteúdo e disponibilizou o sistema para testes na Internet e em uma rede óptica de alta velocidade chamada Kyatera do projeto TIDIA (FAPESP). Segundo Ana Carolina os testes realizados em rede demonstraram que é possível a implementação de um sistema de recuperação de imagens por conteúdo em rede, porém, que fatores importantes devem ser considerados como: arquitetura da máquina utilizada; utilização da CPU e disponibilidade da banda. Testes realizados por voluntários demonstraram que a Internet atual não é ideal para o uso de um sistema de recuperação de imagens por conteúdo. Para acesso em rede de um sistema como esse, seria necessária a implantação de uma rede de alta velocidade interligando os hospitais, clínicas médicas e universidades. Porém, eventuais acessos fora destes locais seriam possíveis dependendo da velocidade da Internet, tamanho do arquivo e disposição do usuário em aguardar o tráfego dos dados pela rede (GRACIOSO, 2008).

O cbPACS, proposto por Bueno *et al.* (2002) é um PACS com recursos que permitem Recuperação de Imagens Baseadas em Conteúdo que faz uso das facilidades da Internet. O cbPACS responde a consultas por similaridade baseadas no vizinho mais próximo ou por *range*, com a vantagem do método de acesso métrico embutido no gerenciador de banco de

dados. O sistema compara as características das imagens obtidas através de histogramas normalizados e histogramas métricos. O cbPACS é composto por quatro módulos. O primeiro módulo trata da aquisição da imagem, recebendo as imagens em formato DICOM 3.0 dos dispositivos de imagem e enviando a informação alfanumérica e os arquivos imagem para o Banco de Dados. O segundo módulo, que é o núcleo do cbPACS, processa as imagens para extrair as características que serão usadas pelo Servidor de Banco de Dados e pelo Servidor Web, que juntamente com o MAM Slim-Tree permitirão a recuperação das imagens por conteúdo. O terceiro módulo é um Sistema Gerenciador de Banco de Dados Relacional estendido para suportar imagens como um tipo nativo através de um interpretador de extensões SQL chamado “Circe”. O quarto módulo é um Servidor Web, responsável por gerenciar o fluxo de informação entre o servidor de Banco de Dados e a aplicação cliente (BUENO *et al.*, 2002). Nessa aplicação específica utilizou-se o SGBDR Oracle para indexar as imagens, vinculado ao MAM Slim-Tree, porém outros SGBDRs também tem sido utilizados, como o InterBase (NETO; OLIVEIRA; VALERI, 2004) que é um banco de dados relacional (SGBDR), que incorpora conceitos subjacentes ao modelo de dados relacional.

Em Figueiredo *et al.* (2004) propõe-se incorporar o tipo imagem em um SGBD Relacional através de uma implementação com base na arquitetura de componentes, das funcionalidades de um sistema CBIR como um módulo que pode ser acoplado a qualquer ambiente.

Diferentemente do que acontece com outros domínios de imagens pesquisados em Visão Computacional, como faces, por exemplo, em que há bases públicas disponíveis para testes, em geral, pesquisas envolvendo imagens médicas têm que superar o obstáculo de encontrar conjuntos de dados que ofereçam conteúdos abrangentes, variados e confiáveis. Entretanto, há projetos que visam criar bases públicas de imagens médicas para validação de

algoritmos de processamento de imagens médicas. As bases de imagens MIRC-RSNA⁹ e myPACS.net¹⁰ são exemplos típicos. Há também um projeto (SANTOS; FURUIE, 2005) vinculado ao Instituto do Coração (InCor), no Hospital das Clínicas que visa tornar disponível uma base intermodal de imagens médicas de arquitetura distribuída, juntamente com protocolos clínicos, informações de diagnóstico, contexto da aquisição, para uso livre em diferentes propósitos. O projeto visa a interação com outras bases de uso livre, além de permitir pesquisa e recuperação de dados, processamento e análise dos dados, entre outras funcionalidades. Xue *et al.* (2007) também estão trabalhando em um projeto semelhante, porém focado em imagens uterinas. O projeto visa auxiliar os profissionais no diagnóstico do câncer de colo de útero, disponibilizando 100.000 imagens e diagnósticos clínicos que poderão ser acessados através de ferramentas via *web* que também propiciarão através de uma interface gráfica (GUI) funcionalidades CBIR baseadas na extração de características de cor, textura, tamanho e localização.

A base criada para realização das pesquisas no presente trabalho também poder-se-á tornar pública, após uma análise da viabilidade de disponibilização desses dados e obviamente se houver consentimento das partes envolvidas. É importante e fundamental enfatizar que aplicações na área médica envolvem questões éticas no que se refere a divulgação de dados pessoais e todos os projetos nessa área de pesquisa devem atentar a essas restrições.

Outro domínio ainda não discutido fervorosamente para imagens médicas são as *interfaces* para usuário. Algumas vezes *interfaces* baseadas na Internet são propostas (MÜLLER *et al.* 2003; LEHMANN; WEIN; GREENSPAN, 2003), mas geralmente comparação de *interfaces* não é relatada. Há muitas soluções criativas em recuperação de imagens que serão interessantes para estudos de *interfaces* efetivas, ergonômicas que atendam a critérios de usabilidade, além da aceitação e uso da tecnologia na prática médica.

⁹ <http://www.rsna.org/mirc/>

¹⁰ <http://www.mypacs.net/>

Estudos sobre os efeitos clínicos das tecnologias de recuperação de imagens por conteúdo, ainda estão distantes. Medidas relacionadas a um possível impacto clínico da aplicação quando usada para a prática clínica real, além de medidas relacionadas ao desempenho e relacionadas ao fator humano, como usabilidade e aceitação da tecnologia, as quais podem ser obtidas através de testes reais com os usuários, ainda não são muito enfatizadas (MÜLLER *et al.*, 2004).

Interação com o usuário e *realimentação por relevância* são duas outras técnicas que precisam ser integradas aos sistemas de recuperação, pois podem proporcionar melhores resultados na aplicação. É desejável que a recuperação de imagens seja interativa e que essa interatividade seja explorada para propiciar os melhores resultados possíveis (MÜLLER *et al.*, 2004). Em Alvarez (2003) é apresentado um estudo de usabilidade de seis sistemas CBIR, onde o foco principal é sempre o usuário final. A autora destaca que para o sucesso de uma aplicação CBIR é necessário que as *interfaces* se adequem às capacidades dos usuários, mas também deve-se ajudar o usuário a entender as limitações da aplicação.

4.6 Considerações Finais

Um dos objetivos em se desenvolver sistemas de Recuperação de Imagens baseado em Conteúdo é evitar a subjetividade existente na caracterização de uma imagem unicamente pelo seu conteúdo textual, visto que diferentes especialistas podem estar interessados em diferentes aspectos de uma mesma imagem (BALAN *et al.*, 2004). Nessa área de pesquisa um dos desafios é encontrar o conjunto de características mais adequado para descrever uma imagem.

Facilitar a integração dessas novas funcionalidades nas aplicações existentes, tais como HIS (Hospital Information System), RIS (*Radiology Information System*) e PACS (*Picture Archiving and Communication System*) ou outros softwares para visualização e gerenciamento

das imagens médicas é outro desafio a ser superado para a efetiva utilização de aplicações de CBIR na área médica, principalmente no que diz respeito aos PACS que capturam, armazenam, distribuem e exibem imagens médicas de forma descentralizada, mas tradicionalmente não suportam buscas de imagens baseadas no conteúdo.

Assim, este capítulo apresentou uma visão geral dos estudos que estão sendo realizados em Recuperação de Imagens Médicas baseado em Conteúdo para atingir esses objetivos.

Metodologia do Trabalho Desenvolvido

5.1 Introdução

O objetivo do presente trabalho é avaliar a eficiência das duas abordagens de Transformada *Wavelet* e *Wavelet Packet* na caracterização de imagens médicas visando a recuperação, considerando apenas suas características de textura.

Para realizar a recuperação das imagens é necessário identificar as características que possam ser usadas para traçar pontos de similaridade entre a imagem passada por parâmetro e as imagens contidas na base de dados onde será realizada a busca (WANGENHEIM, 2005).

Sistemas CBIR “ideais” deveriam automaticamente extrair e indexar o conteúdo semântico das imagens para se adequar aos requisitos de aplicações específicas. No entanto, embora pareça simples para um humano escolher uma foto dentro de uma coleção, reconhecimento e classificação automática de objetos é ainda uma das principais dificuldades em Visão Computacional.

Essa é a principal razão porque características de baixo nível como cor, textura, forma e relacionamento espacial ainda são amplamente usadas (QIAO *et al.*, 2005). Em imagens médicas, a textura tem se destacado como uma das características primitivas da imagem mais utilizada para gerar o vetor de características, devido ao seu grande potencial para distinguir as várias partes do corpo humano.

As imagens médicas contêm estruturas de passa banda orientadas e localizadas, que não podem ser caracterizadas em termos de correlações lineares ou duais. Essa distribuição localizada e compacta da energia nas imagens implica que elas tenham uma estrutura esparsa, o que significa que elas contêm componentes de alta frequência que diminuem a inata redundância, o qual permitirá que uma imagem qualquer possa ser representada com um número relativamente pequeno de descritores.

Nesse contexto, o presente trabalho visa estudar técnicas para extrair características de textura baseadas nas Transformadas *Wavelet* e *Wavelet Packet* de Haar, visando a caracterização adequada das imagens médicas.

5.2 Transformada *Wavelet* e Transformada *Wavelet Packet*

A análise multiresolução da Transformada *Wavelet* (TW) e sua generalização *Wavelet Packet* apresenta muitas funcionalidades vantajosas (CASTAÑÓN; TRAINA, 2002), que podem ser aproveitadas no processo de extração de características das imagens. Essas propriedades também facilitam a extração de características a partir dos coeficientes transformados.

Pelo fato da Transformada *Wavelet Packet* (TWP) separar melhor as frequências, conforme ilustrado pela figura 5.1, acredita-se poder contribuir para ampliar a exatidão dos resultados das consultas, embora o custo computacional necessário para gerar os novos espaços seja sensivelmente maior quando comparado com a Transformada *Wavelet*. O

elevado custo computacional é devido à considerável quantidade de cálculos executados, pois conforme explanado no capítulo 3, esta transformada matemática decompõe tanto os subespaços de aproximação quanto os subespaços de detalhes horizontais, verticais e diagonais nos níveis subseqüentes de decomposição.

Figura 5.1: (a) Imagem de RM Original. (b) TW com 2 níveis de decomposição. (c) TWP com 2 níveis de decomposição.

No presente trabalho, optou-se pela utilização da *Wavelet* de Haar, que é a *Wavelet* com os coeficientes mais simples no espaço $L^2(\mathfrak{R})$ (LIMA, 2003), logo de fácil implementação e com baixo custo computacional. Devido a essas características a *Wavelet* de Haar é amplamente utilizada em pesquisas acadêmicas. Além disso, Bianchi (2006) realizou um estudo com várias *Wavelets* (Haar, Daubechie, *Biorthogonal*, *Reserve Biorthogonal*, *Symlet* e *Coiflet*) para recuperação de imagens de faces humanas, dentre as quais a *Wavelet* de Haar e a *Biorthogonal* destacam-se com melhores resultados nos testes. O estudo também indica que as melhores taxas de recuperação são alcançadas utilizando-se níveis maiores de decomposição. Qiao *et al.* (2005) também realizaram estudos envolvendo a *Biorthogonal* para recuperação de imagens de textura.

Assim, o presente trabalho utiliza a *Wavelet* de Haar, mas realiza também um teste com a *Wavelet Biorthogonal*. Foram implementados dois, três, quatro, cinco, seis e sete níveis de decomposição nos testes, gerando uma imagem de aproximação e várias imagens de detalhes dependendo da *Wavelet* aplicada, conforme tabela 5.1.

Tabela 5.1 – Quantidade de Subimagens geradas após a decomposição.

Nível de Decomposição	Total de subimagens - TW	Total de subimagens - TWP
1º Nível	$4 = 1+3*1$	$4 = 4^1$
2º Nível	$7 = 1+3*2$	$16 = 4^2$
3º Nível	$10 = 1+3*3$	$32 = 4^3$
4º Nível	$13 = 1+3*4$	$64 = 4^4$
5º Nível	$16 = 1+3*5$	$256 = 4^5$
6º Nível	$19 = 1+3*6$	$1024 = 4^6$
7º Nível	$22 = 1+3*7$	$16384 = 4^7$

Nota-se que o aumento no número de subimagens (os termos subespaço e subbanda também são encontrados na literatura com o mesmo significado) é exponencial no caso da *Wavelet Packet*. Fato este que ocorre porque a *Wavelet* aplica um certo número de filtros H (passa-alta) e apenas um filtro G (passa-baixa). Já a *Wavelet Packet* é uma biblioteca construída pela recursão do algoritmo *Wavelet* usando mais filtros G, conforme descrevem

Coifman e Wickerhauser em seu artigo que discute justamente o uso da *Wavelet Packet* em sinais médicos e imagens e ilustrado na figura 5.2 com um sinal unidimensional (COIFMAN; WICKERHAUSER 1998).

Figura 5.2: (a) Transf. *Wavelet* Discreta. (b) Transf. *Wavelet Packet*.

É amplamente discutido na literatura que devido às propriedades da Transformada *Wavelet* é possível gerar excelentes descritores de textura usando os coeficientes obtidos ou a partir de medidas estatísticas extraídas deles. O que pretende-se aqui é avaliar se a *Wavelet Packet* pode ampliar esta capacidade. No entanto, com tantos subespaços gerados após a aplicação do algoritmo TWP, é natural questionar se todos eles contêm informações capazes de discriminar particularidades contidas nas imagens. Daí a idéia de se utilizar um algoritmo para selecionar os subespaços mais relevantes. Seleção esta, que se baseia no uso de uma função de custo, conforme descrito na seção 3.7. Como foi mencionado, uma das funções de custo mais atrativa é a baseada na Entropia, particularmente Entropia de Shannon, a qual foi aplicada nesse estudo. Mas, Wickerhauser (1991) destaca que é importante avaliar outras funções de custo, ressaltando que em seus testes a função de custo baseada no logaritmo da energia (*Log Energy*) sobressaiu-se em determinadas situações, assim esta também foi aplicada no algoritmo envolvendo a *Wavelet Packet* e posteriormente no algoritmo que aplica a *Best Basis*.

Entropia: Define-se a Entropia Shannon-Weaver da sequência $x = \{x_i\}$ por

$$H(x) = -\sum_j p_j \log p_j, \text{ onde } p_j = \frac{|x_j|^2}{\|x\|^2} \text{ e } p \log p = 0 \text{ se } p = 0. \text{ Essa não é uma função de}$$

informação de custo. Entretanto, a função $\lambda(x) = -\sum_j |x_j|^2 \log |x_j|^2$ é. Pela relação

$$H(x) = \|x\|^{-2} \lambda(x) + \log \|x\|^2, \text{ minimizando-se o segundo, minimiza-se o primeiro. Um fato}$$

clássico sobre a entropia é que $\exp H(x)$ é proporcional ao número de coeficientes necessários para representar o sinal para um erro de média dos quadrados fixo (*mean squared error*).

Logaritmo da Energia: Seja $M(x) = \sum_j \log |x_j|^2$, com $\log 0 = 0$ sempre que necessário. Essa é obviamente uma função de informação de custo que pode ser interpretada como a entropia de um processo Gauss-Markov composto de N variáveis Gaussianas randômicas de variância $\sigma_1^2 = |x_1|^2, \dots, \sigma_N^2 = |x_N|^2$. A redefinição de $\log$ para 0 é equivalente a ignorar qualquer componente invariável no processo. Minimizando essa função encontra-se a melhor aproximação para a base Karhunen-Loève para o processo, a qual atinge o mínimo global para M sobre todo grupo ortogonal. Lembrando que M é um mapa de seqüências $\{x_i\}$ para $\Re$ (WICKERHAUSER, 1991).

No capítulo 6 serão discutidos os resultados aplicando-se a Transformada *Wavelet*, *Wavelet Packet* e o algoritmo *Best Basis* para seleção das características.

5.3 Conjunto de Dados

Através de uma parceria entre o Hospital Amaral Carvalho de Jaú e o Departamento de Engenharia Elétrica, da USP, São Carlos, está sendo possível criar um Banco de Imagens Médicas que atualmente possui mais de 3.000 imagens laudadas.

O Banco de Imagens está sendo populado, em sua maioria, com imagens de exames de Medicina Nuclear e principalmente Tomografia Computadorizada de diversas partes do corpo humano, incluindo abdômen superior, abdômen inferior, crânio, pescoço, pulmão, pelve, tórax, coluna, entre outras.

As imagens de CT obtidas no Hospital Amaral Carvalho em geral possuem tamanho 512x512, codificação de 8 bits de níveis de cinza e em corte axial, conforme ilustra a figura 5.3. É importante ressaltar que um único exame de CT gera dezenas ou centenas de imagens sequenciais. Segundo profissionais da área médica, para fornecer um diagnóstico preciso é necessário analisar o conjunto completo de imagens de um único exame, porém no presente estudo na área de processamento de imagens, cada *frame* será tratado como uma imagem única que possui características próprias e particulares de cor, forma ou mais especificamente textura, atributo no qual estão concentradas as pesquisas aqui desenvolvidas.

Figura 5.3: Exemplo de uma série de Imagens de CT de Abdômen Superior em Corte Axial.

As imagens obtidas junto ao Departamento de Medicina Nuclear do Hospital possuem em sua maioria tamanho 256x256 com codificação de 8 bits de nível de cinza e coloridas, conforme amostradas na figura 5.4, embora também existam algumas imagens de tamanhos 128x128, 512x512, 1024x1024.

Figura 5.4: (a) Cintilografia Pulmonar. (b) Cintilografia do Esqueleto – Análise do Fluxo Sangüíneo Ósseo.

No referido conjunto de dados também encontram-se mais de 10.000 imagens de diversos tipos de exames, resoluções, tamanhos e codificação de cores, obtidas através da Internet em sites como MyPacs.net, MIRC.org e OsiriX¹¹, porém estas em geral não possuem laudo médico. A figura 5.5 exibe ilustração de conjuntos de imagens disponibilizadas no site para *download*.

¹¹ *Software Open Source* para visualização de imagens multidimensionais DICOM desenvolvido em parceria com o Departamento de Radiologia do Hospital Universitário de Genebra – Suíça.
<http://pubimage.hcuge.ch/>

Figura 5.5: Exemplo de uma série de Imagens de CT de Abdômen Superior em Corte Axial.

Todas as imagens estão em formato DICOM 3.0, o qual está se consolidando a cada dia como o principal padrão de arquivos utilizados em instituições médicas, conforme discutido no capítulo 4.

É imprescindível ressaltar que para a realização das pesquisas no presente trabalho, os dados pessoais de cada paciente devem ser mantidos em sigilo, respeitando as regras acordadas entre a Comissão de Ética do Hospital Amaral Carvalho e o Departamento de Engenharia Elétrica da USP, Campus São Carlos.

5.4 Conjunto de Imagens Teste

Para aplicar a Análise Multiresolução *Wavelet* e *Wavelet Packet* as imagens devem conter o mesmo número de linhas e colunas. Assim todas as imagens selecionadas para os conjuntos de teste, respeitam essa especificação.

De todas as imagens obtidas foram selecionados dois conjuntos para testes. O primeiro conjunto de imagens para teste é composto por 130 imagens de CT no formato DICOM, com tamanho 512x512 e com codificação de 8 bits de níveis de cinza. Considerando que um único exame pode gerar uma sequência de centenas de imagens e dependendo da orientação do

paciente e do tipo de corte utilizado no momento do exame, foram obtidas classes distintas de imagens dentro de uma mesma modalidade de exame. Um exemplo é amostrado na figura 5.6, que apresenta imagens de um exame de CT de Crânio, contendo 162 imagens no total, que formam subconjuntos, os quais destacam características diferenciadas de uma mesma parte do corpo humano.

Figura 5.6: Amostra de imagens de um exame de CT de Crânio.

Assim, as imagens do primeiro conjunto de teste estão subdivididas em 13 classes provenientes de exames de CT de abdômen inferior, abdômen superior, abdômen completo, tórax, pulmão, rim, coluna vertebral, cólon, intestino, crânio e cérebro. Cada classe possui imagens da mesma parte do corpo de exames diferentes e algumas do mesmo exame, simulando as bases de imagens existentes nos hospitais. A figura 5.7 apresenta uma amostra de imagem de cada classe e a tabela 5.2 descreve o conjunto selecionado.

Figura 5.7: Amostra de imagens das 13 classes selecionadas (primeiro conjunto de testes).

Tabela 5.2 – Classes de Imagens

Classe	Numeração das Imagens	Parte do Corpo	Tamanho
1	1 à 10	Abdômen Inferior	512 x 512
2	11 à 20	Abdômen Superior	512 x 512
3	21 à 30	Crânio	512 x 512
4	31 à 40	Coluna	512 x 512
5	41 à 50	Coluna	512 x 512
6	51 à 60	Abdômen/Rim	512 x 512
7	61 à 70	Crânio	512 x 512
8	71 à 80	Cólon/Intestino	512 x 512
9	81 à 90	Tórax/Pulmão	512 x 512
10	91 à 100	Tórax/Pulmão	512 x 512
11	101 à 110	Tórax	512 x 512
12	111 à 120	Coluna/Pulmão	512 x 512
13	121 à 130	Abdômen Superior	512 x 512

O segundo conjunto de imagens para teste é composto por 1.200 imagens de CT, MR e XA (*X-ray Angiography*) com tamanho 512x512, conforme exemplifica a figura 5.8. As modalidades de exames e tipo de estudo dessas imagens são descritas na tabela 5.3.

Figura 5.8: Amostra de imagens das 12 classes selecionadas (segundo conjunto de testes).

Tabela 5.3 – Classes de Imagens

Classe	Numeração das Imagens	Estudo	Modalidade	Tamanho
1	1 à 100	Lombar	MR	512 x 512
2	101 à 200	Joelho	MR	512 x 512
3	201 à 300	Denta;	CT	512 x 512
4	301 à 400	Pé (Extremidades)	CT	512 x 512
5	401 à 500	Seios da Face/Tórax	CT	512 x 512
6	501 à 600	Crânio/Tórax	CT	512 x 512
7	601 à 700	Crânio/Ombro	CT	512 x 512
8	701 à 800	Abdômen/Rim	CT	512 x 512
9	801 à 900	Abdômen	CT	512 x 512
10	901 à 1000	Angiografia	XA	512 x 512
11	1001 à 1100	Tórax	CT	512 x 512
12	1101 à 1200	Cardíaco	CT	512 x 512

Inicialmente foi selecionado um conjunto menor de imagens (130) para agilizar os testes, pois desejava-se investigar algumas questões como:

1. Quais características se demonstram mais relevantes para imagens médicas?
2. Qual nível de decomposição contribui para ampliar a exatidão dos resultados?
3. Qual a influência nos resultados ao aplicar outra família de Transformada *Wavelet*?
4. As características de segunda ordem de Haralick são muito úteis quando o objetivo é classificar imagens com base no atributo textura. Tal método poderia apresentar melhores resultados do que a Transformada *Wavelet*?
5. Haveria necessidade de uma fase de pré-processamento para melhorar a resolução das imagens antes de se aplicar a Transformada *Wavelet*?
6. Diferentes métricas podem interferir no desempenho das buscas?

Após identificar as respostas para essas e outras questões os resultados finais foram avaliados com o segundo conjunto de imagens.

5.5 Conjunto de Características

Para que possam ser efetuadas consultas baseadas em conteúdo, inicialmente as imagens coletadas são analisadas e processadas individualmente.

Duas linhas de testes são desenvolvidas. A primeira considerada a aplicação da Transformada *Wavelet* e a segunda a aplicação da Transformada *Wavelet Packet*, ambas em uma abordagem Multiresolução.

No caso da aplicação da TW e TWP para geração do espaço de características, algumas estratégias podem ser traçadas com base nos novos espaços gerados após a aplicação das transformadas. Pode-se utilizar os valores dos coeficientes *Wavelets* puros gerados após a transformada para montar os vetores, efetuar uma análise estatística em cada uma das subbandas, de forma que cada elemento do vetor corresponda a uma descrição de cada subimagem, permitindo que o conteúdo da imagem original seja corretamente descrito pelo vetor, ou ainda mesclar as duas estratégias anteriores, montando vetores com valores estatísticos e valores dos coeficientes *Wavelets* puros.

Na literatura encontram-se vários estudos objetivando principalmente a análise estatística dos valores dos coeficientes *Wavelets*. No presente trabalho, todas essas estratégias foram avaliadas para montar o espaço de características.

Para efetuar essa análise estatística há alguns valores que podem ser extraídos para destacar algumas propriedades das imagens como a luminosidade, obtida através da média e variância, a uniformidade, obtida através da energia, e a suavidade da imagem, obtida através da entropia. A entropia mede a desordem em uma imagem, ou seja, o grau de dispersão de níveis de cinza.

Dessa forma, uma vez processadas as imagens, calcula-se a média, variância, energia e entropia dos coeficientes de detalhe e aproximação de cada subespaço gerado pela TW e TWP, esses valores, são então armazenados em vetores de características para posterior análise com

as métricas de distância. Tecnicamente, a variância vem a ser a soma de todos os desvios dos dados amostrais, em relação à média, elevados ao quadrado, soma essa que depois é dividida por $(n-1)$, ou seja, pelo número de graus de liberdade da amostra. A variância da amostra, antes da divisão por $(n-1)$ seria uma grandeza representativa da variabilidade total dos dados amostrais em relação a essa mesma média amostral. Após a divisão, seria uma variância média (CAMPOS, 2002). De maneira simplista pode-se dizer que primeiro é calculada a variância da amostra, só depois é que se extrai a sua raiz quadrada, para conhecer o desvio-padrão. Assim, optou-se por empregar apenas o valor de variância dos coeficientes *Wavelets*.

A vantagem em realizar essa análise estatística nos coeficientes resultantes é que reduz-se a dimensionalidade dos dados, uma vez que cada imagem passa a ser representada por poucos valores. Considerando-se, por exemplo, as medidas estatísticas média, variância e energia dos últimos subespaços de uma decomposição em dois níveis da TW obtém-se um vetor com 12 valores, conforme apresentado na tabela 5.4. No caso da TWP, com dois níveis de decomposição foi gerado um vetor com 48 valores, descritos na tabela 5.5.

Tabela 5.4 – Vetor gerado com o segundo nível de decomposição da TW

Média				Variância				Energia			
1	2	3	4	5	6	7	8	9	10	11	12
C. Apr. CA	D. Hor. CH	D. Ver. CV	D. Diag. CD	C. Apr. CA	D. Hor. CH	D. Ver. CV	D. Diag. CD	C. Apr. CA	D. Hor. CH	D. Ver. CV	D. Diag. CD

Tabela 5.5 – Vetor gerado com o segundo nível de decomposição da TWP

Média																Variância								Energia			
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	...	32	33	34	...	48
AA2	AH2	AV2	AD2	HA2	HH2	HV2	HD2	DA2	DH2	DV2	DD2	VA2	VH2	VV2	VD2	AA2	AH2	AV2	AD2	HA2	HH2	...	VD2	AA2	AH2	...	VD2

Ao considerar-se um vetor de características montado a partir dos valores puros dos coeficientes *Wavelets* sem aplicar qualquer análise estatística, ter-se-ia subespaços de 128×128 , totalizando 65.536 elementos no vetor no caso da TW e 262.144 elementos no caso

da TWP. Tal situação certamente refletiria as consequências da “Maldição da alta dimensionalidade”, descrito na seção 2.3.

Já uma decomposição com a TW ou TWP em 7 níveis, por exemplo, geraria subespaços de 4x4, conforme descreve a tabela 5.6, nesse caso é totalmente viável usar os coeficientes *Wavelets* sem análise estatística para montar os vetores. Além disso, a investigação aqui realizada e discutida no capítulo 6 mostrou que o subespaço de aproximação, particularmente, contém informações suficientes para descrever uma imagem e consequentemente podem ser usados com êxito nas buscas por conteúdo.

Tabela 5.6 – Dimensão dos subespaços em cada nível de decomposição

Nível de Decomposição	Dimensão dos subespaços
1º Nível	256 x 256
2º Nível	128 x 128
3º Nível	64 x 64
4º Nível	32 x 32
5º Nível	16 x 16
6º Nível	8 x 8
7º Nível	4 x 4

5.6 Normalização e Uniformização dos Dados

Para analisar os dados numéricos dispostos em um espaço vetorial são necessárias ferramentas que usam alguma medida de distância. A distância Euclidiana é amplamente usada nesse tipo de problema, pois em duas ou três dimensões ela fornece um valor de distância entre os elementos semelhante ao mundo real; no entanto ela pode não ser a solução ideal para qualquer tipo de análise (FRACOIS; WERTZ; VERLEYSEN, 2005). A escolha da medida de distância envolve muitas vezes uma grande subjetividade, mas é importante analisar a natureza das variáveis (ou características extraídas das imagens), se estas são discretas, contínuas ou binárias; as escalas de medida; se as variáveis são nominais ou ordinais; o efeito que as diferenças de escala das variáveis provocam sobre o valor das

distâncias, pois as que apresentam variações e unidades de medida elevadas, facilmente anularão o efeito das outras variáveis. Para resolver esse problema é comum a prática de normalização das variáveis, de modo a tornar a sua média nula e o seu desvio padrão unitário.

Howarth *et al.* (2004), por exemplo, utilizaram em seu trabalho medidas estatísticas (média e desvio padrão) calculadas após a aplicação da Transformada *Wavelet* de Gabor vinculada às características de textura de Haralick. Devido a variação de valores, os vetores de características foram normalizados usando o desvio padrão de cada elemento no conjunto de dados completo. Em Leow e Lai (2001), os componentes do vetor de características foram normalizados dividindo o valor de cada componente pelo valor mais alto dentre os componentes. Segundo Leow, esse processo remove variações devido a diferença de intensidades, gerando obviamente novos vetores invariantes à intensidade, os quais passam a ser considerados como os vetores de características no processo de recuperação de imagens subsequente. Xue *et al.* (2007), também enfatiza que a normalização é requerida para compensar as disparidades de escala entre os componentes definidos em diferentes domínios. Ele aplica um método de normalização Gaussiana intra e inter classes.

Assim, a consequência de uma normalização ou uniformização nas características extraídas das imagens médicas aqui estudadas antes do cálculo das distâncias entre os vetores também foi observada e avaliada. As pseudo-equações 5.1 e 5.2 demonstram o cálculo realizado no presente estudo para normalizar ou uniformizar os dados.

$$\text{Normalização:} \quad Z_i = (X_i - \text{média}) / \text{DesvioPadrão} \quad (5.1)$$

$$\text{Uniformização:} \quad Z_i = (X_i - X_{\min}) / (X_{\max} - X_{\min}) \quad (5.2)$$

5.7 Função de Distância

Considerando a importância que diferentes métricas podem refletir no resultado final da recuperação, implicando inclusive em maior ou menor desempenho na precisão das respostas

trazidas pelos algoritmos, julgou-se indispensável analisar a variação de desempenho dos algoritmos de recuperação aplicando-se funções de distância distintas.

Esse teste foi realizado no conjunto de 130 imagens para teste e se repetiu no conjunto com 1200 imagens. Uma vez concluída a fase de montagem dos vetores de características, estes foram comparados utilizando as métricas Euclidiana, Euclidiana Normalizada, City-block, Mahalanobis, Minkowski, Cosseno, Hamming, Jaccard. Sendo que, as que apresentaram melhores resultados em todos os testes foram a Distância Euclidiana e a City-block, descritas nas equações 5.3 e 5.4 respectivamente.

$$\text{Euclidiana:} \quad D_{rs} = \left(\sum |x_i - y_i|^2 \right)^{1/2} \quad (5.3)$$

$$\text{City-block:} \quad D_{rs} = \left(\sum_{j=1}^n |x_{rj} - x_{sj}| \right) \quad (5.4)$$

As distâncias resultantes são ordenadas e as “ n ” menores distâncias que correspondem às imagens mais similares são recuperadas. As imagens resultantes da busca estão ordenadas da menor para a maior, ou seja, da imagem mais semelhante à de referência até a menos semelhante. Para o conjunto com 130 imagens foram consideradas as 10 imagens mais semelhantes. Assim, a resposta considerada como ideal à consulta é a exibição das 10 imagens da mesma classe. Para o conjunto com 1200 imagens foram consideradas as 100 imagens mais semelhantes.

Nesse experimento foi implementada a Consulta por Vizinhança (*k-Nearest Neighbors Queries*), onde dado um valor inteiro k , retorna os k elementos do conjunto de dados que são mais similares ao objeto central da consulta.

5.8 Técnicas Auxiliares

5.8.1 Características para Descrição de Textura de Haralick

A fim de se avaliar a recuperação das imagens médicas aqui estudadas usando as características de Haralick foi realizado um teste gerando vetores a partir de valores extraídos das matrizes de co-ocorrência. Para isto foi utilizado um algoritmo desenvolvido pelo Laboratório de Informática Biomédica da Dra. Mia K. Markey na Universidade do Texas (GUPTA; MARKEY, 2005)¹² que extrai as 13 características: (*Energy, Correlation, Inertia, Entropy, Inverse Difference Moment, Sum Average, Sum Variance, Sum Entropy, Difference Average, Difference Variance, Difference Entropy, Information measure of correlation 1, Information measure of correlation 2*). Após calcular as matrizes de co-ocorrência nas quatro direções, foi calculada a média de cada característica para armazenamento no vetor. Para recuperar as imagens médicas mais similares estes vetores foram comparados usando Distância Euclidiana. Os resultados são discutidos no capítulo 6.

5.8.2 Pré-processamento da Imagem e Algoritmos Supervisionados e Não-supervisionados.

A maioria dos trabalhos voltados para recuperação de imagens por conteúdo abordam principalmente a fase de extração de características. Em Rodrigues e Araújo (2003), uma outra vertente é explorada. Os autores argumentam que em um sistema CBIR a fase de pré-processamento da imagem pode ser decisiva para ampliar a eficiência das buscas. Eles implementaram um algoritmo chamado GRAS (*Grass Region Arrow Shot*), que antes de extrair as características da imagem, aplica uma filtragem visando diminuir o ruído e definir as regiões onde o algoritmo de extração irá trabalhar. As operações realizadas na fase de pré-

¹² Haralick Texture Features Matlab Toolbox VERSION 0.1b
<http://bmil.bme.utexas.edu/publications>

processamento são clássicas e constam de eliminação de ruído usando o filtro da média e detecção de bordas com o filtro de Sobel. Em alguns casos, eles eliminam pequenas regiões da imagem através de operações morfológicas como a dilatação. Os resultados desse trabalho mostram que mesmo utilizando um processamento simples, obtém-se resultados satisfatórios na fase de extração e consequentemente nas pesquisas, esse ganho pode representar de 5 a 60% dependendo do perfil das imagens contidas na base de dados.

Considerando essa idéia analisou-se o benefício que uma fase de pré-processamento antes do cálculo dos coeficientes com a Transformada *Wavelet* poderia trazer na recuperação das imagens aqui estudadas.

O filtro da média pode ser implementado usando uma máscara 3x3 com todos os coeficientes igual a 1, dividindo o resultado da operação por um fator de normalização, nesse caso igual a 9. Na escolha do tamanho da máscara deve-se considerar que quanto maior a máscara, maior o grau de borramento da imagem resultante. As figuras 5.9 apresentam uma imagem onde foi aplicado convolução com uma máscara 3x3 ou 5x5. A diferença é mínima e o restante da base apresentou basicamente o mesmo comportamento.

Figura 5.9: (a) Imagem Original. (b) Convolução com Máscara 3x3. (c) Convolução com Máscara 5x5.

Informações adicionais sobre esses conceitos podem ser encontradas em (GONZALEZ; WOODS, 2000).

5.9 Materias

Os experimentos foram realizados utilizando equipamento com processador Intel Core 2 Duo de 1.8Ghz, 2Gb de memória de RAM, 2Mb de cache e 120Gb de HD de 5.400rpm (rotações por minuto). A informação sobre o cache é importante, pois ao repetir a busca muitas informações já se encontram no cache da máquina, tendendo a ser mais rápida. A informação sobre a capacidade física do HD nesse caso é irrelevante, mas a informação sobre a velocidade do disco é útil, pois quanto maior, mais rápido as informações serão carregadas para a memória. Os algoritmos foram desenvolvidos com o auxílio da ferramenta Matlab versão 7.0 (R14).

Resultados e Conclusões

6.1 Considerações Iniciais

Neste capítulo será apresentada uma descrição dos experimentos desenvolvidos, resultados e conclusões obtidas com as técnicas baseadas nas Transformadas *Wavelet* e *Wavelet Packet* e o algoritmo *Best Basis* descritos no capítulo 3. A decomposição *Wavelet* localiza descontinuidades, enquanto que a análise da melhor base (*Best Basis*) encontra as frequências vibrantes e a representação ótima dentro da biblioteca. O objetivo é investigar se essas variações da Transformada *Wavelet* original refletem de maneira positiva para extração das características nas imagens e consequentemente aumentem o desempenho das buscas. Estabelece-se um comparativo entre o desempenho das transformadas. Além, de avaliar outros itens que interferem no processo de busca como a escolha da medida de dissimilaridade, a normalização e uniformização dos dados e a combinação das características extraídas para montagem dos vetores.

Vale ressaltar que a principal *Wavelet* usada nos testes foi a *Wavelet* de Haar por razões já discutidas na seção 5.2, mesmo que omitida das instruções do experimento. Quando a *Wavelet Biorthogonal* for empregada esta será mencionada no texto.

6.2 Análise do Nível de Decomposição

Para realizar alguns testes fundamentais para esse estudo, foram inicialmente separadas 130 imagens de CT e MR com tamanhos 512x512, conforme descrito na seção 5.4. Assim, os testes descritos a seguir baseiam-se nesse primeiro conjunto de teste. Ao utilizar a Transformada *Wavelet* para extrair características de imagens, uma das questões a serem respondidas é quantos níveis de decomposição aplicar para obter resultados satisfatórios, ou ainda em qual nível de decomposição os resultados obtidos são melhores, além de qual dos coeficientes gerados contém informações mais relevantes. Dessa forma, um dos primeiros testes realizados visava aplicar a transformada em cada imagem e montar vetores de características usando apenas os coeficientes de aproximação ou detalhes horizontais, verticais ou diagonais do último nível de decomposição, a figura 6.1 ilustra os filtros aplicados e os coeficientes gerados pela decomposição.

Figura 6.1: Decomposição *Wavelet* em dois níveis.

As informações do espectro são armazenadas na banda de aproximação, logo esses coeficientes contêm informações suficientes para descrever a imagem, uma vez que é uma versão passa-baixa da imagem original, por isto sobressaíram-se nos testes. As imagens de detalhes, grosso modo, nada mais são do que a representação das bordas em cada uma das direções obtidas pela transformada. Foram gerados vetores de características com tamanhos variados de acordo com o nível de decomposição, conforme a tabela 6.1.

Tabela 6.1 – Número de Elementos no Vetor: Coeficientes *Wavelets*

Decomposição	Tamanho da Imagem	No. de Elementos no Vetor
2º Nível	128 x 128	16.384
3º Nível	64 x 64	4.096
4º Nível	32 x 32	1.024
5º Nível	16 x 16	256
6º Nível	8 x 8	64
7º Nível	4 x 4	16

Os resultados podem ser analisados a partir de gráficos *Recall x Precision*, exibidos na figura 6.2. Os vetores foram comparados usando distância Euclidiana e nota-se que os coeficientes de aproximação alcançaram maior precisão nas buscas em todos os níveis.

Outro fato notável é que embora o 6º nível gere uma matriz 8x8, o que implicará em um vetor de apenas 64 valores, foi o que manteve maior média geral (93%) contra 81% usando vetores com coeficientes de detalhes horizontais, 76%, com detalhes diagonais e 82% com detalhes verticais. Ressaltando mais uma vez a capacidade das *Wavelets* em representar dados com poucos valores, além disso, os coeficientes de aproximação guardam informações de textura e forma da imagem original, já os coeficientes de detalhes enfatizam as discrepâncias entre as frequências, ressaltando as altas frequências. A diferença de valores entre os coeficientes também deve ser considerada com um fator relevante, coeficientes de aproximação possuem uma escala de valores mais altos que os demais coeficientes, o que pode implicar em maior poder de discriminação. A matriz de confusão, exibida na figura 6.3

comprova esses dados e demonstra que poucas classes se misturaram. Das 13 classes, 8 classes recuperaram 100% das imagens corretas em todas as buscas. As demais matrizes geradas com os coeficientes de detalhes do 6º nível de decomposição podem ser encontradas no Apêndice A.

Figura 6.2: Eficiência de recuperação usando vetores com coeficientes *Wavelets* (TW).

	Transformada Wavelet com seis níveis de decomposição - Coeficientes de aproximação												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	99%	0%	0%	0%	0%	1%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	85%	0%	15%	0%	0%	0%	0%
Classe 8	0%	0%	10%	0%	0%	0%	0%	90%	0%	0%	0%	0%	0%
Classe 9	0%	0%	0%	0%	0%	0%	59%	0%	41%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	97%	3%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Distância Euclidiana

Matriz 8x8

Eficiência de Recuperação: 93%

Figura 6.3: Matriz de confusão – TW com 6 níveis, coeficientes de aproximação.

6.3 Resultados obtidos com a Normalização e Uniformização dos Dados

Analisando os valores dos coeficientes de aproximação das diversas imagens do conjunto de teste, nota-se que há diferenças a serem consideradas. Assim, optou-se por realizar uma uniformização nos dados, de forma que todos os valores fiquem compreendidos no intervalo de 0 a 1 e também uma normalização a fim de eliminar qualquer grande diferença de valores entre os dados, usando as equações descritas na seção 5.6. No caso dos CA (Coeficientes de Aproximação) tais métodos não geraram impacto no desempenho das buscas, as matrizes de confusão exibidas nas figuras 6.4 e 6.5 resultam em média de eficiência de 93% com os dados normalizados, exatamente o mesmo valor obtido com os vetores de valores puros dos coeficientes de CA e 92% com os dados uniformizados. A única variação perceptível refere-se a média de acerto individual de algumas classes, as quais estão destacadas nas matrizes de confusão. No entanto, ao trabalhar com características distintas nos testes demonstrados a partir da seção 6.10 verifica-se que esses processos geram grandes diferenças nos resultados finais.

	Transformada Wavelet com seis níveis de decomposição - Coeficientes de aproximação NORMALIZADOS												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	99%	0%	0%	0%	0%	1%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	97%	0%	1%	0%	2%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	84%	0%	16%	0%	0%	0%	0%
Classe 8	0%	0%	13%	0%	0%	0%	0%	85%	0%	0%	0%	0%	2%
Classe 9	0%	0%	0%	0%	0%	0%	56%	0%	44%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	98%	2%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Distância Euclidiana Matriz 8x8 Eficiência de Recuperação: 93%

Figura 6.4: Matriz de confusão¹³ – TW com 6 níveis, CA normalizados.

	Transformada Wavelet com seis níveis de decomposição - Coeficientes de aproximação UNIFORMIZADOS												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	96%	0%	1%	0%	3%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	80%	0%	20%	0%	0%	0%	0%
Classe 8	0%	0%	17%	0%	0%	0%	0%	79%	0%	0%	0%	0%	4%
Classe 9	0%	0%	0%	0%	0%	0%	56%	0%	44%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	97%	3%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Distância Euclidiana Matriz 8x8 Eficiência de Recuperação: 92%

Figura 6.5: Matriz de confusão – TW com 6 níveis, CA uniformizados.

6.4 Análise da Wavelet Biorthogonal

Conforme discutido na seção 5.2, alguns autores usam a *Wavelet Biorthogonal* ao invés da *Wavelet* de Haar para extração de características alegando melhores resultados. Sabe-se que simetria e reconstrução exatas são incompatíveis (exceto para *Wavelet* de Haar) se os mesmos filtros FIR (*Finite Impulse Response*) são usados para reconstrução e decomposição. Assim, a *biorthogonal* utiliza duas funções base *wavelet* ao invés de uma, sendo uma para decomposição e outra para reconstrução, visando simetria com suporte compacto. Assim, tal *Wavelet* foi implementada para análise com 6 níveis de decomposição, montando sempre o vetor com todos os coeficientes de aproximação do último nível. As *Wavelets* Biortogonais bior1.1, bior1.3, bior1.5, bior2.2, bior2.4, bior2.6, bior2.8, bior3.1, bior3.5, bior3.7, bior3.9,

¹³ A eficiência de recuperação é a obtida pela média da diagonal principal da matriz de confusão

bior4.4, bior5.5, bior6.8, onde *biorN.N* indica o número de momentos nulos dos filtros de análise e síntese, os quais devem possuir a mesma altura, foram testadas e comparadas com os resultados da *Wavelet* de Haar.

Observa-se nos gráficos *Recall x Precision* exibidos na figura 6.6 que a Bior1.1 possui desempenho semelhante a *Wavelet* de Haar. As demais Biortogonais demonstram resultados abaixo dos já obtidos. Isto porque a Bior1.1 utiliza os mesmo filtros de Haar, conforme exibe a figura 6.7 e a matriz de confusão na figura 6.8 consolida essa informação.

Figura 6.6: *Recall x Precision* comparativo entre as *Wavelets* de Haar e *Biorthogonal*

Figura 6.7: Filtros da *Wavelet Biorthogonal* 1.1 (LE-TIEN; CHIEN, 2004).

No primeiro gráfico da figura 6.6 que compara a *Wavelet* de Haar com as Biortogonais 1.1, 1.3, 1.5 cabe uma observação à Bior1.3 e Bior1.5 que apresentaram bom desempenho enquanto a faixa de revocação é menor, buscando cerca de 60% da base. Ao ampliar a faixa de busca, no entanto, os valores dos coeficientes extraídos perdem um pouco seu poder em separar as imagens, fazendo com que deixem de ser tão eficiente. Analisando o gráfico verifica-se que isto é mais nítido na Bior1.5, que embora a curva demonstre excelente desempenho nas buscas com revocação menor, acaba literalmente “despencando” conforme as revocações aumentam. Já a *Wavelet* de Haar e Bior1.1 mantém um boa média de recuperação para a toda base.

Nota-se que a matriz de confusão da Bior1.1 ilustrada na figura 6.8 exibe exatamente os mesmo valores da matriz de confusão gerada com *Wavelet* de Haar e consequentemente a mesma média de eficiência.

	Transformada Wavelet com seis níveis de decomposição - Coeficientes de aproximação - Biortogonal 1.1												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	99%	0%	0%	0%	0%	1%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	85%	0%	15%	0%	0%	0%	0%
Classe 8	0%	0%	10%	0%	0%	0%	0%	90%	0%	0%	0%	0%	0%
Classe 9	0%	0%	0%	0%	0%	0%	59%	0%	41%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	97%	3%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Distância Euclidiana Matriz 8x8 Eficiência de Recuperação: 93%

Figura 6.8: Matriz de confusão da *Biorthogonal* 1.1 com 6 níveis de decomposição.

Assim, considerando que os resultados foram inferiores à *Wavelet* de Haar e nos testes realizados por Bianchi (2006) essas foram as *Wavelets* com melhores desempenhos para extrair características de imagens para posterior recuperação, definiu-se para a continuidade das análises, utilizar a *Wavelet* de Haar. Obviamente que, diferentes *Wavelets* podem apresentar desempenhos distintos dependendo do conjunto de dados a ser analisado, mas, testar várias *Wavelets* para avaliar qual delas é mais adequada para o conjunto de dados em questão, está fora do escopo deste projeto. Essa tarefa, no entanto, pode ser desenvolvida em um trabalho futuro.

6.5 Resultados obtidos com Imagens pré-processadas

Conforme descrito no item 5.2.7.2 da metodologia, alguns autores pré-processam as imagens antes da fase de extração de características.

As matrizes de confusão do Apêndice B apresentam exatamente os mesmos valores de recuperação ao se usar um filtro da média de 3x3 ou 5x5 convoluída com a imagem. A média de eficiência de recuperação ficou em 92%, ou seja, 1% menor que os resultantes obtidos usando os coeficientes de aproximação *Wavelet*, o que se observa ao comparar as matrizes é

que algumas classes que não haviam atingido 100% de acerto em todas as buscas passou a atingir esse valor. Por outro lado, determinadas classes registraram queda no desempenho.

O filtro de Sobel também foi aplicado nas imagens da base de estudo. Esse filtro permite detectar bordas nos pontos onde o gradiente da imagem é maior. A figura 6.9 ilustra o processo. Porém, novamente a média da matriz de confusão resultou em 92% de eficiência de recuperação, mostrando que para o conjunto de dados desse estudo, tais técnicas não agregaram melhorias.

Figura 6.9: (a) Imagem Original. (b) Filtro de Sobel

6.6 Análise utilizando as Características de Haralick

De acordo com argumentação preliminar na seção 5.8.1, as características de textura propostas por Haralick extraídas de matrizes de co-ocorrência são exaltadas por muitos autores como excelente mecanismo para descrição de textura. Dessa forma, visando avaliar o comportamento de tais medidas estatísticas de segunda ordem no conjunto de dados aqui estudado, foi aplicado um algoritmo que calcula a matriz SGLD (*Spatial Grey Level Dependence*). De acordo com o autor do algoritmo¹⁴ é recomendável que inicialmente a imagem tenha seu histograma equalizado, para depois ser passada como parâmetro de entrada para o algoritmo, juntamente com a distância entre os pixels e ângulo para cálculo da matriz

¹⁴ Laboratório de Informática Biomédica da Dra. Mia K. Markey na Universidade do Texas
<http://bmil.bme.utexas.edu/publications>

SGLD. Para cada imagem do banco foram calculadas quatro matrizes de co-ocorrência nos seguintes ângulos (0° , 45° , 90° , 135°) e dessas matrizes foram extraídas as 13 características (*Energy*, *Correlation*, *Inertia*, *Entropy*, *Inverse Difference Moment*, *Sum Average*, *Sum Variance*, *Sum Entropy*, *Difference Average*, *Difference Variance*, *Difference Entropy*, *Infomation measure of correlation 1*, *Information measure of correlation 2*). Após cálculo das diferentes matrizes e das medidas estatísticas, foi extraída a média de cada uma dessas 13 características de textura das quatro matrizes gerando um vetor final com a média das mesmas.

A comparação desses vetores foi realizada usando distância Euclidiana, no entanto a média de acerto da Matriz de confusão ficou muito abaixo quando comparada com a utilização dos coeficientes de aproximação, conforme pode ser observado na figura 6.10, 38% neste caso, contra 93% para a recuperação com os coeficientes de aproximação (ver figura 6.3). Essas características extraídas são globais, talvez uma segmentação na imagem antes da extração das características poderia contribuir positivamente para melhorar os resultados, pois assim poder-se-ia aplicar Haralick especificamente na região segmentada, analisando dessa forma regiões específicas da imagem. O fato é que nesse caso, o foco do trabalho voltar-se-ia ao estudo das características de Haralick, o que não é o objetivo aqui. “Haralick” apenas foi aplicado como uma tentativa de ampliar o desempenho nas buscas e para analisar qual seria o comportamento dessa técnica no conjunto de dados estudado. Mas, fica a ressalva para uma investigação futura.

13 Características de Haralick: média das medidas estatísticas nos ângulos 0, 45, 90 e 135 graus													
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	63%	0%	7%	0%	0%	5%	0%	14%	2%	9%	0%	0%	0%
Classe 2	0%	50%	0%	14%	0%	4%	0%	0%	6%	3%	0%	7%	16%
Classe 3	7%	0%	46%	0%	1%	2%	5%	2%	0%	7%	15%	15%	0%
Classe 4	0%	19%	0%	26%	12%	18%	2%	2%	4%	3%	3%	6%	5%
Classe 5	0%	0%	5%	6%	53%	12%	22%	0%	0%	0%	0%	2%	0%
Classe 6	5%	5%	6%	10%	14%	20%	8%	6%	8%	4%	2%	5%	7%
Classe 7	0%	0%	8%	0%	24%	7%	32%	0%	7%	4%	18%	0%	0%
Classe 8	24%	0%	5%	1%	0%	11%	0%	22%	7%	7%	2%	17%	4%
Classe 9	2%	5%	0%	2%	0%	6%	6%	9%	34%	10%	12%	0%	14%
Classe 10	9%	0%	3%	2%	0%	6%	5%	11%	10%	31%	22%	0%	1%
Classe 11	0%	0%	6%	0%	0%	1%	8%	2%	6%	18%	54%	4%	1%
Classe 12	0%	5%	18%	3%	0%	5%	0%	18%	1%	0%	4%	41%	5%
Classe 13	0%	32%	0%	6%	0%	6%	0%	2%	15%	7%	0%	4%	28%

Distância Euclidiana Eficiência de Recuperação: 38%

Figura 6.10: Matriz de confusão gerada a partir das 13 Características de Haralick.

6.7 Algoritmo Não supervisionado

Conforme discutido na seção 5.8.2 e considerando-se os resultados descritos na seção 6.2, onde o melhor desempenho de recuperação foi obtido usando-se apenas os Coeficientes de Aproximação, decidiu-se avaliar o desempenho de cada grupo de coeficientes (CA, CH, CV, CD). O segundo melhor resultado obtido, neste caso, ficam os Coeficientes Horizontais para gerar o vetor, o terceiro melhor resultado foi obtido com os Coeficientes Verticais e em último lugar com os Coeficientes Diagonais, conforme demonstra a tabela 6.2.

Tabela 6.2 – Média de Acertos em cada Classe usando CA, CH, CD ou CV no vetor

	CA	CH	CD	CV
Classe 1	10,00	10,00	10,00	10,00
Classe 2	9,90	10,00	9,60	10,00
Classe 3	10,00	10,00	9,90	10,00
Classe 4	9,90	5,40	4,90	5,70
Classe 5	10,00	6,60	10,00	6,10
Classe 6	10,00	9,70	5,00	5,00
Classe 7	8,50	9,60	9,30	9,00
Classe 8	9,00	5,90	3,50	8,20
Classe 9	4,10	3,90	2,80	2,70
Classe 10	10,00	8,80	6,70	9,70
Classe 11	9,70	7,90	8,60	9,70
Classe 12	10,00	9,80	10,00	10,00
Classe 13	10,00	8,30	8,40	10,00
Média Geral	9,32	8,15	7,59	8,16

Utilizando a imagem 31 (número que representa a imagem no conjunto de testes) como exemplo, cujas imagens da mesma classe são identificadas pelos números de 31 a 40, verifica-se que há variação no resultado das buscas quando considera-se apenas CA, CH, CV ou CD como elementos do vetor. Na tabela 6.3, observa-se que a busca com CA traz 9 imagens corretas das dez possíveis. A busca com CD traz a imagem 40 não constante nas buscas com CA, CH e CV. Assim, utilizando-se todos os coeficientes em uma busca não-supervisionada, avaliou-se o possível aumento de desempenho de recuperação sem a intervenção do usuário,

através de um algoritmo não-supervisionado que utilizasse as melhores taxas de cada conjunto de características (CA, CH, CV ou CD).

Tabela 6.3 – Recuperação da Imagem 31 usando Vetor com Diferentes Coeficientes

CA	31	32	33	39	35	37	36	34	38	81
CH	31	32	33	39	37	35	34	88	85	66
CV	31	32	33	39	81	37	63	62	64	61
CD	31	32	33	39	40	34	81	85	83	66

O algoritmo proposto possui os seguintes passos:

1. Decomposição da imagem com a Transformada *Wavelet* de Haar em 6 níveis (melhor resultado obtido);
2. Cálculo dos coeficientes de aproximação, detalhes horizontais, verticais e diagonais (CA, CH, CV e CD), armazenando-os em vetores independentes;
3. Comparação do vetor contendo CA da imagem de referência (imagem identificada como 31, por exemplo) com os demais vetores usando a Distância Euclidiana e registro do resultado;
4. Comparação do vetor contendo CH da imagem de referência com os demais vetores usando a Distância Euclidiana e registro do resultado. Idem para CD e CV;
 - a. Após esses passos o algoritmo identificará as 40 imagens mais semelhantes à imagem de referência.
5. Análise dos resultados e escolha das 10 imagens mais similares dentre as 40 encontradas, sem repetição.

A matriz de confusão exibida na figura 6.11 descreve o desempenho das buscas usando essa metodologia. O que nota-se é que mais uma tentativa em elevar os resultados mostrou-se insuficiente para tal propósito. A média de eficiência ficou em torno de 78% contra 93% obtidos apenas com CA do 6º nível.

	Transf. Wavelet com seis níveis de decomposição - Algoritmo não-Supervisionado												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	97%	0%	0%	2%	0%	0%	0%	1%	0%	0%	0%	0%
Classe 3	0%	0%	99%	0%	1%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	57%	0%	0%	13%	0%	30%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	99%	0%	1%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	73%	11%	0%	16%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	93%	0%	7%	0%	0%	0%	0%
Classe 8	0%	0%	22%	0%	34%	0%	0%	35%	0%	0%	0%	5%	4%
Classe 9	0%	0%	0%	0%	0%	0%	72%	0%	28%	0%	0%	0%	0%
Classe 10	0%	0%	0%	18%	0%	0%	0%	0%	14%	68%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	86%	4%	10%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	3%	13%	84%

Distância Euclidiana

Matriz 8x8

Eficiência de Recuperação: 78%

Figura 6.11: Matriz de confusão resultante da aplicação do algoritmo não-supervisionado.

6.8 Análise de Métricas para Cálculo da Dissimilaridade

Aqui são apresentados os resultados dos testes mencionados na seção 5.7, envolvendo métricas distintas. Durante a revisão bibliográfica pôde-se observar que diferentes autores utilizam métricas distintas, cada um enfatizando sua escolha. O desempenho da métrica depende do conjunto de dados e principalmente das características extraídas e do tipo de distribuição gerada por essas características. Assim, julgou-se necessário validar os resultados utilizando as principais métricas encontradas na literatura. O cálculo da dissimilaridade entre a imagem de referência e as demais imagens da base foi implementado utilizando-se as seguintes métricas: Euclidiana, Euclidiana Normalizada, City-block, Mahalanobis, Minkowski, Jacard, Coseno, Hamming, Correlação.

O gráfico exibido na figura 6.12 apresenta uma consolidação dos testes realizados e no Apêndice C, podem ser encontradas as matrizes de confusão obtidas. A distância de Mahalanobis é apropriada quando existem significantes diferenças nos dados, uma vez que ela ressalta a variabilidade entre os dados baseada na matriz de covariância. O resultado inferior mostra que os dados (imagens da base) não possuem grande variância entre si. Os testes também mostram que embora a distância Euclidiana seja muito difundida para recuperação de imagens e várias outras aplicações realmente pode não ser a solução ideal para qualquer tipo

de análise, fato que fica mais evidente ao se utilizar o segundo conjunto de testes com 1200 imagens. Por fim, a distância City-block ou Manhattan demonstrou ser a mais adequada para os dados aqui analisados e consequentemente passou a ser utilizada nos testes que se seguem a partir desse ponto.

Figura 6.12: Desempenho das métricas de dissimilaridade.

6.9 Ampliação da Base de Testes

Os testes realizados na base inicial de 130 imagens objetivaram identificar técnicas que otimizassem a recuperação das imagens médicas. Além disso, tais técnicas precisavam ser aplicadas na análise da Transformada *Wavelet Packet*. Assim, da base de imagens atual obtida no Hospital Amaral Carvalho de Jaú e de outros conjuntos de imagens de exames variados disponíveis on-line (ver seção 5.3), foi montado o segundo conjunto de testes com 1.200 imagens de CT, MR e XA (*X-ray Angiography*), com tamanho 512x512, em níveis de cinza, separadas em 12 classes com 100 imagens cada.

As referidas imagens foram selecionadas com auxílio de técnicas de análise de agrupamentos explanadas na seção 2.6.3. A matriz de distâncias City-block, calculada com

base nos vetores com CA do 6º nível foi passada como parâmetro para geração dos *clusters*. Vários métodos de ligação foram avaliados na geração dos agrupamentos (ligação simples, ligação completa, ligação média, centróide, *weighted*¹⁵, mediana¹⁶ e *ward*¹⁷). O número máximo de agrupamentos considerado foi doze. Assim, uma separação ideal apresentaria 100 elementos da mesma classe em cada agrupamento. A tabela 6.4 mostra a quantidade de elementos em cada *cluster* e um resumo de quantas e quais classes cada método de ligação conseguiu criar sem haver qualquer mistura com elementos de classes distintas. Na referida tabela, observa-se que usando o método de ligação *ward* foi possível separar 8 classes das 12 existentes com 100% de precisão, ou seja, os 100 elementos agrupados pertencem a mesma classe. A tabela 6.5 discrimina quais tipos de elementos foram agrupados em cada *cluster* e a figura 6.13 apresenta o Dendograma resultante com valor de corte igual a 12. O uso dessas técnicas ajudou na seleção das imagens, indicando de certa forma quais classes teriam maior probabilidade de se misturar.

Tabela 6.4 – Agrupamentos gerados de acordo com o método de ligação

	Método de ligação						
	Simple	Completa	Média	Centróide	Weighted	Median	Ward
Cluster 1	431	403	427	427	427	427	244
Cluster 2	67	51	61	70	44	48	55
Cluster 3	1	35	2	3	17	19	87
Cluster 4	1	9	10	100	102	102	100
Cluster 5	100	102	100	100	10	4	100
Cluster 6	221	100	100	100	100	100	100
Cluster 7	79	100	100	100	100	100	100
Cluster 8	14	100	100	14	100	100	100
Cluster 9	86	100	14	86	100	100	100
Cluster 10	100	14	86	100	14	14	14
Cluster 11	36	86	100	36	86	86	100
Cluster 12	64	100	100	64	100	100	100
Número de classes separadas	2	6	6	5	6	6	8
Identificação das classes separadas	2, 11	3, 5, 6, 8, 11, 12	3, 5, 6, 8, 11, 12	3, 5, 6, 8, 11	3, 5, 6, 8, 11, 12	3, 5, 6, 8, 11, 12	3, 4, 5, 6, 7, 8, 11, 12

¹⁵ *Weighted*: distância media ponderada (WPGMA)

¹⁶ Mediana: distância do centro de massa ponderada (WPGMC)

¹⁷ *Ward*: algoritmo da distância mínima.

Tabela 6.5 – Discriminação dos elementos em cada *cluster*

Agrupamento	Qtde. de elementos	Identificação
<i>Cluster 1</i>	244	Classe 1 completa, elementos da classe 2 e 10
<i>Cluster 2</i>	55	Elementos da classe 2
<i>Cluster 3</i>	87	86 elementos da classe 9 e elemento 178 (classe 2)
<i>Cluster 4</i>	100	Classe 3
<i>Cluster 5</i>	100	Classe 4
<i>Cluster 6</i>	100	Classe 5
<i>Cluster 7</i>	100	Classe 6
<i>Cluster 8</i>	100	Classe 7
<i>Cluster 9</i>	100	Classe 8
<i>Cluster 10</i>	14	Elementos da classe 9
<i>Cluster 11</i>	100	Classe 11
<i>Cluster 12</i>	100	Classe 12

Figura 6.13: Dendrograma de agrupamento das classes.

6.10 Recuperação das Imagens usando a Transformada Wavelet

As informações coletadas com base nos testes anteriores destacam detalhes importantes que devem ser considerados em um sistema de recuperação de imagens por conteúdo. A normalização ou uniformização nos dados pode alterar o desempenho final de um sistema CBIR, além disso, quando se trata da utilização da Transformada *Wavelet* cada nível de decomposição pode identificar características distintas que contibuem ou não para o processo, e a escolha da métrica revelou-se como um fator decisivo. Ao ampliar o número de imagens

para o conjunto de testes finais julgou-se relevante revalidar algumas técnicas anteriores, a fim de se obter dados mais concretos que comprovem a eficiência da metodologia aplicada.

O primeiro passo nessa etapa consistiu em aplicar a Transformada *Wavelet* decompondo as 1200 imagens em 2, 3, 4, 5, 6 e 7 níveis. Em cada nível de decomposição foram gerados vetores com características distintas. Trabalhou-se com vetores cujos elementos eram todos os coeficientes *wavelet* e vetores cujos elementos eram medidas estatísticas de primeira ordem obtidas dos coeficientes *wavelet*, além de vetores que mesclavam esses dados, conforme descritos na tabela 6.6, sempre considerando o último nível de decomposição, o que gerou vetores de tamanhos distintos dependendo das características e nível de decomposição utilizado.

Tabela 6.6 – Composição dos Vetores de Características: Transf. *Wavelet*

Características no vetor	Abreviação
Coeficientes de Aproximação	CA
Coeficientes de Aproximação + Coefic. de Detalhe Horizontal + Coefic. de Detalhe Vertical + Coefic. de Detalhe Diagonal	CA + DH + DV + DD
Coeficientes de Aproximação + Média, Variância e Energia dos Coeficientes de Aproximação	CA + MVE da CA
Coeficientes de Aproximação + Média, Variância e Energia dos Coeficientes de Aproximação, Detalhe Horizontal, Detalhe Vertical e Detalhe Diagonal	CA + MVE (ca, dh, dv, dd)
Média, Variância e Energia dos Coeficientes de Aproximação, Detalhe Horizontal, Detalhe Vertical e Detalhe Diagonal	MVE (ca, dh, dv, dd)
Coeficientes de Aproximação + Entropia Global da Imagem	CA + EntropGlobal
Coeficientes de Aproximação + Entropia da Imagem de Aproximação	CA + Entrop(ca)

O cálculo da dissimilaridade entre esses vetores empregou as Distâncias City-block e Euclidiana, a fim de comprovar através de uma base maior a diferença de desempenho entre elas, pois se a distância City-block mostrou-se superior à Euclidiana em uma base de teste com 130 imagens, tal fato deveria se repetir com as 1200 imagens. De todas as matrizes de confusão geradas com os vetores da tabela 6.6, em 90% delas a distância City-block apresentou maior eficiência, atingindo pico de 26,07% e mantendo média de 5,23% superior à distância Euclidiana. Esses dados podem ser observados na tabela 6.7 que apresenta uma

síntese dos testes realizados envolvendo a Transformada *Wavelet*. Nessa tabela, encontram-se a quantidade de elementos que compõe o vetor, além da média da diagonal da matriz de confusão em cada nível de decomposição e para cada tipo de vetor, totalizando 41 testes. A tabela também estabelece um comparativo entre as métricas.

O primeiro melhor resultado – 91,36% de eficiência na recuperação – ocorre no 7º nível de decomposição, usando um vetor com 64 elementos composto pelas linhas de uma matriz 4x4 de coeficientes de aproximação, detalhe horizontal, detalhe vertical e detalhe diagonal do último nível de decomposição ($4 * (4 * 4)$). Já no segundo melhor resultado – 91,15% de eficiência – observa-se um empate entre a recuperação com um vetor de 64 elementos formado por uma matriz 8x8 dos coeficientes de aproximação do 6º nível de decomposição e um vetor com 65 valores formado pela matriz 8x8 dos coeficientes de aproximação acrescidos do valor de entropia da subimagem gerada no 6º nível. Uma vez comprovada que realmente a métrica interfere no desempenho de recuperação e que para o conjunto de dados aqui estudados a City-block sobressai-se às demais, precisava-se constatar a interferência de um processo de normalização ou uniformização nesses vetores antes do cálculo da dissimilaridade.

Dessa forma, foi implementada uma alteração no algoritmo para que após a extração dos coeficientes ou das medidas estatísticas, esses dados fossem normalizados ou uniformizados antes de serem passados como parâmetros para recuperação. Os novos resultados após uniformização são comparados com os anteriores e sintetizados na tabela 6.8. Observa-se que o primeiro melhor resultado, passou de 91,36% para 91,59%, percentualmente a diferença é pequena, mas algumas alterações devem ser enfatizadas:

1. Esse resultado ocorreu no 5º nível de decomposição e não mais no 7º nível diminuindo assim o tempo de processamento.

2. O vetor que gerou esse resultado é composto por 268 elementos composto de uma matriz 16x16 de coeficientes de aproximação, acrescido de valores estatísticos de média,

variância e energia de cada um dos subespaços gerados no 5º Nível, contra os 64 elementos do melhor resultado anterior.

Já o segundo melhor resultado não sofreu tanta variação, uma vez que emprega um vetor com 64 elementos provenientes de uma matriz 8x8 dos CA do 6º nível.

A mesma variação também pode ser observada na tabela 6.9 que apresenta uma síntese das médias de eficiência de recuperação obtidas a partir das matrizes de confusão geradas calculando-se a dissimilaridade entre vetores normalizados, onde tanto o primeiro quanto o segundo melhor resultado derivaram de vetores com CA acrescido de medidas estatísticas. Assim, pode-se afirmar que operações de normalização e uniformização de dados certamente interferem no desempenho da recuperação, mas é preciso uma avaliação cautelosa sobre os ganhos conseguidos antes de qualquer generalização.

Tabela 6.7 –Comparativo das médias de eficiência de recuperação usando as distâncias City-block e Euclidiana para cálculo da dissimilaridade entre vetores com valores “puros”, obtidas a partir de matrizes de confusão.

Transformada Wavelet																		
	2º Nível			3º Nível			4º Nível			5º Nível			6º Nível			7º Nível		
Características no Vetor	Qtde	Cityblock	Euclidiana	Qtde	Cityblock	Euclidiana	Qtde	Cityblock	Euclidiana	Qtde	Cityblock	Euclidiana	Qtde	Cityblock	Euclidiana	Qtde	Cityblock	Euclidiana
CA	16.384	87,75%	84,04%	4.096	88,52%	85,67%	1.024	89,70%	87,76%	256	90,94%	89,75%	64	91,15%	90,45%	16	88,60%	88,47%
CA+DH+DV+DD	65.536	inviável		16.384	83,12%	84,04%	4.096	83,49%	85,67%	1.024	84,65%	87,76%	256	88,12%	89,75%	64	91,36%	90,45%
CA + MVE da CA	16387	88,64%	62,57%	4099	82,94%	59,02%	1027	70,38%	60,36%	259	64,36%	62,23%	67	61,97%	61,69%	19	56,11%	56,05%
CA + MVE (ca...cd)	16396	88,74%	62,70%	4108	83,19%	59,43%	1036	72,76%	61,64%	268	67,76%	64,54%	76	68,39%	65,89%	28	74,73%	73,86%
MVE (ca...cd)	12	60,60%	58,11%	12	61,42%	58,92%	12	64,60%	61,61%	12	66,48%	64,54%	12	68,23%	65,89%	12	74,72%	73,86%
CA + EntropGlobal	16385	87,96%	77,94%	4097	88,68%	78,57%	1025	89,38%	78,79%	257	88,95%	78,80%	65	87,32%	77,88%	17	82,40%	74,99%
CA + Entrop(ca)	16385	87,78%	84,46%	4097	88,54%	85,72%	1025	89,71%	87,76%	257	90,94%	89,75%	65	91,15%	90,45%	17	88,60%	88,47%

Tabela 6.8 – Comparativo das médias de eficiência de recuperação usando a distância City-block para cálculo da dissimilaridade entre vetores com valores “puros” e uniformizados, obtidas a partir de matrizes de confusão.

Transformada Wavelet																		
	2º Nível			3º Nível			4º Nível			5º Nível			6º Nível			7º Nível		
Características no Vetor	Qtde	Cityblock	Uniformiz.	Qtde	Cityblock	Uniformiz.	Qtde	Cityblock	Uniformiz.	Qtde	Cityblock	Uniformiz.	Qtde	Cityblock	Uniformiz.	Qtde	Cityblock	Uniformiz.
CA	16.384	87,75%	88,23%	4.096	88,52%	88,96%	1.024	89,70%	90,31%	256	90,94%	91,35%	64	91,15%	91,41%	16	88,60%	88,94%
CA+DH+DV+DD	65.536			16.384	83,12%	71,78%	4.096	83,49%	73,79%	1.024	84,65%	76,15%	256	88,12%	80,98%	64	91,36%	89,76%
CA + MVE da CA	16387	88,64%	88,24%	4099	82,94%	88,99%	1027	70,38%	90,37%	259	64,36%	91,30%	67	61,97%	91,03%	19	56,11%	87,23%
CA + MVE (ca...cd)	16396	88,74%	88,29%	4108	83,19%	89,20%	1036	72,76%	90,80%	268	67,76%	91,59%	76	68,39%	91,03%	28	74,73%	86,51%
MVE (ca...cd)	12	60,60%	77,39%	12	61,42%	75,46%	12	64,60%	75,25%	12	66,48%	72,81%	12	68,23%	71,33%	12	74,72%	75,07%
CA + EntropGlobal	16385	87,96%	88,23%	4097	88,68%	88,97%	1025	89,38%	90,30%	257	88,95%	91,32%	65	87,32%	91,21%	17	82,40%	87,80%
CA + Entrop(ca)	16385	87,78%	88,24%	4097	88,54%	88,97%	1025	89,71%	90,31%	257	90,94%	91,31%	65	91,15%	91,11%	17	88,60%	87,39%

Tabela 6.9 – Comparativo das médias de eficiência de recuperação usando a distância City-block para cálculo da dissimilaridade entre vetores com valores “puros” e normalizados, obtidas a partir de matrizes de confusão

Transformada <i>Wavelet</i>																			
Características no Vetor	2º Nível			3º Nível			4º Nível			5º Nível			6º Nível			7º Nível			
	Qtde	Cityblock	Normaliz.	Qtde	Cityblock	Normaliz.	Qtde	Cityblock	Normaliz.	Qtde	Cityblock	Normaliz.	Qtde	Cityblock	Normaliz.	Qtde	Cityblock	Normaliz.	
	CA	16.384	87,75%	87,88%	4.096	88,52%	88,53%	1.024	89,70%	89,59%	256	90,94%	90,81%	64	91,15%	90,95%	16	88,60%	88,47%
	CA+DH+DV+DD	65.536			16.384	83,12%	46,90%	4.096	83,49%	57,60%	1.024	84,65%	67,06%	256	88,12%	77,40%	64	91,36%	88,46%
	CA + MVE da CA	16387	88,64%	87,90%	4099	82,94%	88,55%	1027	70,38%	89,64%	259	64,36%	90,91%	67	61,97%	90,97%	19	56,11%	87,50%
	CA + MVE (ca...cd)	16396	88,74%	87,93%	4108	83,19%	88,68%	1036	72,76%	90,09%	268	67,76%	91,56%	76	68,39%	91,14%	28	74,73%	84,97%
	MVE (ca...cd)	12	60,60%	75,78%	12	61,42%	71,59%	12	64,60%	70,34%	12	66,48%	66,98%	12	68,23%	66,74%	12	74,72%	72,64%
	CA + EntropGlobal	16385	87,96%	87,89%	4097	88,68%	88,53%	1025	89,38%	89,59%	257	88,95%	90,82%	65	87,32%	90,82%	17	82,40%	87,87%
	CA + Entrop(ca)	16385	87,78%	87,89%	4097	88,54%	88,53%	1025	89,71%	89,60%	257	90,94%	90,85%	65	91,15%	90,45%	17	88,60%	87,41%

Muitos artigos encontrados na literatura simplesmente aplicam uniformização ou normalização nos dados sem critério, mas comparando as médias da tabela 6.8, ou seja, dados sem alteração versus dados uniformizados descobre-se que ao mesmo tempo em que a uniformização elevou o desempenho, atingindo pico de 31,12% maior com dados uniformizados, também houve situações em que ocorreram quedas acentuadas na média, com pico de -11,34%. Nos testes aqui realizados, no geral, a uniformização elevou em média 5,46% o desempenho na recuperação.

Visando facilitar a interpretação dos dados apresentados nas tabelas 6.7, 6.8 e 6.9, foram elaborados gráficos contendo o melhor resultado em cada nível de decomposição, os quais são exibidos nas figuras 6.14, 6.15 e 6.16. Algo a ser observado em todos os gráficos é que em todos os níveis, o melhor resultado na recuperação de imagens sempre envolveu vetores contendo os Coeficientes de Aproximação. Ao considerar os valores dos coeficientes sem manipulação nota-se que em geral eles são suficientes para distinguir uma imagem da outra, no entanto ao normalizar ou uniformizar os dados, as medidas estatísticas passam a desempenhar papel importante para separação e recuperação das imagens. O número de elementos no vetor também deve ser considerado, pois dependendo da característica a ser utilizada, maior será o número de elementos quanto menor for o nível de decomposição. Sendo assim, o algoritmo levará menos tempo para processar a Transformada *Wavelet*, mas em contrapartida levará mais tempo para extrair as características e montar os vetores, pois estará manipulando matrizes maiores.

Verificando a tabela 6.9, as médias das matrizes de confusão dos valores normalizados ficaram sempre abaixo das médias com valores uniformizados. Essas matrizes de confusão podem ser encontradas na íntegra no Apêndice D.

Figura 6.14: Melhores resultados por nível sem alterar os dados.

Figura 6.15: Melhores resultados por nível: valores uniformizados.

Figura 6.16: Melhores resultados por nível: valores normalizados.

Em uma análise geral, a eficiência de recuperação com valores normalizados apresentou pouca diferença quando comparada a com valores uniformizados, isto pode ser minuciosamente apurado nas tabelas 6.7, 6.8, 6.9. Pode-se, então, afirmar que para as características extraídas do conjunto de imagens aqui estudado, a uniformização influencia de maneira mais positiva do que a normalização dos dados.

Foram implementados gráficos *Recall x Precision*, dos melhores resultados com dados sem manipulação e dados uniformizados, os quais são exibidos na figura 6.17. Verifica-se que a diferença de desempenho em termos percentuais é muito pequena, o que varia é o nível de decomposição e o tipo de características no vetor.

Figura 6.17: (a) RxP: dados sem manipulação. (b) RxP: dados uniformizados.

6.11 Recuperação das Imagens usando a Transformada *Wavelet Packet*

A Transformada *Wavelet Packet* pode fornecer uma análise mais detalhada das frequências presente na imagem. Faz parte dos objetivos deste estudo avaliar as propriedades da TWP voltadas para recuperações de imagens médicas. A distância City-block será empregada nessa análise, pois como verificado foi a métrica que apresentou melhor desempenho com o conjunto de dados utilizados.

Ao executar o algoritmo da *Wavelet Packet* deve-se definir qual função de informação de custo será usada para cálculo dos coeficientes. Conforme mostram estudos de Wickerhauser (1991) (ver seção 5.2) em geral utiliza-se uma função de custo aditiva baseada no valor de entropia, particularmente entropia de Shannon, mas ele mesmo adverte que é importante avaliar outros tipos de entropia como a *Log Energy* ou baseada em *Threshold*, ou mesmo utilizar uma função baseada em outro tipo de informação.

O uso de uma entropia baseada em *Threshold* implicaria em uma análise dos dados para se estabelecer qual o valor ideal para o *Threshold*. Tal estudo, no entanto, está fora do escopo deste trabalho. Já a entropia *Log Energy* não necessita de um parâmetro extra, assim ela foi implementada para análise dos resultados. Descobriu-se então, que os resultados das buscas

são expressivamente melhores quando se utiliza a entropia *Log Energy* para cálculo dos coeficientes na *Wavelet Packet*. A função de custo, no caso a entropia, é fundamental para computar a *Best Basis* no algoritmo *Best Tree*, o qual será descrito na seção 6.12.

Foram implementados vários algoritmos para extrair atributos das imagens usando *Wavelet Packet* com 2, 3, 4, 5 e 6 níveis de decomposição e armazená-los no vetor. No 7º nível de decomposição o alto número de coeficientes leva a uma alta dimensionalidade dos dados inviabilizando a implementação, além do alto custo computacional envolvido para computar a TWP em 7 níveis. A tabela 6.10 apresenta o número de subespaços gerados no último nível de decomposição. Foram 11 testes em cada nível de decomposição usando a TWP, totalizando 55 experimentos com características variadas, conforme descritas na tabela 6.11.

Tabela 6.10 – Número de subespaços no último nível de decomposição da TWP

Nível de decomposição	Tamanho	Número de subespaços no último nível
2º Nível	128x128	16
3º Nível	64x64	64
4º Nível	32x32	256
5º Nível	16x16	1024
6º Nível	8x8	4096

Tabela 6.11 – Composição dos Vetores de Características: Transf. *Wavelet Packet*

Características no vetor	Abbreviation
Coeficientes de Aproximação + Média, Variância e Energia dos subespaços do último nível + Entropia de todos os nós	CA + MVE + Eall
Coeficientes de Aproximação + Média, Variância e Energia dos subespaços do último nível + Entropia dos últimos nós	CA + MVE + E
Coeficientes de Aproximação + Média, Variância e Energia dos subespaços do último nível	CA + MVE
Coeficientes de Aproximação + Entropia de todos os nós	CA + Eall
Coeficientes de Aproximação + Entropia dos últimos nós	CA + E
Coeficientes de Aproximação	CA
Média, Variância e Energia dos subespaços do último nível + Entropia de todos os nós	MVE + Eall
Média, Variância e Energia dos subespaços do último nível + Entropia dos últimos nós	MVE + E
Média, Variância e Energia dos subespaços do último nível	MVE
Entropia de todos os nós	Eall
Entropia dos últimos nós	E

Considerando-se cada conjunto de características isoladamente pode-se observar através da tabela 6.12 que os melhores desempenhos nas buscas ocorrem em sua maioria no 2º ou 6º nível de decomposição, em geral com alto número de elementos no vetor, ou seja, dependendo do espaço de características utilizado o custo computacional será infinitamente menor. Nessa análise também fica evidente a influência da função de custo no cálculo dos coeficientes. Nota-se que em todos os experimentos o uso da entropia *Log Energy* gerou resultados iguais aos computados com a entropia de Shannon ou muito superiores.

Já na tabela 6.13 encontram-se os 10 (dez) melhores resultados gerais dentre os 55 experimentos realizados em ordem crescente, onde se verifica que os valores dos coeficientes de aproximação e os valores de entropia estão presentes em todas as situações, destacando-se como as características mais relevantes para recuperação das imagens através da *Wavelet Packet*. A figura 6.18 apresenta o gráfico *Recall x Precision* do melhor resultado geral e a figura 6.19 sintetiza de forma gráfica o melhor resultado nas buscas em cada nível de decomposição, onde novamente aparecem CA e entropia. Lembrando que esses resultados foram obtidos com valores ditos “puros”, ou seja, sem uniformização e nem normalização.

Tabela 6.12 – Comparativo das médias de eficiência de recuperação usando vetores de características obtidos com a Transf. *Wavelet Packet*

Trasnformada Wavelet Packet															
Características no Vetor	2º Nível			3º Nível			4º Nível			5º Nível			6º Nível		
	Qtde	Log Energy	Shannon	Qtde	Log Energy	Shannon	Qtde	Log Energy	Shannon	Qtde	Log Energy	Shannon	Qtde	Log Energy	Shannon
CA + MVE + Eall	16.453	91,61%	55,38%	4.373	86,91%	56,15%	2.133	77,86%	56,87%	4.693	73,30%	57,61%	17.813	74,66%	58,36%
CA + MVE + E	16.448	90,92%	56,69%	4.352	85,20%	58,28%	2.048	75,62%	58,93%	4.352	72,27%	59,73%	16.448	74,39%	60,37%
CA + MVE	16.432	88,91%	88,91%	4.288	83,75%	83,75%	1.792	74,94%	74,94%	3.328	72,11%	72,11%	12.352	74,35%	74,35%
CA + Eall	16.405	92,27%	55,38%	4.181	93,48%	56,15%	1.365	93,48%	56,87%	1.621	93,77%	57,60%	5.525	92,67%	58,35%
CA + E	16.400	91,35%	56,69%	4.160	92,94%	58,28%	1.280	93,41%	58,93%	1.280	93,79%	59,72%	4.160	94,85%	60,34%
CA	16384	87,83%	87,83%	4.096	88,52%	88,52%	1.024	89,70%	89,70%	256	90,94%	90,94%	64	91,15%	91,15%
MVE + Eall	69	79,82%	55,38%	277	75,27%	56,15%	1109	72,35%	56,87%	4437	72,50%	57,61%	17749	74,56%	58,36%
MVE + E	64	73,10%	56,69%	256	67,55%	58,28%	1024	69,10%	58,93%	4096	71,46%	59,73%	16384	74,27%	60,37%
MVE	48	62,10%	62,10%	192	64,05%	64,05%	768	68,22%	68,22%	3072	71,25%	71,25%	12288	74,23%	74,23%
Eall	21	81,05%	55,38%	85	81,63%	56,15%	341	81,47%	56,87%	1365	81,51%	57,60%	5461	82,97%	58,35%
E	16	76,92%	56,69%	64	76,22%	58,28%	256	76,20%	58,93%	1024	75,61%	59,72%	4096	74,74%	60,34%

VALOR Indica melhor desempenho com o conjunto de características

Tabela 6.13 – Dez melhores resultados: Transf. *Wavelet Packet*

Características	Nvel de Decomp.	Qtde de Elementos no Vetor	Média da Matriz de Confusão
CA + E	6º Nível	4.160	94,85%
CA + E	5º Nível	1.280	93,79%
CA + Eall	5º Nível	1.621	93,77%
CA + Eall	4º Nível	1.365	93,48%
CA + Eall	3º Nível	4.181	93,48%
CA + E	4º Nível	1.280	93,41%
CA + E	3º Nível	4.160	92,94%
CA + Eall	6º Nível	5.525	92,67%
CA + Eall	2º Nível	16.405	92,27%
CA + MVE + Eall	2º Nível	16.453	91,61%

Figura 6.18: *Recall x Precision* do melhor resultado nas buscas com características extraídas após aplicação da *Wavelet Packet*.

Figura 6.19: Melhores resultados por nível: *Wavelet Packet*.

Outra análise interessante que se pode fazer é sintetizada no gráfico da figura 6.20 que compara o desempenho por nível de decomposição, considerando o número máximo de elementos no vetor versus o número mínimo de elementos no vetor no nível de decomposição em questão. Considere, por exemplo, o 2º nível de decomposição, o maior vetor nesse nível possui 16.453 elementos, provenientes da matriz 128x128 dos coeficientes de aproximação, acrescido de 48 valores de média, variância e energia de cada um dos 16 subespaços resultantes e 21 valores de entropia, correspondente a cada subespaço gerado. Com esse vetor foi possível obter 91,61% de média de acerto. Nesse mesmo nível o menor vetor possui 16 valores de entropia provenientes de cada subespaço do último nível de decomposição, com esse vetor foi possível atingir 76,92%.

No entanto, a proporção inverte conforme aumenta o nível de decomposição. No 6º nível o maior vetor possui 17.813 elementos obtendo média de 74,66% e o menor vetor possui 64 elementos atingindo média de 91,15%. Para montar esse gráfico utilizou-se apenas o maior

e o menor vetor em cada nível, mas observando-se todos os resultados obtidos verifica-se que os valores de entropia são tão relevantes para recuperar imagens quanto os coeficientes de aproximação. Nos primeiros níveis de decomposição os vetores são basicamente formados por valores de CA e nos últimos níveis os vetores são basicamente formados por valores de entropia. Já nos níveis intermediários prevalecem as medidas estatísticas de média, variância e energia que semelhante ao ocorrido com a TW provaram mais uma vez não serem suficientes para distinguir as imagens, mesmo considerando que a TWP aumenta consideravelmente o número desse tipo de característica no vetor.

Figura 6.20: Desempenho considerando o máximo versus o mínimo número de elementos no vetor por nível de decomposição.

Conforme analisado na aplicação da TW, promover uma uniformização ou normalização nos dados pode contribuir para ampliar a exatidão nas buscas. Assim, a tabela 6.14 apresenta os 5 (cinco) melhores resultados coletados dos experimentos com a *Wavelet Packet* e sua versão uniformizada e normalizada, as matrizes de confusão desses resultados encontram-se no Apêndice E. Novamente nota-se que a uniformização gera médias superiores à normalização. E observa-se que o melhor resultado que havia sido obtido, apresentou queda de 17,26% após uniformização. Mas, ao contrário do que foi observado na Transformada

Wavelet, uniformização e normalização interferem negativamente na maioria das vezes, no caso da Transformada *Wavelet Packet*, considerando-se as características aqui utilizadas.

Tabela 6.14 – Uniformização x Normalização – Transf. *Wavelet Packet*

Características	Elementos	Média	Nível	Uniformiz.	Normaliz.
CA + E	4.160	94,85%	6º Nível	77,59%	77,21%
CA + E	1.280	93,79%	5º Nível	89,31%	89,33%
CA + Eall	1.621	93,77%	5º Nível	88,91%	88,73%
CA + Eall	1.365	93,48%	4º Nível	94,59%	94,45%
CA + Eall	4.181	93,48%	3º Nível	92,52%	92,09%

6.12 *Wavelet Packet* vinculada ao algoritmo *Best Tree*

A decomposição *Wavelet Packet* produz muitas representações redudantes, dando acesso a uma coleção de bases ortonormais das quais as “*best basis*” podem ser escolhidas baseada em algum critério. A decomposição *Wavelet Packet* pode ser visualizada como uma árvore onde cada nó-pai tem 4 (quatro) nós-filho. Devido a excessiva representação gerada, em muitas abordagens tem sido implementado técnicas para podar a árvore *Wavelet Packet* com base em uma função de custo. Nesses métodos a característica extraída do nó-pai é comparada a de seus nós-filhos baseada em algum critério de avaliação. Esse processo é iterativo começando dos nós-folha e terminando quando uma árvore podada de maneira otimizada é obtida. Assim, o algoritmo *Best Tree* analisa a árvore recursivamente de baixo para cima procurando pelas melhores bases para representar o objeto de estudo.

Ao executar o algoritmo para decomposição *Wavelet Packet* o mesmo já calcula os valores de entropia para cada nó. Ao rodar o algoritmo *Best Tree* esses valores apenas são comparados e os nós somente permanecem divididos se a soma das entropias dos nós-filhos for menor que a entropia do nó-pai, caso contrário esses nós-filhos são unidos ao nó-pai. Consequentemente, o valor de entropia do nó-pai passa então a ser a soma das entropias dos

nós-filhos. A figura 6.21 ilustra o resultado do algoritmo *Best Tree* aplicado a uma decomposição *Wavelet Packet* em 4 níveis.

Figura 6.21: Árvore *Wavelet Packet* após algoritmo *Best Tree*.

Considerando que os melhores resultados obtidos com a implementação da *Wavelet Packet* foram com vetores, cujos elementos eram coeficientes de aproximação, acrescido de valores de entropia de todos os subespaços gerados ou apenas dos subespaços do último nível de decomposição, os testes realizados com o algoritmo *Best Tree* avaliou essas duas situações.

Deve-se considerar também que o algoritmo deve ser adaptativo, pois cada uma das 1200 imagens do conjunto de teste pode gerar *Best Tree* distintas.

Assim, foi implementado um algoritmo adaptativo, cujos passos são:

1. Considera a existência de uma matriz previamente gerada, contendo os vetores de todas as imagens que será usada como base para comparação.
 2. Lê a imagem de referência
 3. Aplica a TWP em quantos níveis forem necessários
 4. Aplica o algoritmo *Best Tree* reduzindo a quantidade de nós na árvore
 5. Extrai os atributos desejados dos subespaços restantes e armazena em um vetor.
 6. Gera uma matriz temporária contendo todos os vetores de todas as imagens, porém sem os atributos referentes aos nós que foram podados com o algoritmo *Best Tree*.
 7. Calcula a distância City-block entre a imagem de referência e os vetores temporários.
 8. Ordena as distâncias em ordem crescente para obter as imagens mais similares.
- Esse processo é executado para cada imagem de referência a ser pesquisada.

O algoritmo *Best Tree* elimina os subespaços menos relevantes, no entanto, os resultados observados na tabela 6.15 mostram-se inferiores aos resultados aplicando-se apenas a TWP. Nesses testes o maior desempenho se deu no 4º nível de decomposição, atingindo 93,39%. A figura 6.22 exibe o gráfico *Recall* x *Precision* desse resultado.

Figura 6.22: *Recall* x *Precision* – algoritmo *Best Tree*.

Tabela 6.15 – Resultados obtidos com o algoritmo *Best Tree*

Trasnformada <i>Wavelet Packet</i> com algoritmo <i>Best Tree</i>															
	2º Nível			3º Nível			4º Nível			5º Nível			6º Nível		
Características no Vetor	Qtde	Log Energy	Shannon	Qtde	Log Energy	Shannon	Qtde	Log Energy	Shannon	Qtde	Log Energy	Shannon	Qtde	Log Energy	Shannon
CA + E	16.400	90,95%	56,40%	4.160	89,14%	57,45%	1.280	89,83%	56,51%	1.280	90,95%	56,61%	4.160	91,15%	56,19%
CA + Eall	16.405	91.98%	55,22%	4.181	93.11%	55,74%	1.365	93.39%	56,12%	1.621	91.97%	56,76%	5.525	89,99%	57,58%

As matrizes de confusão dos resultados da tabela 6.15 encontram-se no Apêndice F.

6.13 Comparativo entre a TW, TWP e a TWP com *Best Tree*

Resumo dos resultados obtidos com a *Wavelet* e a *Wavelet Packet*.

Melhor resultado geral dos testes com a TW: vetor com valores uniformizados de coeficientes de aproximação, acrescido de valores de média, variância e energia dos subespaços do último nível, totalizando 268 elementos, com 5 níveis de decomposição, obtendo **91,59%** de eficiência de recuperação (média da diagonal principal da matriz de confusão), conforme exibida na figura 6.23.

	Transformada <i>Wavelet</i> - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	83,28	0,53	-	-	-	-	-	-	-	16,19	-	-
Classe 2	22,24	58,44	4,77	0,13	-	-	-	-	0,86	5,02	-	8,54
Classe 3	-	0,44	99,56	-	-	-	-	-	-	-	-	-
Classe 4	1,83	-	-	98,17	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	89,30	7,81	-	2,89	-	-	-	-
Classe 6	-	-	-	-	5,96	91,68	-	2,36	-	-	-	-
Classe 7	0,05	-	-	-	-	-	97,57	-	-	2,38	-	-
Classe 8	-	-	-	-	0,72	3,91	-	94,37	-	-	1,00	-
Classe 9	-	0,08	-	12,01	-	-	0,03	-	87,88	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,16	-	-	99,84	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Distância City-block

Matriz 16x16

Eficiência de Recuperação: 91,59%

Figura 6.23: Matriz de confusão do melhor resultado com a TW.

Melhor resultado geral dos testes com a TWP: vetor com coeficientes de aproximação, acrescido de valores de entropia do último nível de decomposição sem

uniformização, totalizando 4.160 elementos, com 6 níveis de decomposição, obtendo **94,85%** de eficiência de recuperação (média da diagonal principal da matriz de confusão), conforme exibida na figura 6.24.

	Transf. Wavelet Packet - 6 Níveis de Dec. - Coeficientes de Aproximação + Entropia (nós finais do 6o. Nível) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	97,58	-	-	-	-	-	2,42	-	-	-	-	-
Classe 2	10,78	86,97	-	1,40	-	-	-	-	-	0,02	-	0,83
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	89,28	9,68	-	1,04	-	-	-	-
Classe 6	-	-	-	-	6,07	93,10	-	0,83	-	-	-	-
Classe 7	0,06	-	-	-	-	-	99,94	-	-	-	-	-
Classe 8	-	-	-	-	4,91	5,31	-	83,87	-	-	5,91	-
Classe 9	-	-	-	1,98	-	-	8,43	-	89,59	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,01	-	1,08	-	-	98,91	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Distância City-block Matriz 8x8 Eficiência de Recuperação: 94,85%

Figura 6.24: Matriz de confusão do melhor resultado com a TWP.

Melhor resultado geral dos testes com a TWP aplicando algoritmo *Best Tree*: vetor com coeficientes de aproximação, acrescido de valores de entropia de todos os níveis de decomposição sem uniformização, totalizando 1.365 elementos, com 4 níveis de decomposição, obtendo **93,39%** eficiência de recuperação, conforme exibida na figura 6.25.

	WAVELET PACKET com BEST TREE - 4 Níveis de Dec. - CA + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	93,62	2,12	-	-	-	-	4,26	-	-	-	-	-
Classe 2	25,09	70,62	0,05	-	-	-	-	-	0,14	0,05	-	4,05
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	99,91	-	-	-	-	-	0,09	-	-
Classe 5	-	-	-	-	90,75	6,28	-	2,97	-	-	-	-
Classe 6	-	-	-	-	4,13	92,64	-	3,23	-	-	-	-
Classe 7	0,57	-	-	-	-	-	99,43	-	-	-	-	-
Classe 8	-	-	-	-	4,91	4,46	-	87,85	-	-	2,78	-
Classe 9	-	0,14	-	4,13	-	-	7,91	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,93	-	-	99,07	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Distância City-block Matriz 32x32 Eficiência de Recuperação: 93,39%

Figura 6.25: Matriz de confusão do melhor resultado com a TWP – *Best Tree*.

Uma questão a ser considerada é que o ganho registrado nas buscas com *Wavelet Packet* e *Wavelet Packet* com *Best Tree* inevitavelmente vem acompanhado de aumento no custo computacional, que cresce de acordo com o nível de decomposição.

6.14 Tempo de Processamento

O tempo para geração do conjunto de características das 1200 imagens empregando a Transformada *Wavelet Packet*, foi muito superior ao tempo necessário para montar os vetores utilizando a Transformada *Wavelet*, além do nível de decomposição, outro fator que influencia é o tipo de característica extraída das imagens. Para realizar as consultas por similaridade sempre foi considerado $kNN = 100$, ou seja, como cada classe é composta por 100 imagens, deseja-se que o algoritmo localize todas as imagens pertencentes à classe. A imagem de referência usada como base para montar a tabela 6.16, está identificada no conjunto de imagens como 1111.dcm e é ilustrada na figura 6.26.

Figura 6.26: Imagem 1111.dcm (CT – cardíaca).

Uma observação com relação à *Best Tree* é que para qualquer imagem pesquisada deve-se executar o algoritmo adaptativo e comparar os nós restantes da imagem de referência com os valores dos mesmos nós para as 1200 imagens, por isso as duas últimas colunas da tabela 6.16 não estão preenchidas.

Tabela 6.16 – Tempo Médio de Processamento

Transformada aplicada	Observação	Características extraídas	Elementos no vetor	Nível de decompos.	Eficiência de Recuper.	*Tempo para Geração dos 1200 vetores	**Tempo para extração das caracter. da imagem de referência (segundos)		***Tempo de pesquisa da imagem considerando vetor já carregado na memória, ou seja, apenas comparação com os demais (segs)	
							1°. tempo	2°. tempo	1°. tempo	2°. tempo
Wavelet	Melhor resultado	CA+CH+CV+CD	64 vls	7n	91,36%	4m 36s	0,3120	0,2500	0,0460	0,0470
Wavelet Dados uniformiz.	Melhor resultado	CA+MVE(ca...cd)	268 vls	5n	91,59%	5m 22s	0,3590	0,3280	0,0630	0,0940
Wavelet Dados normaliz..	Melhor resultado	CA+MVE(ca...cd)	268 vls	5n	91,56%	5m 23s	0,3280	0,3430	0,0940	0,1090
Wavelet Packet Log Energy	1°. Melhor resultado	CA+E(último nível)	4160 vls	6n	94,85%	55m 25s	3,2810	3,3280	0,6250	0,5150
Wavelet Packet Log Energy	2°. Melhor resultado	CA+E(último nível)	1280 vls	5n	93,79%	24m 49s	1,5160	1,5160	0,1870	0,2190
Wavelet Packet Dados uniformiz.	Melhor resultado	CA+E(todos níveis)	1365 vls	4 n	94,59%	15m 50s	4,6250	4,5310	0,2650	0,2190
Wavelet Packet Dados normaliz.	Melhor resultado	CA+E(todos níveis)	1365 vls	4 n	94,45%	15m 51s	4,5470	4,5000	0,2180	0,2340
Best Tree	Melhor resultado	CA+E(todos níveis)	1365 vls	4 n	93,39%	15m 18s	2,1400	2,1250		

* Lê cada uma das 1200 imagens, extrai as características e armazena no vetor

** Lê a imagem de referência, extrai as características e compara com os demais vetores já carregados na memória.

*** Os 1200 vetores já estão carregados na memória, então pode-se apenas ler o vetor correspondente à imagem de referência e compará-lo com os demais. Nesse caso, não é necessário ler a imagem e extrair as características, uma vez que as mesmas já estão na memória. No entanto, isto apenas é válido para essa situação. Em uma aplicação real a probabilidade da imagem a ser pesquisada não existir no banco é sem dúvida muito maior o que implicaria no tempo de processamento do teste anterior.

A figura 6.27 traz um exemplo de consulta realizada na base de imagens, com $kNN = 20$, usando a metodologia descrita na última linha da tabela 6.16. Como resultado tem-se as 20 imagens mais similares à imagem de referência 1111.dcm recuperadas com sucesso.

Figura 6.27: Recuperação das 20 imagens mais similares à 1111.dcm

6.15 Conclusões

Atualmente a maioria dos equipamentos na área médica utiliza o padrão DICOM, que foi concebido justamente para facilitar o intercâmbio de informações. Assim, as imagens obtidas junto ao Hospital Amaral de Carvalho da cidade de Jaú seguem esse formato, o qual foi mantido durante os testes com as imagens. É sabido que um arquivo em formato DICOM contém duas partes: o cabeçalho com informações textuais e as imagens que compõem o estudo clínico. Embora os arquivos DICOM contenham informações textuais adicionais em seus cabeçalhos, que auxiliam na identificação da imagem que está sendo analisada, no presente trabalho foram exploradas apenas as informações pictóricas contidas nesses arquivos,

objetivando mais os estudos para o processamento de imagens propriamente dito dentro da macro linha de pesquisa Visão Computacional. Embora, essas informações possam ser de grande valia, pois informam qual a técnica usada para obtê-las, a parte do corpo, o tipo de exame, o sexo do paciente, etc, os estudos aqui realizados provaram que apenas analisando as imagens é possível separá-las dos demais arquivos do banco de imagens.

No presente trabalho foram utilizadas as Transformadas *Wavelet* e *Wavelet Packet* de Haar para transformar as imagens em espaços de frequência multiescalas, visando a caracterização com base no atributo textura das imagens. Uma vez processadas as imagens, os coeficientes *wavelet* obtidos e medidas estatísticas foram utilizadas para gerar os vetores de características. Os valores de média, variância e energia embora maiores em valor absoluto que os coeficientes *wavelets*, o que poderia influenciar o cálculo das distâncias, mostraram que não tem alto poder para discriminar as imagens, pois mesmo tendo gerado em alguns casos resultados satisfatórios, prejudicaram os resultados na maioria das vezes.

No entanto, pode-se afirmar que a normalização e a uniformização ao mesmo tempo em que aumentam expressivamente o desempenho de recuperação em alguns casos, também proporciona o efeito contrário em outros casos, prejudicando o desempenho. Esse fato é observado em todos os testes com a *Wavelet*, *Wavelet Packet* e algoritmo *Best Tree*. A uniformização dos dados gerou sempre melhores resultados do que a normalização, pois a uniformização promove uma equalização dos valores em um intervalo entre 0 a 1, diminuindo de maneira mais acentuada a variação nos dados do que a normalização que considerada a média e desvio padrão. No caso da TW, esses processos ampliaram o desempenho de recuperação, mas o mesmo não foi observado com a TWP.

O que ficou provado nos testes com a TW é que os Coeficientes de Aproximação (CA) são bons descritores de textura e que uniformizando os dados aumenta-se a eficiência de recuperação. Usando apenas os valores de CA do sexto nível de decomposição para compor o

vetor de características obteve-se 91,15% de eficiência de recuperação. Com estes mesmos valores uniformizados, obteve-se 91,41%.

Para que a *Wavelet Packet* torne-se vantajosa para decompor imagens, é necessário explorar outras características que podem ser obtidas a partir dos subespaços gerados. Assim, nos testes com a *Wavelet Packet*, CA e Entropia destacaram-se como os atributos com maior capacidade para discriminar as imagens. Usando valores de CA e Entropia do sexto nível de decomposição foi possível obter 94,85% de eficiência de recuperação.

Como comparativo, usando valores de CA e Entropia obtidos com a Transformada *Wavelet* atingiu-se 91,15% (mesma eficiência de recuperação que usando apenas CA). Em síntese, os testes visavam maior eficiência de recuperação e tentavam explorar as propriedades da Transformada *Wavelet Packet* para atingir este objetivo.

Na área de processamento de imagens a TWP ainda é pouco usada, o que motivou sua aplicação no processamento das imagens médicas, visando verificar suas reais contribuições para a recuperação das imagens mais similares. Porém, decompor uma imagem em níveis altos de decomposição usando a *Wavelet Packet*, torna o processo suscetível ao mal da alta dimensionalidade, devido ao alto número de valores no vetor. Com 6 (seis) níveis de decomposição obteve-se em alguns casos mais de 16.000 elementos no vetor; aplicar 7 níveis de decomposição é praticamente inviável e provavelmente não traria ganhos de 5,15% que é o que faltou para atingir 100% de eficiência nos testes com a *Wavelet Packet*.

Com relação aos coeficientes *wavelet* a banda de aproximação é a que concentra mais informações sobre a imagem com importantes características para o processo de recuperação. As informações concentradas nos coeficientes de detalhes, salvo poucas exceções, não alcançaram destaque na análise aqui desenvolvida. Considerando-se a Transformada *Wavelet*, altos níveis de decomposição geram subespaços com menos informação redundante, o que contribui para o bom desempenho de recuperação. Na *Wavelet Packet* os resultados foram

mais variados, ou seja, não dependeram do nível de decomposição, mas sim das características extraídas dos subespaços.

Apenas a *Wavelet Biorthogonal*, por razões já discutidas, foi empregada para testes e comparada com a *Wavelet* de Haar, a qual gerou resultados inferiores, com exceção da bior1.1 que obteve o mesmo desempenho que a *Wavelet* de Haar, pois as duas possuem critérios muito próximos para realizar a decomposição. Mesmo a *Wavelet* de Haar sendo mais simples, e por isto muitas vezes criticadas por muitos, ela continua sendo amplamente usada nas pesquisas e provou aqui ser suficiente para o propósito de recuperação de imagens. Certamente, outras famílias *Wavelets* poderiam ter sido aplicadas, mas os resultados dependem de uma série de fatores e não apenas da *Wavelet* escolhida para decomposição.

Conforme Rodrigues e Araujo (2003) afirmam em seu trabalho, uma fase de pré-processamento pode ser decisiva para a fase de extração de características de um sistema CBIR. Essa afirmação é totalmente plausível, por isto a metodologia por eles sugerida é aplicada no presente trabalho. Mas, no entanto para o conjunto de imagens dessa pesquisa, tais técnicas não influenciaram tão positivamente como nas pesquisas por eles desenvolvidas, indicando que as imagens não continham tanto ruído ou que as técnicas foram insuficientes para enfatizar particularidades nas imagens que pudessem separá-las das demais.

Com o pré-processamento das imagens, a média de eficiência de recuperação ficou em 92%, ou seja, 1% menor que os resultantes obtidos usando os coeficientes de aproximação *Wavelet*, mostrando que para o conjunto de dados desse estudo, tais técnicas não agregaram melhoras.

As características de textura propostas por Haralick extraídas de matrizes de co-ocorrência e exaltadas por muitos autores como excelente mecanismo para descrição de textura foram também aplicadas. No entanto, a média de acerto calculada pela matriz de

confusão ficou muito abaixo quando comparada com a utilização dos coeficientes de aproximação, atingindo apenas 38% de eficiência de recuperação.

A idéia de se implementar um algoritmo não-supervisionado trabalhando com todos os tipos de coeficientes mostrou-se insuficiente, pois além do aumento do custo computacional, a média de eficiência de recuperação ficou em torno de 78%.

O estudo sobre as métricas indicou que a métrica Euclidiana, embora utilizada maciçamente nos trabalhos descritos na literatura, nem sempre é a solução mais adequada. No caso do conjunto de características aqui estudadas a distância City-block foi a que apresentou melhor resultado.

Técnicas de análise de agrupamento podem ser uma ferramenta muito útil para estudar o conjunto de imagens, pois permitem identificar quais classes tem maior probabilidade de se misturarem e conseqüentemente alertar sobre as classes em que as características extraídas possuem menor poder de discriminação. Encontrar as características ideais para representar imagens semanticamente diferentes, mas visualmente semelhantes é um dos desafios em sistemas CBIR e tais técnicas podem minimizar esse esforço.

No que se refere ao algoritmo *Best Tree*, Wickerhauser (1991) alerta para a importância da função de informação de custo no cálculo da *Wavelet Packet*. Nos testes aqui realizados realmente pode-se constatar que dependendo da função escolhida os resultados obtidos são profundamente afetados. O uso da *Log Energy* foi expressivamente melhor que a entropia de Shannon, sendo responsável por melhorar os resultados com a *Wavelet Packet*.

Analisando-se a separação das classes foi possível observar que, em se tratando de imagens da mesma parte do corpo, porém em cortes diferentes, provavelmente será necessário identificar novos atributos, que as distingam com maior precisão.

Tanto nas análises com a *Wavelet* quanto com a *Wavelet Packet* as classes com mais problemas foram as classes 1 e 2. Ao se pesquisar imagens da classe 2, a incidência de recuperar imagem da classe 1 foi em torno de 10 a 20% (misturou joelho com coluna).

Ao se utilizar a *Wavelet*, as classes que apresentaram menos problemas foram as classes 3, 10, 11 e 12. Na *Wavelet Packet* as classes com menos problemas foram as classes 3, 4, 10 e 12, ou seja, quando uma técnica ou característica beneficia uma classe acaba prejudicando a outra. Ao se buscar imagens das classes 3, 4, 10 e 12 raramente estas se misturam com outras classes, pois comparada às demais imagens tem características muito particulares.

Por outro lado, em ambas as técnicas, as imagens das classes 5, 6 e 8, mesmo que levemente, misturam-se entre si mais ou menos a uma proporção de 5%.

Dependendo da característica empregada, ao se buscar a classe 9, verifica-se que esta se mistura levemente com a classe 7 (as duas são imagens da região abdominal). E ao se pesquisar a classe 11 ela se mistura muito levemente com a 8 (também da região abdominal).

Encontrar o conjunto de características e a técnica perfeita que satisfaça todas as classes é muito complexo, o que se pode fazer é refinar o resultado da metodologia aplicada através da extração de outras características como forma, por exemplo, ou mesmo empregar uma técnica de segmentação antes do cálculo dos coeficientes.

O que fica claro neste estudo é que o desempenho de recuperação não depende de um fator isolado como a escolha da *Wavelet* ou a medida de dissimilaridade aplicada, mas sim de um conjunto de fatores onde cada parte agrega sua contribuição ao todo. Esse trabalho estabelece que esses fatores devem ser analisados cuidadosamente antes de se fazer uma afirmação que um método é melhor do que outro.

A escolha da *Wavelet*, da medida de dissimilaridade, as características que serão trabalhadas, a necessidade de uniformizar ou normalizar essas características, a necessidade

de pré-processar a imagem, tudo isto é importante, mas deseja-se enfatizar que não é um desses fatores isoladamente que vai definir se haverá 100% na recuperação das imagens. Até mesmo a qualidade das imagens interfere no processo, pois se as imagens aqui selecionadas tivessem sido obtidas através de outros equipamentos de diagnóstico, certamente outros resultados poderiam ter sido obtidos.

Por fim, considerando-se que na área médica a precisão na obtenção das informações tem importância fundamental, a Transformada *Wavelet Packet* revelou vantagens relevantes sobre os métodos tradicionais que aplicam a Transformada *Wavelet*. Embora mais custosa computacionalmente, esta desvantagem pode facilmente ser compensada com equipamentos mais robustos sem prejudicar os orçamentos financeiros das instituições. Afinal, neste campo de pesquisa, fornecer ferramentas que auxiliem o profissional no diagnóstico e escolha do tratamento mais adequado ao paciente é imprescindível.

6.16 Contribuições

Além da revisão bibliográfica sobre métodos de caracterização de imagens médicas na busca por métodos eficientes na recuperação de imagens por conteúdo, foram geradas as seguintes contribuições:

- Estudo comparativo entre as Transformadas *Wavelet* e *Wavelet Packet* para caracterização das imagens médicas;
- Elaboração de uma base de imagens médicas laudadas em sua maioria;
- Desenvolvimento de algoritmos para extração de características em imagens médicas, usando *Wavelet*, *Wavelet Packet*, *Best Tree*;
- Estudo sobre variadas medidas de dissimilaridade voltadas para recuperação de imagens por conteúdo e para comparação dos vetores gerados;

- Análise das características mais discriminantes em imagens médicas;
- Análise dos parâmetros a serem avaliados na recuperação de imagens médicas por conteúdo;
- Análise do desempenho na recuperação das imagens utilizando as duas abordagens matemáticas.

6.17 Trabalhos Futuros

As informações contidas no cabeçalho dos arquivos DICOM podem ser usadas para aperfeiçoar o resultado das buscas das imagens, mesclando esses dados em um algoritmo supervisionado.

A facilidade de acesso às informações permitindo que o profissional agilize suas decisões também é primordial, logo disponibilizar essas imagens em uma base pública e desenvolver uma interface amigável para acesso remoto aos algoritmos pode ser implementada em trabalhos futuros para auxiliar o ensino e ao diagnóstico.

Além disso, outras famílias *Wavelets* podem ser utilizadas e avaliadas, outras funções de custo podem ser avaliadas para uso na *Wavelet Packet* com o algoritmo *Best Tree*. Na literatura há várias outras métricas que também podem ser avaliadas.

O estudo das técnicas empregadas para pré-processar as imagens podem ser aperfeiçoados, para auxiliar na fase de extração.

Técnicas para redução de dimensionalidade podem ser aplicadas, pois ao se trabalhar com a TWP obtém-se alto número de características em decorrência do grande número de subespaços gerados, evitando assim que características relevantes percam seu poder de discriminação por estarem misturadas a muitas outras características irrelevantes. Técnicas de mineração de dados também podem contribuir para minimizar os efeitos da alta dimensionalidade, além de auxiliar no processo de seleção de características.

O fato é que a área de processamento de imagens está em constante evolução e novas investigações podem surgir para auxiliar os pesquisadores em sua missão de encontrar alternativas que beneficiem e facilitem a vida das pessoas.

Referências Bibliográficas

(ALVAREZ, 2003) ALVAREZ, S. P. *Análisis de Usabilidad de Sistemas CBIR*. Departamento de Biblioteconomía y Documentación. Facultad de Ciencias de la Información. Universidad Complutense de Madrid. Documentación de las ciencias de la información, nº 26, pp. 313-350, 2003.

(AKLEMAN; JIANER, 1999) AKLEMAN, E., JIANER, C. *Generalized distance functions*. Coll. of Archit., Texas A&M Univ., College Station, TX. Shape Modeling and Applications. Proceedings Shape Modeling Conference International '99, Aizu-Wakamatsu, Japan, pp. 72-79, 1999.

(BAEZA-YATES, RIBEIRO-NETO, 1999) BAEZA-YATES, R., RIBEIRO-NETO, B. *Modern Information Retrieval*. Addison-Wesley Longman Publishing, 1999.

(BALAN *et al.*, 2004) BALAN, A. G. R., TRAINA, A. J. M., TRAINA JR., C., MARQUES, P. M. A. M. *Integrando Textura e Forma para a Recuperação de Imagens por Conteúdo*. IX Congresso Brasileiro de Informática em Saúde – CBIS'2004, Ribeirão Preto, SP, pp. 6, p. in CD-ROM, 2004.

(BHALERAO; RAJPOOT, 2003) BHALERAO A. H., RAJPOOT, M. N. *Discriminant Feature Selection for Texture Classification*. Proceedings British Machine Vision Conference (BMVC'2003), Norwich (UK), September, 2003.

(BIANCHI, 2006) BIANCHI, M. F. de. *Extração de Características de Imagens de Faces Humanas através de Wavelets, PCA e IMPCA*. Dissertação de mestrado. Escola de Engenharia de São Carlos (EESC), Departamento de Engenharia Elétrica. Universidade de São Paulo, São Carlos. 2006.

(BUENO *et al.*, 2002) BUENO, J. M., CHINO, F., TRAINA, A. J.M., TRAINA JR, C., MARQUES, P. M. A. M. *How to Add Content-based Image Retrieval Capability in a PACS*. IEEE International Conference on Computer Based Medical Systems - CBMS, Maribor, Slovenia, pp. 321-326, 2002.

(BURKHARD; KELLER, 1973) BURKHARD, W. A, KELLER, R. M. *Some Approaches to Best-Match File Searching*. Communications of the ACM, 16(4):230-236, 1973.

(CAMPO; TRAINA, 2003)CAMPO, C. Y., TRAINA, A. J. M. *Uma Abordagem Eficiente para Recuperação de Imagens Médicas*. WIM - Workshop de Informática Médica, Fortaleza, CE, 2003.

(CAMPOS, 2002) CAMPOS, G. M. *Estatística Prática para Docentes e Pós-Graduandos*. Faculdade de Odontologia de Ribeirão Preto da Universidade de São Paulo, Capítulo 11, 2002. Disponível em:

http://www.forp.usp.br/restauradora/gmc/gmc_livro/gmc_livro_cap11.html

(CASTAÑÓN, 2003) CASTAÑÓN, C. A. B. *Recuperação de Imagens por Conteúdo através de uma Análise Multiresolução por Wavelets*. Dissertação de Mestrado. Instituto de Ciências Matemáticas e Computação – ICMC. Universidade de São Paulo, São Carlos. 2003.

(CASTAÑÓN; TRAINA, 2002) CASTAÑÓN, C. A. B., TRAINA, A. J. M. *Extração de Características de Imagens Médicas Baseadas na Distribuição de Cor nos Espaços de Wavelets*. Anais do 2º Workshop de Informática Médica – WIM'2002, junto ao Simpósio Brasileiro de Engenharia de Software (SBES) da Sociedade Brasileira de Computação. Gramado, RS, 2002.

(COIFMAN; WICKERHAUSER, 1998) COIFMAN, R. WICKERHAUSER, M. V. *Experiments with Adapted Wavelet de-noising for Medical Signals and Images*. Time Frequency and Wavelets in Biomedical Signal Processing, ser. IEEE Press Series in Biomedical Engineering, M. Akay, Ed. 1998, ch. 12, pp. 323-346, 1998.

(COIFMAN; WICKERHAUSER, 1992) COIFMAN R. R., WICKERHAUSER, M. V. *Entropy-based algorithms for best basis selection*. IEEE Transaction on Information Theory, 38(2):1713—1716, March, 1992.

(DAUBECHIE, 1992) DAUBECHIE, I. *Ten Lectures on Wavelets*. CBMS-NSF Regional Conference Series in Applied Mathematics, Vol. 61. SIAM Journ. of Math. Anal. Philadelphia, Pennsylvania, 1992.

(DAUBECHIE, 1996) DAUBECHIE, I. *Where do Wavelets Come from? – A Personal Point of View*. Proceedings of the IEEE, Vol. 84, No. 4, Abril, 1996.

(DY et al., 2003) DY, J.G.; BRODLEY, C.E.; KAK, A.; BRODERICK, L.S.; AISEN, A.M. *Unsupervised Feature Selection Applied to Content-based Retrieval of Lung Images*. Pattern Analysis and Machine Intelligence, IEEE Transactions on Vol. 25, Issue 3, pp: 373 – 378, March, 2003.

(EAKINS; GRAHAM, 1999) EAKINS, J. P., GRAHAM, M. E. *Content-based Image Retrieval A report to the JISC Technology Applications Programme*. Institute for Image Data Research, University of Northumbria at Newcastle, 1999.

(FIGUEIREDO et al., 2004) FIGUEIREDO, J. M., TRAINA JR., C., TRAINA, A. J., MARQUES, P. M. A. *Flexibilizando Buscas por Conteúdo em ambientes PACS*. IX

Congresso Brasileiro de Informática em Saúde - CBIS'2004, Ribeirão Preto, SP, pp. 6 p. in CD-ROM, 2004.

(FIGUEIREDO, 2005) FIGUEIREDO, J. M. de. *Formalização do Domínio Imagem para Buscas Por Conteúdo em SGBDs Relacionais*. Dissertação Mestrado. Instituto de Ciências Matemáticas e de Computação – ICMC. Universidade de São Paulo, São Carlos, 2005.

(FRANCOIS; WERTZ; VERLEYSSEN, 2005) FRANCOIS , D., WERTZ, V., VERLEYSSEN , M. *Non-Euclidean metrics for similarity search in noisy datasets*. Université Catholique de Louvain – UCL. Machine Learning Group. ESANN'2005 Proceedings – European Symposium on Artificial Neural Networks, Bruges (Bélgica), pp. 27-29, Abril, 2005.

(GARCIA; ZIKOS; TZIRITAS, 2000) GARCIA, C., ZIKOS G., TZIRITAS G. *Wavelet packet analysis for face recognition*. Image and Vision Computing, Vol. 18, Issue 4, pp. 289-297, March, 2000.

(GATO; NUNES; SCHIABEL, 2004) GATO, H. E. R., NUNES, F. L. S., SCHIABEL, H. *Uma Proposta de Recuperação de Imagens Mamográficas Baseada em Conteúdo*. Congresso Brasileiro de Informática em Saúde, SBIS'2004, Ribeirão Preto, SP, 2004.

(GONZALEZ; WOODS, 2000) GONZALEZ, R. C., WOODS, R. E. *Processamento de Imagens Digitais*. São Paulo, 1ª. Ed.: Edgard Blücher, 2000, 509. ISBN: 8521202644.

(GRACIOSO, 2008) GRACIOSO, A. C. N. R. *Avaliação do Desempenho de Recuperação de Imagens Médicas baseada em Conteúdo em Redes de Computadores*. Dissertação de Mestrado. Escola de Engenharia de São Carlos (EESC), Departamento de Engenharia Elétrica. Universidade de São Paulo, São Carlos. 2008.

(GRAPS, 1995) GRAPS, A. *An Introduction to Wavelets*. IEEE Computational Science and Engineering, 2(2):50-61, 1995.

(GROSSMAN; MORLET, 1984) GROSSMAN, A., MORLET, J. *Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape*. Society for Industrial and Applied Mathematics, Vol. 15, No. 4. SIAM J. Math. Anal, July, 1984.

(GUPTA; MARKEY, 2005) GUPTA, S., MARKEY, M. K. *Correspondence in Texture Features between two Mammographic Views*, Medical Physics 32:1598-1606, 2005.

(HAAR, 1910) HAAR, A. *Zur Theorie der Orthogonalen Funktionen-Systeme*, Mathematische Annalen, 69, pp. 331-371, 1910.

(HARALICK; SHANMUGAN; DINSTEIN, 1973), HARALICK, R. M., SHANMUGAN, K., DINSTEIN, I. *Textural Features for Image Classification*. IEEE Transactions on Systems, Man and Cybernetics, SMC-3(6), pp. 610-621, 1973.

(HIEMATH; SHIVASHANKAR, 2006) P.S. HIEMATH, S.SHIVASHANKAR. *Texture Classification using Wavelet Packet Decomposition*. Gulbarga University. Dept. of P.G.Studies and Research in Computer Science, Karnataka, India. GVIP Journal, Volume 6, Issue 2, September, 2006.

(HOWARTH *et al.*, 2004) HOWARTH, P., YAVLINSKY, A., HEESCH, D., RÜGER, S. *Visual Features for Content-based Medical Image Retrieval*. Cross Language Evaluation Forum, Bath, UK, 2004.

(HUANG; AVIYENTE, 2006) HUANG, K., AVIYENTE, S. *Information Theoretic Wavelet Packet Subband Selection for Texture Classification*, Signal Processing, vol. 86, no. 7, pp. 1410-1420, July, 2006.

(JAIN; MURTY; FLYNN, 1999) JAIN, A. K., MURTY, M. N., FLYNN, P. J. *Data Clustering: A Review*. ACM Computing Surveys, vol. 31, no. 3, pp. 254-323, Sep., 1999.

(KATO, 1992) KATO, T. *Database Architecture for Content-Based Image Retrieval*. In Proc. Of the SPIE, Image Storage and Retrieval Systems, vol. 1662, pp. 112-123, San Jose, CA. 1992.

(KIM; KANG, 2007) KIM, S. C., KANG, T. J. *Texture classification and segmentation using Wavelet Packet Frame and Gaussian Mixture Model*. Journal of the Pattern Recognition Society, Vol. 40, pp. 1207-1221, April, 2007.

(KOKARE; CHATTERJI; BISWAS, 2003) KOKARE, M., CHATTERJI, B.N., BISWAS, P.K. *Comparison of Similarity Metrics for Texture Image Retrieval*. Dept. of Electron. & Electr. Commun. Eng., Indian Inst. of Technol., Kharagpur, India. TENCON 2003. Conference on Convergent Technologies for Asia-Pacific Region, Vol.2, pp. 571- 575, 2003.

(LEHMANN; WEIN; GREENSPAN, 2003) LEHMANN, T. M., WEIN, B. B., GREENSPAN, H. *Integration of Content-Based Image Retrieval to Picture Archiving and Communication Systems*. Proceedings of the Medical Informatics Europe Conference (MIE 2003), St. Malo, France, 2003.

(LEOW; LAI, 2001) LEOW, W. K., LAI, S. Y. *Invariant texture matching method for image retrieval*. National University of Singapore (Singapore, SG). Patent number: 6192150, Issue

date: February 20, 2001.

(LE-TIEN; CHIEN, 2004) LE-TIEN, L., CHIEN, H. D. *An Efficient Approach Combining Wavelets and Neural Networks for Equalizer Signal Processing in Digital Communications*. Proceeding of the 2nd IASTED International Conference on Communication and Computer Networks, CCN 2004, Cambridge, MA, USA, pp 128-132, Nov 8-10, 2004.

(LIMA, 2002) LIMA, P. C. de. *Wavelets em Processamento de Imagens*. Departamento de Matemática – ICEX. Universidade Federal de Minas Gerais, 2002.

(LIMA, 2003) LIMA, P. C. de. *Wavelets: Uma Introdução*. Departamento de Matemática – ICEX. Universidade Federal de Minas Gerais, 2003.

(LIMA, 2004) LIMA, P. C. de. *Wavelets: Teoria, Algoritmos e Aplicações*. Departamento de Matemática – ICEX. Universidade Federal de Minas Gerais, 2004.

(LOUREIRO *et al.*, 2005) LOUREIRO, F. P., CETALE SANTOS, M. A., OSÓRIO, P. L. M., SOARES FILHO, D. M. *Modelagem Acústica por Divisão em Domínios Independentes usando Transformada Wavelet Packet*. Ninth International Congress of The Brazilian Geophysical Society, Setembro, 2005.

(LUI *et al.*, 2008) LIU, H., SONG, D., RÜGER, S., HU, R., UREN, V. *Comparing Dissimilarity Measures for Content-based Image Retrieval*. Asia Information Retrieval Symposium (AIRS'2008), Harbin, China, 2008.

(MALLAT, 1989) MALLAT, S. G. *A Theory for Multiresolution Signal Decomposition: The Wavelet Representation*. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 11, No. 7, July, 1989.

(MALLAT, 1998) MALLAT, S. *A Wavelet Tour of Signal Processing*. Academic Press, 1998.

(MATHWORKS, 2004) The Mathworks Inc. *Matlab: The Language of Technical Computing*. Matlab Help, 2004

(MIAO *et al.*, 2004) MIAO, Y., WANG, Y. *The Research of Semantic Content Applied to Brain CT Images*. 17th IEEE Symposium on Computer-Based Medical Systems (CBMS'2004), IEEE Computer Society, 2004.

(MOURA *et al.*, 2003) MOURA, D. M., SILVA, L. V., NERY, M. S., RODRIGUES, P. S. S. *Recuperação de Imagens Baseado em Conteúdo*. Departamento de Ciência da Computação, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil. Anais do IV Workshop

em Tratamento de Imagens, NPDI/DCC/ICEx/UFMG, pp. 101-109, Junho, 2003.

(MÜLLER *et al.*, 2004) MÜLLER, H., MICHOUX, N., BANDON, D., GEISSBUHLER A. A *Review of Content-Based Image Retrieval Systems in Medical Applications – Clinical Benefits and Future Directions*. International Journal of Medical Informatics, vol. 73, pp. 1-23, 2004

(NEMA, 2004) NEMA – National Electrical Manufacturers Association. *Digital Imaging and Communications in Medicine (DICOM). Part 1: Introduction and Overview*, 2004.

(NETO; OLIVEIRA; VALERI, 2004) NETO, G. H., OLIVEIRA, W. de, VALERI, F. V. *Armazenamento de Imagens Médicas com InterBase*. Infocomp Journal of Computer Science. Vol. 3, n. 1, pp. 13-17, 2004.

(OLIVEIRA *et al.*, 2000) OLIVEIRA, R. A R., CLAUDINO, L. M. B., ARAÚJO, A. A., PERRATON, L., GUIMARÃES, S. J. F. *Extração de Características Utilizando Wavelets para Indexação de Imagens*. Anais I Workshop em Tratamento de Imagens. Universidade Federal de Minas Gerais. Belo Horizonte, MG, 2000.

(OLIVEIRA, 2003) OLIVEIRA, H. M. de. *Análise de Sinais para Engenheiros: Uma Abordagem via Wavelets*. Editora; Manole, 2003.

(PARRAGA, 2002) PARRAGA, A. *Aplicação da Transformada Wavelet Packet na Análise e Classificação de Sinais de Vozes Patológicas*. Dissertação de Mestrado. Departamento de Engenharia Elétrica. Universidade Federal do Rio Grande do Sul, 2002.

(POLIKAR, 2001) POLIKAR, R. *The engineer's ultimate guide to wavelet analysis - the wavelet tutorial*. College of Engineering. Rowan University, 2001.

(QIAO *et al.*, 2005) QIAO, Y.-L., LU, Z.-M., PAN, J. S.; SUN, S. H. *Spline Wavelets Based Texture Features for Image Retrieval*. International Journal of Innovative Computing, Information and Control – ICIC, Vol. 2, Number 3, pp. 653-658, June, 2006.

(QURESHI *et al.*, 2006) QURESHI, H, RAJPOOT, N., WILSON, R., NATTKEMPER, T., HANS, V. *Classification of Meningiomas using Discriminant Wavelet Packets and Learning Vector Quantization*. Proceedings Medical Image Understanding and Analysis (MIUA'2007), 2007.

(RAJPOOT, 2003) RAJPOOT, N. M. *Local Discriminant Wavelet Packet Basis for Texture Classification*. Proceedings SPIE Wavelets X (Wavelets X'2003), San Diego (USA), August 2003.

(ROCHA, 2007) ROCHA, A. R. *Classificação de texturas a partir de vetores de atributos e função de distribuição de probabilidades*. Universidade Estadual de Campinas (Unicamp). Instituto de Computação. Campinas, SP, 2007.

(RODRIGUES; ARAUJO, 2003) RODRIGUES, P. S. S., ARAUJO, A. A. Um modelo Bayesiano combinando Análise Semântica Latente e Atributos Espaciais para Recuperação de Informação Visual. Tese de doutorado. Departamento de Ciência da Computação. Universidade Federal de Minas Gerais, Belo Horizonte, 2003.

(ROSA *et al.*, 2002) ROSA, N. A., SANTOS FILHO, R. F., BUENO, J. M., TRAINA, A. J. M., TRAINA JR., C. *Sistema de Recuperação de Imagens Similares em um Hospital Universitário*. VIII Congresso Brasileiro de Informática em Saúde – CBIS'2002, Natal, RN, 2002.

(SAARBRÜCKEN; KAISERSLAUTERN, 1994) SAARBRÜCKEN, P. M., KAISERSLAUTERN H.-G. S. *Wavelet and Digital Image Processing*. Surveys on Mathematics for Industry, 4(3):195-235, 1994.

(SANTOS; FURUIE, 2005) SANTOS, M. dos, FURUIE, S. S. *Base de Imagens para Avaliação de Algoritmos de Processamento de Imagens Médicas*. Anais do V Workshop de Informática Médica (WIM'2005). Vol. 2005. pp. 1-4, Porto Alegre, RS, 2005.

(SANTOS; FURUIE, 2006) SANTOS, M. dos, FURUIE, S. S. *Sharing Medical Images: a Proposal of a Reference Image Database*. In: SPIE Medical Imaging 2006: PACS and Imaging Informatics. Vol. 6142. pp. 1-9, San Diego, CA, 2006.

(SIEGEL, 1999) SIEGEL, E. L. *Current State of the Art and Future Trends*. In Elliot L. Siegel and Robert M. Kolodner, editors, *Filmless Radiology*, pp. 3–20, Springer Verlag, New York City, NY, 1999.

(SILVA; CARVALHO; GATTASS, 2004) SILVA, A. C.; CARVALHO, P. C. P; GATTASS, M. *Diagnóstico de Nódulo Pulmonar Solitário Utilizando Textura e Geometria em Imagens de Tomografia Computadorizada: Resultados Preliminares*. Revista IEEE America Latina, VOL. 2, 30, jun., 2004.

(SILVA; EYNG, 2002) SILVA, A. V. da; EYNG, J. *Wavelets e Wavelet Packets*. Seminário Visão Computacional. Curso de Pós Graduação de Ciência da Computação – CPGCC. Departamento de Informática e Estatística. Universidade Federal de Santa Catarina, 2002.

(SKALANSKY, 1978) SKALANSKY, J., *Image segmentation and feature extraction*. IEEE Trans. System Man Cybernat., 8(4), 237-247, 1978.

(SOARES, 1997) SOARES, M. J. *Onduletas e Processamento de Sinal*. Depart. de Matemática, Universidade do Minho, Braga, Portugal. Editora: Fundação João Jacinto Magalhães, 1997.

(SOUZA et al.,) SOUZA, E. M. de, PAGAMISSE, A., MONICO, J.F.G., POLEZEL, W.G.C. *Comparação das Bases de Wavelets Ortonormais e Biortogonais: Implementação, Vantagens e Desvantagens no Posicionamento com GPS*. Sociedade Brasileira de Matemática Aplicada e Computacional. TEMA Tend. Mat. Apl. Comput., 8, No. 1 , pp. 149-158, 2007,

(STASIU, 2003) STASIU, R. K. *Técnicas de Indexação para Buscas por Similaridade em Bases de Dados*. TI-nr. 1082, Trabalho Individual I. Programa de Pós Graduação. Universidade Federal do Rio Grande do Sul – UFRGS, 2003.

(TEKNOMO, 2006) TEKNOMO, Kardi. *What is Similarity and Dissimilarity?* Human Centered Mobility Technologies in Arsenal Research, Austria. Disponível em <http://people.revoledu.com/kardi/tutorial/Similarity/WhatIsSimilarity.html>

(TRAINA JR. et al., 2000) TRAINA JR., C., TRAINA, A., SEEGER, B., FALOUTSOS, C. *Slim-Trees: High Performance Metric Trees Minimizing Overlap Between Nodes*. International Conference on Extending Database Technology (EDBT'2000), v. 1777 of Lecture Notes in Computer Science, pp. 51-65, Germany, 2000.

(TRAINA, 2001) TRAINA, A. J. *Suporte a Visualização de Consultas por Similaridade em Imagens Médicas através de Estruturas de Indexação Métrica*. Tese de Live-Docente em Computação. Instituto de Ciências Matemáticas e de Computação – ICMC. Universidade de São Paulo, São Carlos, 2001.

(TRAINA; TRAINA JR, 2005) TRAINA, A. J. M., TRAINA JR., C. *Técnicas e Aplicações de Recuperação de Imagens por Conteúdo*. Minicurso sobre CBIR. I Workshop de Visão Computacional. Universidade Metodista de Piracicaba – Unimep, Piracicaba, SP, 2005.

(VALENS, 1999) VALENS, C. *A Really Friendly Guide to Wavelets*. 2004. Technical Report, Ume University, 1999.

Disponível em: <http://pagesperso-orange.fr/polyvalens/clemens/wavelets/wavelets.html>

(WANGENHEIM, 2005) WANGENHEIM, A. V. *Tecnologia e Tendências em Informática na Saúde*. Seminário de Informática Médica 2005. Universidade Federal de Santa Catarina – UFSC. Laboratório de Telemedicina. Hospital Universitário Ernani de São Thiago, Florianópolis, 2005.

(WATANABE; TRAINA, 2005) WATANABE, C. Y. V.; TRAINA, A. J. M. *Recuperação de Imagens Médicas por Conteúdo Usando Transformadas Wavelets*. II Simpósio de

Instrumentação e Imagens Médicas, São Pedro, SP, pp. 1-2, Outubro, 2005.

(WICKERHAUSER, 1991) WICKERHAUSER, M. V. *INRIA Lectures on Wavelet Packet Algorithms*. Minicourse lecture notes. *Proceedings ondelettes et paquets d'ondes*, pp. 31-99, Rocquencourt, France, 17-21 June, 1991.

(WICKERHAUSER, 1994) WICKERHAUSER M. V. *Adapted Wavelet Packet Analysis from Theory to Software*. Wellesley, MA: AK Peters, Ltd., 9 May, 1994.

(XUE et al., 2007) XUE, Z., ANTANI, S., LONG, L. R., JERONIMO, J., THOMA, G. R. *Investigating CBIR Techniques for Cervicographic Images*. Proceedings in Annual Symposium of the American Medical Information Association (AMIA 2007), Chicago, pp. 826-830, November, 2007.

(YANG; TREWN, 2004) YANG, K., TREWN, J. *Multivariate Statistical Methods in Quality Management*. McGraw-Hill Professional, 1 edition (February 24, 2004). 288. ISBN: 0071432086,.

(YU et al., 2006) YU, J., AMORES, J., SEBE, N., TIAN, Q. *A New Study on Distance Metrics as Similarity Measurement*. IEEE International Conference on Multimedia and Expo, pp. 533-536, Toronto, Ont., 9-12 July, 2006

(ZHANG; LU, 2003) ZHANG, D., LU G. *Evaluation of similarity measurement for image retrieval*. Neural Networks and Signal Processing, 2003. Proceedings of the 2003 International Conference on Volume 2, Issue, page(s): 928 - 931 Vol.2, 14-17, Dec., 2003.

(ZHOU; HUANG, 2002) ZHOU, X. S., HUANG, T. S. *Unifying Keywords and Visual Contents in Image Retrieval*. IEEE Multimedia, 2002.

APÊNDICE A – Matrizes de confusão geradas usando Transformada *Wavelet* com seis níveis de decomposição e distância Euclidiana entre os vetores. Conjunto de 130 imagens.

Transformada Wavelet com seis níveis de decomposição - Coeficientes de aproximação													
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	99%	0%	0%	0%	0%	1%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	85%	0%	15%	0%	0%	0%	0%
Classe 8	0%	0%	10%	0%	0%	0%	0%	90%	0%	0%	0%	0%	0%
Classe 9	0%	0%	0%	0%	0%	0%	59%	0%	41%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	97%	3%	0%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Distância Euclidiana

Matriz 8x8

Eficiência de Recuperação: 93%

Transformada Wavelet com seis níveis de decomposição - Coeficientes de Detalhes Horizontais													
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	54%	0%	0%	14%	0%	32%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	66%	0%	32%	0%	2%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	97%	0%	0%	3%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	96%	0%	4%	0%	0%	0%	0%
Classe 8	0%	0%	10%	0%	0%	3%	0%	59%	0%	0%	2%	0%	26%
Classe 9	0%	0%	0%	0%	2%	0%	59%	0%	39%	0%	0%	0%	0%
Classe 10	0%	0%	0%	12%	0%	0%	0%	0%	0%	88%	0%	0%	0%
Classe 11	0%	5%	0%	0%	4%	0%	0%	3%	0%	0%	79%	0%	9%
Classe 12	0%	0%	1%	0%	0%	0%	0%	0%	0%	0%	0%	98%	1%
Classe 13	0%	0%	0%	0%	0%	0%	0%	13%	0%	0%	0%	4%	83%

Distância Euclidiana

Matriz 8x8

Eficiência de Recuperação: 81%

Transformada Wavelet com seis níveis de decomposição - Coeficientes de Detalhes Diagonais													
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	96%	0%	0%	3%	0%	0%	0%	1%	0%	0%	0%	0%
Classe 3	0%	0%	99%	0%	1%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	49%	0%	0%	20%	0%	31%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	50%	24%	0%	26%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	93%	0%	7%	0%	0%	0%	0%
Classe 8	0%	0%	22%	0%	34%	0%	0%	35%	0%	0%	0%	5%	4%
Classe 9	0%	0%	0%	0%	0%	0%	72%	0%	28%	0%	0%	0%	0%
Classe 10	0%	0%	0%	18%	0%	0%	0%	0%	15%	67%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	88%	4%	10%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	3%	13%	84%

Distância Euclidiana

Matriz 8x8

Eficiência de Recuperação: 76%

Transformada Wavelet com seis níveis de decomposição - Coeficientes de Detalhes Verticais													
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	57%	0%	0%	23%	0%	20%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	61%	0%	34%	0%	5%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	2%	50%	17%	0%	31%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	90%	0%	10%	0%	0%	0%	0%
Classe 8	0%	18%	0%	0%	0%	0%	0%	82%	0%	0%	0%	0%	0%
Classe 9	0%	0%	0%	0%	0%	0%	73%	0%	27%	0%	0%	0%	0%
Classe 10	1%	0%	0%	0%	2%	0%	0%	0%	0%	97%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	97%	3%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Distância Euclidiana

Matriz 8x8

Eficiência de Recuperação: 82%

APÊNDICE C – Matrizes de confusão das métricas de dissimilaridade

	Transf. Wavelet com 6 níveis de decomposição: Coefic.de aproximação - Distância City-block												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	87%	0%	13%	0%	0%	0%	0%
Classe 8	0%	0%	14%	0%	0%	0%	0%	86%	0%	0%	0%	0%	0%
Classe 9	0%	0%	0%	0%	0%	0%	56%	0%	44%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	97%	3%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Eficiência de Recuperação: 93%

	Transf. Wavelet com 6 níveis de decomposição: Coefic.de aproximação - Distância Minkowski, p=3												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	99%	0%	0%	0%	0%	1%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	98%	0%	2%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	85%	0%	15%	0%	0%	0%	0%
Classe 8	0%	0%	6%	0%	0%	0%	0%	94%	0%	0%	0%	0%	0%
Classe 9	0%	0%	0%	0%	0%	0%	63%	0%	37%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	96%	4%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

p = 1 = city block

p = 2 = mahalanobis

Eficiência de Recuperação: 93%

	Transf. Wavelet com 6 níveis de decomposição: Coefic.de aproximação - Distância Euclidiana Normalizada												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	99%	0%	0%	0%	0%	1%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	97%	0%	1%	0%	2%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	84%	0%	16%	0%	0%	0%	0%
Classe 8	0%	0%	13%	0%	0%	0%	0%	85%	0%	0%	0%	0%	2%
Classe 9	0%	0%	0%	0%	0%	0%	56%	0%	44%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	98%	2%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Eficiência de Recuperação: 93%

	Transf. Wavelet com 6 níveis de decomposição: Coefic.de aproximação - Distância Cosseno												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	80%	0%	20%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	81%	0%	19%	0%	0%	0%	0%
Classe 8	0%	0%	7%	0%	0%	0%	0%	93%	0%	0%	0%	0%	0%
Classe 9	0%	0%	0%	0%	3%	0%	60%	0%	37%	0%	0%	0%	0%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	97%	3%	0%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%

Eficiência de Recuperação: 91%

	Transf. Wavelet com 6 níveis de decomposição: Coefic.de aproximação - Distância Correlação												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 2	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 3	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 4	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Classe 5	0%	0%	0%	0%	87%	0%	13%	0%	0%	0%	0%	0%	0%
Classe 6	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
Classe 7	0%	0%	0%	0%	0%	0%	75%	0%	12%	0%	3%	3%	7%
Classe 8	0%	0%	6%	0%	0%	0%	0%	93%	1%	0%	0%	0%	0%
Classe 9	0%	0%	1%	0%	2%	0%	51%	10%	30%	0%	2%	0%	4%
Classe 10	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	94%	5%	1%
Classe 12	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	100%	0%
Classe 13	0%	0%	0%	0%	0%	0%	2%	0%	0%	0%	0%	0%	98%

Eficiência de Recuperação: 91%

	Transf. Wavelet com 6 níveis de decomposição: Coefic.de aproximação - Distância Mahalanobis												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	53%	0%	0%	0%	3%	0%	44%	0%	0%	0%	0%	0%	0%
Classe 2	1%	51%	0%	0%	0%	0%	48%	0%	0%	0%	0%	0%	0%
Classe 3	5%	2%	36%	0%	2%	0%	53%	0%	1%	0%	0%	1%	0%
Classe 4	10%	4%	0%	32%	6%	0%	48%	0%	0%	0%	0%	0%	0%
Classe 5	3%	2%	0%	0%	40%	0%	54%	0%	0%	0%	0%	1%	0%
Classe 6	5%	8%	1%	0%	11%	22%	52%	0%	1%	0%	0%	0%	0%
Classe 7	7%	4%	0%	0%	3%	0%	86%	0%	0%	0%	0%	0%	0%
Classe 8	5%	4%	1%	0%	8%	0%	66%	10%	0%	0%	0%	6%	0%
Classe 9	4%	2%	0%	2%	10%	0%	64%	0%	18%	0%	0%	0%	0%
Classe 10	12%	3%	0%	0%	5%	0%	65%	0%	0%	14%	0%	1%	0%
Classe 11	5%	9%	0%	0%	8%	0%	51%	0%	0%	0%	22%	5%	0%
Classe 12	3%	1%	0%	0%	4%	0%	56%	0%	0%	0%	0%	36%	0%
Classe 13	9%	3%	0%	0%	6%	0%	68%	0%	0%	0%	0%	0%	14%

Eficiência de Recuperação: 33%

	Transf. Wavelet com 6 níveis de decomposição: Coefic.de aproximação - Distância de Hamming												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	19%	0%	0%	0%	0%	0%	0%	0%	11%	70%	0%	0%	0%
Classe 2	9%	10%	0%	0%	0%	0%	0%	0%	11%	70%	0%	0%	0%
Classe 3	0%	0%	10%	0%	0%	0%	0%	80%	0%	0%	0%	0%	10%
Classe 4	9%	0%	0%	12%	0%	0%	0%	0%	14%	65%	0%	0%	0%
Classe 5	0%	0%	0%	0%	90%	0%	10%	0%	0%	0%	0%	0%	0%
Classe 6	10%	0%	0%	0%	0%	12%	0%	0%	18%	60%	0%	0%	0%
Classe 7	0%	0%	0%	0%	81%	0%	18%	0%	1%	0%	0%	0%	0%
Classe 8	0%	0%	0%	0%	0%	0%	91%	0%	0%	0%	0%	0%	9%
Classe 9	0%	0%	0%	0%	80%	0%	10%	0%	10%	0%	0%	0%	0%
Classe 10	9%	0%	0%	0%	0%	0%	0%	0%	20%	71%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	81%	0%	0%	10%	0%	9%
Classe 12	0%	0%	0%	0%	0%	0%	0%	78%	0%	0%	0%	12%	10%
Classe 13	0%	0%	0%	0%	0%	0%	0%	81%	0%	0%	0%	0%	19%

Eficiência de Recuperação: 30%

	Transf. Wavelet com 6 níveis de decomposição: Coefic.de aproximação - Distância Jaccard												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Classe 13
Classe 1	19%	0%	0%	0%	0%	0%	0%	0%	11%	70%	0%	0%	0%
Classe 2	9%	10%	0%	0%	0%	0%	0%	0%	11%	70%	0%	0%	0%
Classe 3	0%	0%	10%	0%	0%	0%	0%	80%	0%	0%	0%	0%	10%
Classe 4	9%	0%	0%	12%	0%	0%	0%	0%	14%	65%	0%	0%	0%
Classe 5	9%	0%	0%	0%	10%	0%	0%	0%	21%	60%	0%	0%	0%
Classe 6	10%	0%	0%	0%	0%	12%	0%	0%	18%	60%	0%	0%	0%
Classe 7	9%	0%	0%	0%	0%	0%	10%	0%	15%	65%	0%	1%	0%
Classe 8	0%	0%	0%	0%	0%	0%	91%	0%	0%	0%	0%	0%	9%
Classe 9	9%	0%	0%	0%	0%	0%	1%	0%	21%	69%	0%	0%	0%
Classe 10	9%	0%	0%	0%	0%	0%	0%	0%	20%	71%	0%	0%	0%
Classe 11	0%	0%	0%	0%	0%	0%	0%	81%	0%	0%	10%	0%	9%
Classe 12	0%	0%	0%	0%	0%	0%	0%	78%	0%	0%	0%	12%	10%
Classe 13	0%	0%	0%	0%	0%	0%	0%	81%	0%	0%	0%	0%	19%

Eficiência de Recuperação: 24%

Tabela: Desempenho das Métricas de Dissimilaridade

Métrica	Performance
Distância City-block	93,38%
Distância Euclidiana Normalizada	93,23%
Distância Minkowski $p = 3$	93,00%
Distância Euclidiana Normalizada	92,85%
Distância Cosseno	91,38%
Distância Correlação	90,54%
Distância Mahalanobis	33,38%
Distância Hamming	29,54%
Distância Jaccard	23,62%

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	53,48	1,51	-	-	-	-	-	-	-	45,01	-	-
Classe 2	9,13	64,33	0,77	0,12	-	-	-	-	0,86	20,15	-	4,64
Classe 3	-	5,85	92,17	-	-	-	-	-	1,98	-	-	-
Classe 4	5,28	0,27	-	94,42	-	-	-	-	-	0,03	-	-
Classe 5	-	-	-	-	84,71	7,57	-	7,72	-	-	-	-
Classe 6	-	-	-	-	7,59	85,27	-	7,14	-	-	-	-
Classe 7	4,53	3,62	-	-	-	-	70,69	-	-	21,16	-	-
Classe 8	-	-	-	-	0,20	0,37	-	99,21	-	-	0,22	-
Classe 9	-	0,86	-	8,46	-	-	0,04	-	90,64	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,77	-	-	99,23	-
Classe 12	-	5,41	-	-	-	-	-	-	-	-	-	93,85

Decomp. Wavelet
Distância EuclidianaEficiência de Recup.
85,67apenas CA
4096 vls

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	69,43	0,18	-	-	-	-	-	-	-	30,39	-	-
Classe 2	15,06	63,96	2,98	0,03	-	-	-	-	0,83	14,27	-	2,87
Classe 3	-	0,06	98,86	1,08	-	-	-	-	-	-	-	-
Classe 4	1,76	-	-	97,50	-	-	-	-	-	0,74	-	-
Classe 5	-	-	-	-	90,51	6,00	-	3,49	-	-	-	-
Classe 6	-	-	-	-	5,58	89,68	-	4,74	-	-	-	-
Classe 7	-	-	-	-	-	-	79,59	-	-	20,41	-	-
Classe 8	-	-	-	-	1,20	3,25	-	94,62	-	-	0,93	-
Classe 9	-	0,11	-	12,42	-	-	-	-	87,47	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,83	-	-	99,17	-
Classe 12	-	2,28	-	-	-	-	-	-	-	-	-	96,74

Decomp. Wavelet
Distância CityblockEficiência de Recup.
88,96apenas CA
4096 vls

UNIFORMIZADO

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	69,62	0,22	-	-	-	-	-	-	-	30,16	-	-
Classe 2	15,23	63,45	2,25	0,01	-	-	-	-	0,85	13,88	-	4,33
Classe 3	-	0,53	98,83	0,64	-	-	-	-	-	-	-	-
Classe 4	1,25	-	-	97,99	-	-	-	-	-	0,76	-	-
Classe 5	-	-	-	-	88,60	6,09	-	5,31	-	-	-	-
Classe 6	-	-	-	-	6,37	89,93	-	3,70	-	-	-	-
Classe 7	-	-	-	-	-	-	74,28	-	-	25,72	-	-
Classe 8	-	-	-	-	0,64	0,41	-	98,76	-	-	0,19	-
Classe 9	-	-	-	12,06	-	-	-	-	87,94	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,38	-	-	98,62	-
Classe 12	-	4,82	-	-	-	-	-	-	-	-	-	94,28

Decomp. Wavelet
Distância CityblockEficiência de Recup.
88,53apenas CA
4096 vls

NORMALIZADO

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	73,26	0,26	-	-	-	-	-	-	-	26,48	-	-
Classe 2	15,46	63,85	3,24	0,03	-	-	-	-	0,86	12,58	-	3,98
Classe 3	-	0,82	99,14	0,04	-	-	-	-	-	-	-	-
Classe 4	1,43	-	-	98,30	-	-	-	-	-	0,27	-	-
Classe 5	-	-	-	-	88,48	7,95	-	3,57	-	-	-	-
Classe 6	-	-	-	-	6,59	89,26	-	4,15	-	-	-	-
Classe 7	-	-	-	-	-	-	88,14	-	-	11,86	-	-
Classe 8	-	-	-	-	2,20	4,82	-	91,56	-	-	1,42	-
Classe 9	-	0,14	-	13,29	-	-	0,05	-	86,52	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,50	-	-	99,50	-
Classe 12	-	0,57	-	-	-	-	-	-	-	-	-	98,43

Decomp. Wavelet
Distância CityblockEficiência de Recup.
89,70apenas CA
1.024

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	59,59	1,69	-	-	-	-	-	-	-	38,72	-	-
Classe 2	10,37	64,24	1,31	0,11	-	-	-	-	0,86	17,53	-	5,58
Classe 3	-	4,90	94,08	-	-	-	-	-	1,02	-	-	-
Classe 4	4,88	0,24	-	94,88	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	84,66	8,75	-	6,59	-	-	-	-
Classe 6	-	-	-	-	7,53	87,10	-	5,37	-	-	-	-
Classe 7	3,10	2,99	-	-	-	-	84,41	-	-	9,50	-	-
Classe 8	-	-	-	-	0,30	0,68	-	98,75	-	-	0,27	-
Classe 9	-	0,86	-	8,18	-	-	0,28	-	90,68	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,43	-	-	99,57	-
Classe 12	-	4,08	-	-	-	-	-	-	-	-	-	95,16

Decomp. Wavelet
Distância EuclidianaEficiência de Recup.
87,76apenas CA
1.024

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,72	0,23	-	-	-	-	-	-	-	23,05	-	-
Classe 2	17,12	62,70	3,62	0,06	-	-	-	-	0,82	11,46	-	4,22
Classe 3	-	0,36	99,58	0,06	-	-	-	-	-	-	-	-
Classe 4	2,11	-	-	97,71	-	-	-	-	-	0,18	-	-
Classe 5	-	-	-	-	90,16	6,51	-	3,33	-	-	-	-
Classe 6	-	-	-	-	5,48	90,94	-	3,58	-	-	-	-
Classe 7	-	-	-	-	-	-	86,31	-	-	13,69	-	-
Classe 8	-	-	-	-	0,87	3,09	-	95,24	-	-	0,80	-
Classe 9	-	0,13	-	12,12	-	-	0,01	-	87,74	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,57	-	-	99,43	-
Classe 12	-	1,86	-	-	-	-	-	-	-	-	-	97,20

Decomp. Wavelet
Dsitância Cityblock

Eficiência de Recup.
90,31

apenas CA
1.024

UNIFORMIZADO

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,30	0,34	-	-	-	-	-	-	-	23,36	-	-
Classe 2	16,95	61,55	2,64	0,03	-	-	-	-	0,83	11,60	-	6,40
Classe 3	-	0,53	99,42	0,05	-	-	-	-	-	-	-	-
Classe 4	1,19	-	-	98,29	-	-	-	-	-	0,52	-	-
Classe 5	-	-	-	-	88,17	6,81	-	5,02	-	-	-	-
Classe 6	-	-	-	-	6,28	91,14	-	2,58	-	-	-	-
Classe 7	-	-	-	-	-	-	80,04	-	-	19,96	-	-
Classe 8	-	-	-	-	0,55	0,45	-	98,77	-	-	0,23	-
Classe 9	-	-	-	12,03	-	-	0,01	-	87,96	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,10	-	-	98,90	-
Classe 12	-	4,61	-	-	-	-	-	-	-	-	-	94,49

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
89,59

apenas CA
1.024

NORMALIZADO

	WAVELET - 5 íveis de Dec. - Coeficientes de Aproximação do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	81,07	0,40			-	-	-	-		18,53	-	
Classe 2	17,58	61,57	3,58	0,11					0,86	9,64		6,66
Classe 3		0,35	99,65		-	-	-	-			-	
Classe 4	1,58			98,34						0,08		
Classe 5	-	-	-		87,80	9,15		3,05	-		-	-
Classe 6		-	-	-	6,32	90,56		3,12	-	-	-	-
Classe 7	0,15	-	-	-			94,39			5,46	-	-
Classe 8	-	-	-	-	1,36	5,74		91,52			1,38	-
Classe 9	-	0,14	-	12,06	-	-	0,23		87,57	-	-	-
Classe 10	-	-	-	-	-	-	-	-		100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,16	-	-	99,84	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
90,94

apenas CA
256

	WAVELET - 5 íveis de Dec. - Coeficientes de Aproximação do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	71,74	1,73	-	-	-	-	-	-	-	26,53	-	-
Classe 2	13,32	62,58	2,15	0,11	-	-	-	-	0,86	13,65	-	7,33
Classe 3	-	3,57	96,43	-	-	-	-	-	-	-	-	-
Classe 4	4,31	-	-	95,69	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	83,43	10,30	-	6,27	-	-	-	-
Classe 6	-	-	-	-	7,42	88,80	-	3,78	-	-	-	-
Classe 7	1,40	2,37	-	-	-	-	91,87	-	-	4,36	-	-
Classe 8	-	-	-	-	0,45	1,34	-	97,89	-	-	0,32	-
Classe 9	-	0,88	-	8,53	-	-	0,19	-	90,40	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,03	-	-	99,97	-
Classe 12	-	0,90	-	-	-	-	-	-	-	-	-	98,22

Decomp. Wavelet
Distância Euclidiana

Eficiência de Recup.
89,75

apenas CA
256

	WAVELET - 5 íveis de Dec. - Coeficientes de Aproximação do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	83,49	0,40	-	-	-	-	-	-	-	16,11	-	-
Classe 2	19,03	59,45	3,79	0,13	-	-	-	-	0,86	8,72	-	8,02
Classe 3	-	0,13	99,87	-	-	-	-	-	-	-	-	-
Classe 4	1,95	-	-	97,97	-	-	-	-	-	0,08	-	-
Classe 5	-	-	-	-	88,94	7,65	-	3,41	-	-	-	-
Classe 6	-	-	-	-	5,60	91,75	-	2,65	-	-	-	-
Classe 7	0,13	-	-	-	-	-	93,26	-	-	6,61	-	-
Classe 8	-	-	-	-	0,64	3,59	-	95,11	-	-	0,66	-
Classe 9	-	0,13	-	12,01	-	-	0,03	-	87,83	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,15	-	-	99,85	-
Classe 12	-	0,37	-	-	-	-	-	-	-	-	-	98,63

Decomp. Wavelet
Dsitância Cityblock

Eficiência de Recup.
91,35

apenas CA
256

UNIFORMIZADO

WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação do 5o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	82,93	0,53	-	-	-	-	-	-	-	16,54	-	-
Classe 2	18,66	57,43	3,57	0,12	-	-	-	-	0,86	9,08	-	10,28
Classe 3	-	0,25	99,75	-	-	-	-	-	-	-	-	-
Classe 4	1,19	-	-	98,40	-	-	-	-	-	0,41	-	-
Classe 5	-	-	-	-	87,20	7,92	-	4,88	-	-	-	-
Classe 6	-	-	-	-	6,43	91,70	-	1,87	-	-	-	-
Classe 7	-	-	-	-	-	-	90,51	-	-	9,49	-	-
Classe 8	-	-	-	-	0,45	0,69	-	98,51	-	-	0,35	-
Classe 9	-	0,03	-	11,92	-	-	0,07	-	87,98	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,39	-	-	99,61	-
Classe 12	-	3,30	-	-	-	-	-	-	-	-	-	95,74

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
90,81

apenas CA
256

NORMALIZADO

WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação do 6o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	87,90	0,59	-	-	-	-	-	-	-	11,51	-	-
Classe 2	21,75	53,80	4,65	0,07	-	-	-	-	0,63	4,83	-	14,27
Classe 3	-	0,35	99,65	-	-	-	-	-	-	-	-	-
Classe 4	1,71	-	-	98,29	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	87,37	10,03	-	2,60	-	-	-	-
Classe 6	-	-	-	-	6,38	90,75	-	2,87	-	-	-	-
Classe 7	-	-	-	-	-	-	97,71	-	-	2,29	-	-
Classe 8	-	-	-	-	0,91	6,60	-	91,57	-	-	0,92	-
Classe 9	-	0,14	0,12	12,04	-	-	-	-	87,70	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
91,15

apenas CA
64

MELHOR
RESULTADO

Máximo vlr. 1,2580E+05
Mínimo vlr. -1,3107E+05

WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação do 6o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	84,04	0,90	-	-	-	-	-	-	-	15,06	-	-
Classe 2	19,19	54,65	3,39	-	-	-	-	-	0,86	7,47	-	14,44
Classe 3	-	2,89	97,11	-	-	-	-	-	-	-	-	-
Classe 4	3,82	-	-	95,91	-	-	-	-	0,27	-	-	-
Classe 5	-	-	-	-	81,32	12,19	-	6,49	-	-	-	-
Classe 6	-	-	-	-	7,24	89,33	-	3,43	-	-	-	-
Classe 7	0,48	-	-	-	-	-	99,35	-	-	0,17	-	-
Classe 8	-	-	-	-	0,82	4,04	-	95,05	-	-	0,09	-
Classe 9	-	0,67	-	9,52	-	-	-	-	89,81	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	0,19	-	-	-	-	-	-	-	-	-	98,85

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
90,45

apenas CA
64

WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação do 6o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	89,15	0,61	-	-	-	-	-	-	-	10,24	-	-
Classe 2	22,60	52,44	5,00	0,04	-	-	-	-	0,62	4,28	-	15,02
Classe 3	-	0,14	99,86	-	-	-	-	-	-	-	-	-
Classe 4	1,99	-	-	98,01	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	88,15	8,63	-	3,22	-	-	-	-
Classe 6	-	-	-	-	6,09	91,68	-	2,23	-	-	-	-
Classe 7	-	-	-	-	-	-	97,42	-	-	2,58	-	-
Classe 8	-	-	-	-	0,72	4,28	-	94,48	-	-	0,52	-
Classe 9	-	0,14	-	12,04	-	-	-	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	1,13	-	-	-	-	-	-	-	-	-	97,92

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
91,41

apenas CA
64

Melhor Resultado
UNIFORMIZADO

Máximo vlr. 1
Mínimo vlr. 0

WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação do 6o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	89,50	0,86	-	-	-	-	-	-	-	9,64	-	-
Classe 2	22,66	50,66	4,84	0,04	-	-	-	-	0,59	4,52	-	16,69
Classe 3	-	0,36	99,64	-	-	-	-	-	-	-	-	-
Classe 4	1,45	-	-	98,55	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	86,71	8,96	-	4,33	-	-	-	-
Classe 6	-	-	-	-	7,18	90,98	-	1,84	-	-	-	-
Classe 7	-	-	-	-	-	-	96,18	-	-	3,82	-	-
Classe 8	-	-	-	-	0,71	1,32	-	97,59	-	-	0,38	-
Classe 9	-	0,36	-	11,61	-	-	-	-	88,03	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	5,56	-	-	-	-	-	-	-	-	-	93,56

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
90,95

apenas CA
64

Melhor Resultado
NORMALIZADO

Máximo vlr. 3,7957
Mínimo vlr. -3,0902

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	84,98	4,88	-	-	-	-	0,15	-	-	9,99	-	-
Classe 2	18,45	47,25	5,10	-	-	-	9,84	-	0,81	-	-	18,55
Classe 3	-	1,44	96,35	0,74	-	-	-	-	-	-	-	1,47
Classe 4	0,52	-	-	98,08	-	-	1,40	-	-	-	-	-
Classe 5	-	-	-	-	80,52	10,04	-	9,32	-	-	0,12	-
Classe 6	-	-	-	-	7,40	87,39	-	4,55	-	-	0,66	-
Classe 7	0,18	0,10	-	-	-	-	99,72	-	-	-	-	-
Classe 8	-	-	-	-	8,87	6,58	-	83,67	-	-	0,88	-
Classe 9	-	0,14	1,48	12,04	-	-	-	-	86,34	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,05	-	0,04	-	-	99,91	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,60apenas CA
16

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	86,53	3,97	-	-	-	-	0,07	-	-	9,43	-	-
Classe 2	18,39	46,54	5,74	-	-	-	9,63	-	0,86	-	-	18,84
Classe 3	-	1,24	97,11	-	-	-	-	-	-	-	-	1,65
Classe 4	1,01	-	-	97,98	-	-	1,01	-	-	-	-	-
Classe 5	-	-	-	-	81,14	8,95	-	9,83	-	-	0,08	-
Classe 6	-	-	-	-	7,64	87,35	-	4,41	-	-	0,60	-
Classe 7	0,25	0,18	-	-	-	-	99,57	-	-	-	-	-
Classe 8	-	-	-	-	8,34	5,50	-	85,34	-	-	0,82	-
Classe 9	-	0,20	0,61	11,98	-	-	-	-	87,21	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,06	-	0,03	-	-	99,91	-
Classe 12	-	0,03	0,35	-	-	-	-	-	-	-	-	98,62

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,94apenas CA
16

UNIFORMIZADO

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	85,37	3,46	-	-	-	-	0,18	-	-	10,99	-	-
Classe 2	17,16	49,65	4,88	-	-	-	9,34	-	0,86	-	-	18,11
Classe 3	-	3,15	96,61	-	-	-	-	-	0,11	-	-	0,13
Classe 4	-	-	-	94,02	-	-	5,98	-	-	-	-	-
Classe 5	-	-	-	-	77,91	11,73	-	10,26	-	-	0,10	-
Classe 6	-	-	-	-	8,09	88,67	-	2,46	-	-	0,78	-
Classe 7	0,78	0,23	-	-	-	-	98,95	-	-	0,04	-	-
Classe 8	-	-	-	-	9,49	5,61	-	84,17	-	-	0,73	-
Classe 9	-	1,00	0,95	10,74	-	-	-	-	87,31	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,47apenas CA
16

NORMALIZADO

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	47,01	0,02	-	-	-	-	-	-	-	52,97	-	-
Classe 2	8,84	65,12	0,59	0,15	-	-	-	-	0,83	23,77	-	0,70
Classe 3	-	0,06	89,68	6,71	-	-	-	-	3,55	-	-	-
Classe 4	-	-	-	95,45	-	-	-	-	-	4,55	-	-
Classe 5	-	-	-	-	88,19	4,69	-	7,12	-	-	-	-
Classe 6	-	-	-	-	7,11	84,21	-	8,68	-	-	-	-
Classe 7	-	-	-	-	-	-	51,45	-	-	48,55	-	-
Classe 8	-	-	-	-	1,36	1,43	-	96,45	-	-	0,76	-
Classe 9	-	0,14	-	16,06	-	-	-	-	83,80	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,47	-	-	98,53	-
Classe 12	-	1,41	-	-	-	-	-	-	-	-	-	97,60

Decomp. Wavelet
Distância CityblockEficiência de Recup.
83,12CA+CH+CV+CD
4.096 cada coef.
16.384 total

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	50,31	1,30	-	-	-	-	-	-	-	48,39	-	-
Classe 2	8,44	64,16	0,37	0,12	-	-	-	-	0,86	21,58	-	4,47
Classe 3	-	6,71	90,00	-	-	-	-	-	3,29	-	-	-
Classe 4	5,44	0,26	-	94,18	-	-	-	-	-	0,12	-	-
Classe 5	-	-	-	-	84,35	7,05	-	8,60	-	-	-	-
Classe 6	-	-	-	-	7,43	84,32	-	8,25	-	-	-	-
Classe 7	4,44	3,31	-	-	-	-	58,67	-	-	33,58	-	-
Classe 8	-	-	-	-	0,18	0,30	-	99,36	-	-	0,16	-
Classe 9	-	0,88	-	8,52	-	-	-	-	90,60	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,93	-	-	99,07	-
Classe 12	-	5,82	-	-	-	-	-	-	-	-	-	93,45

Decomp. Wavelet
Distância EuclidianaEficiência de Recup.
84,04CA+CH+CV+CD
4.096 vls cada coef.
16.384 total

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	18,27	-	-	-	-	-	-	-	-	81,73	-	-
Classe 2	12,59	46,45	-	-	-	-	-	-	0,55	40,41	-	-
Classe 3	-	-	65,05	19,56	-	-	-	-	15,39	-	-	-
Classe 4	-	-	-	86,00	-	-	-	-	-	14,00	-	-
Classe 5	-	-	-	-	88,38	1,84	-	9,78	-	-	-	-
Classe 6	-	-	-	-	6,83	81,73	-	10,89	-	-	0,55	-
Classe 7	-	-	-	-	-	-	49,34	-	-	50,66	-	-
Classe 8	-	-	-	-	0,54	0,60	-	97,95	-	0,64	0,27	-
Classe 9	-	0,11	-	17,55	-	-	-	-	82,34	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,20	-	7,86	-	-	91,94	-
Classe 12	-	0,67	-	1,13	-	-	-	-	3,93	39,74	-	53,93

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
71,78

CA+CH+CV+CD
4096 vls cada coef.
16.384 total

UNIFORMIZADO

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	8,96	-	-	-	-	-	-	-	-	91,04	-	-
Classe 2	0,43	8,25	-	-	-	-	-	-	-	91,32	-	-
Classe 3	0,07	0,04	17,55	19,30	-	-	-	-	13,05	49,99	-	-
Classe 4	-	-	-	56,98	-	-	-	-	-	43,02	-	-
Classe 5	-	-	-	-	49,40	0,09	-	12,46	-	38,05	-	-
Classe 6	-	-	-	-	7,47	39,74	-	52,07	-	0,47	0,25	-
Classe 7	-	-	-	-	-	-	44,63	-	-	55,37	-	-
Classe 8	-	-	-	-	0,14	0,06	-	81,73	-	18,03	0,04	-
Classe 9	-	-	-	-	-	-	-	-	74,35	25,65	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,65	-	45,72	-	-	53,63	-
Classe 12	-	-	-	-	-	-	-	-	-	72,33	-	27,61

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
46,90

CA+CH+CV+CD
4096 vls cada coef.
16.384 total

NORMALIZADOS

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	49,86	0,08	-	-	-	-	-	-	-	50,06	-	-
Classe 2	8,78	65,25	0,79	0,15	-	-	-	-	0,82	23,63	-	0,58
Classe 3	-	1,55	92,51	3,96	-	-	-	-	1,98	-	-	-
Classe 4	-	-	-	94,93	-	-	-	-	-	5,07	-	-
Classe 5	-	-	-	-	88,81	4,35	-	6,84	-	-	-	-
Classe 6	-	-	-	-	7,03	84,65	-	8,32	-	-	-	-
Classe 7	-	-	-	-	-	-	51,02	-	-	48,98	-	-
Classe 8	-	-	-	-	1,11	0,95	-	96,89	-	-	1,05	-
Classe 9	-	0,14	-	14,66	-	-	-	-	85,20	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,97	-	-	98,03	-
Classe 12	-	4,30	-	-	-	-	-	-	-	-	-	94,76

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
83,49

CA+CH+CV+CD
1.024 cada coef
4.096 total

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	53,48	1,51	-	-	-	-	-	-	-	45,01	-	-
Classe 2	9,13	64,33	0,77	0,12	-	-	-	-	0,86	20,15	-	4,64
Classe 3	-	5,85	92,17	-	-	-	-	-	1,98	-	-	-
Classe 4	5,28	0,27	-	94,42	-	-	-	-	-	0,03	-	-
Classe 5	-	-	-	-	84,71	7,57	-	7,72	-	-	-	-
Classe 6	-	-	-	-	7,59	85,27	-	7,14	-	-	-	-
Classe 7	4,53	3,62	-	-	-	-	70,69	-	-	21,16	-	-
Classe 8	-	-	-	-	0,20	0,37	-	99,21	-	-	0,22	-
Classe 9	-	0,86	-	8,46	-	-	0,04	-	90,64	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,77	-	-	99,23	-
Classe 12	-	5,41	-	-	-	-	-	-	-	-	-	93,85

Decomp. Wavelet
Distância Euclidiana

Eficiência de Recup.
85,67

CA+CH+CV+CD
1.024 cada coef
4.096 total

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	23,16	-	-	-	-	-	-	-	-	76,84	-	-
Classe 2	11,41	50,16	-	-	-	-	-	-	0,41	38,02	-	-
Classe 3	0,02	0,01	77,62	16,46	-	-	-	-	5,89	-	-	-
Classe 4	-	-	-	86,12	-	-	-	-	-	13,88	-	-
Classe 5	-	-	-	-	89,90	1,16	-	8,94	-	-	-	-
Classe 6	-	-	-	-	6,36	81,82	-	11,35	-	-	0,47	-
Classe 7	-	-	-	-	-	-	49,49	-	-	50,51	-	-
Classe 8	-	-	-	-	0,50	0,25	-	98,26	-	0,19	0,80	-
Classe 9	-	0,14	-	16,20	-	-	-	-	83,48	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,01	-	7,47	-	-	92,52	-
Classe 12	-	6,43	-	-	-	-	-	-	0,96	39,15	-	52,91

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
73,79

CA+CH+CV+CD
1.024 cada coef
4.096 total

UNIFORMIZADO

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	14,71	-	-	-	-	-	-	-	-	85,29	-	-
Classe 2	0,69	18,65	-	-	-	-	-	-	-	80,66	-	-
Classe 3	0,19	-	57,70	1,85	-	-	-	-	7,67	32,59	-	-
Classe 4	-	-	-	65,63	-	-	-	-	-	34,37	-	-
Classe 5	-	-	-	-	70,63	0,11	-	14,98	-	14,28	-	-
Classe 6	-	-	-	-	9,74	44,78	-	45,42	-	-	0,06	-
Classe 7	-	-	-	-	-	-	47,49	-	-	52,51	-	-
Classe 8	-	-	-	-	0,39	-	-	82,80	-	16,61	0,20	-
Classe 9	-	-	-	-	-	-	-	-	76,15	23,85	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	0,02	0,02	-	23,14	-	-	76,82	-
Classe 12	-	-	-	-	-	-	-	-	-	64,02	-	35,87

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
57,60

CA+CH+CV+CD
1.024 cada coef
4.096 total

NORMALIZADOS

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	58,88	0,13	-	-	-	-	-	-	-	40,99	-	-
Classe 2	10,09	65,24	0,89	0,19	-	-	-	-	0,79	21,57	-	1,23
Classe 3	-	0,90	93,84	5,26	-	-	-	-	-	-	-	-
Classe 4	0,35	-	-	94,01	-	-	-	-	-	5,64	-	-
Classe 5	-	-	-	-	89,66	5,23	-	5,11	-	-	-	-
Classe 6	-	-	-	-	6,44	86,95	-	6,61	-	-	-	-
Classe 7	-	-	-	-	-	-	52,02	-	-	47,98	-	-
Classe 8	-	-	-	-	0,71	0,94	-	96,72	-	-	1,63	-
Classe 9	-	0,14	-	11,78	-	-	0,43	-	87,65	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	2,78	-	-	97,22	-
Classe 12	-	5,50	-	-	-	-	-	-	-	-	-	93,61

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
84,65

CA+CH+CV+CD
256 cada coef
1.024 total

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	59,59	1,69	-	-	-	-	-	-	-	38,72	-	-
Classe 2	10,37	64,24	1,31	0,11	-	-	-	-	0,86	17,53	-	5,58
Classe 3	-	4,90	94,08	-	-	-	-	-	1,02	-	-	-
Classe 4	4,88	0,24	-	94,88	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	84,66	8,75	-	6,59	-	-	-	-
Classe 6	-	-	-	-	7,53	87,10	-	5,37	-	-	-	-
Classe 7	3,10	2,99	-	-	-	-	84,41	-	-	9,50	-	-
Classe 8	-	-	-	-	0,30	0,68	-	98,75	-	-	0,27	-
Classe 9	-	0,86	-	8,18	-	-	0,28	-	90,68	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,43	-	-	99,57	-
Classe 12	-	4,08	-	-	-	-	-	-	-	-	-	95,16

Decomp. Wavelet
Distância Euclidiana

Eficiência de Recup.
87,76

CA+CH+CV+CD
256 cada coef
1.024 total

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	34,82	-	-	-	-	-	-	-	-	65,18	-	-
Classe 2	13,03	52,76	-	-	-	-	-	-	-	34,21	-	-
Classe 3	0,38	0,31	84,13	13,41	-	-	-	-	1,77	-	-	-
Classe 4	0,05	-	-	86,74	-	-	-	-	-	13,21	-	-
Classe 5	-	-	-	-	92,35	1,83	-	5,82	-	-	-	-
Classe 6	-	-	-	-	5,75	83,89	-	9,79	-	-	0,57	-
Classe 7	-	-	-	-	-	-	49,32	-	-	50,68	-	-
Classe 8	-	-	-	-	0,60	0,18	-	96,55	-	-	2,67	-
Classe 9	-	0,26	-	5,44	-	-	3,89	-	86,45	3,96	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	8,15	-	-	91,85	-
Classe 12	0,87	14,96	-	-	-	-	-	-	-	28,69	-	54,91

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
76,15

CA+CH+CV+CD
256 cada coef
1.024 total

UNIFORMIZADO

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	24,72	-	-	-	-	-	-	-	-	75,28	-	-
Classe 2	8,49	36,29	-	-	-	-	-	-	-	55,22	-	-
Classe 3	1,67	0,02	76,61	2,09	-	-	-	-	1,56	18,05	-	-
Classe 4	0,01	-	-	74,20	-	-	-	-	-	25,79	-	-
Classe 5	-	-	-	-	85,87	1,03	-	13,09	-	-	0,01	-
Classe 6	-	-	-	-	11,54	61,76	-	25,99	-	-	0,71	-
Classe 7	-	-	-	-	-	-	48,42	-	-	51,58	-	-
Classe 8	-	-	-	-	0,30	-	-	87,56	-	11,11	1,03	-
Classe 9	-	-	-	-	-	-	-	-	78,11	21,89	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	0,03	-	-	14,70	-	-	85,27	-
Classe 12	-	-	-	-	-	-	-	-	-	53,73	-	45,95

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
67,06

CA+CH+CV+CD
256 cada coef
1.024 total

NORMALIZADOS

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 6o. Nível												Decomp. Wavelet
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Cityblock
Classe1	76,06	0,30	-	-	-	-	-	-	-	23,64	-	-	
Classe 2	13,00	67,09	0,59	0,13	-	-	-	-	0,73	17,04	-	1,42	Eficiência de Recup. 88,12
Classe 3	-	1,43	97,96	0,61	-	-	-	-	-	-	-	-	
Classe 4	3,24	-	-	95,91	-	-	-	-	-	0,85	-	-	
Classe 5	-	-	-	-	89,32	7,34	-	3,34	-	-	-	-	CA+CH+CV+CD
Classe 6	-	-	-	-	5,45	90,22	-	4,33	-	-	-	-	64 cada coef
Classe 7	-	-	-	-	-	-	63,77	-	-	36,23	-	-	256 total
Classe 8	-	-	-	-	0,23	0,84	-	96,59	-	-	2,34	-	
Classe 9	-	0,15	-	3,25	-	-	7,15	-	89,45	-	-	-	
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	-	-	-	-	-	1,94	-	-	98,06	-	
Classe 12	-	6,10	-	-	-	-	-	-	-	-	-	93,00	

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 6o. Nível												Decomp. Wavelet
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Euclidiana
Classe1	71,74	1,73	-	-	-	-	-	-	-	26,53	-	-	
Classe 2	13,32	62,58	2,15	0,11	-	-	-	-	0,86	13,65	-	7,33	Eficiência de Recup. 89,75
Classe 3	-	3,57	96,43	-	-	-	-	-	-	-	-	-	
Classe 4	4,31	-	-	95,69	-	-	-	-	-	-	-	-	
Classe 5	-	-	-	-	83,43	10,30	-	6,27	-	-	-	-	CA+CH+CV+CD
Classe 6	-	-	-	-	7,42	88,80	-	3,78	-	-	-	-	64 cada coef
Classe 7	1,40	2,37	-	-	-	-	91,87	-	-	4,36	-	-	256 total
Classe 8	-	-	-	-	0,45	1,34	-	97,89	-	-	0,32	-	
Classe 9	-	0,88	-	8,53	-	-	0,19	-	90,40	-	-	-	
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	-	-	-	-	-	0,03	-	-	99,97	-	
Classe 12	-	0,90	-	-	-	-	-	-	-	-	-	98,22	

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 6o. Nível												Decomp. Wavelet
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Cityblock
Classe1	57,53	0,01	-	-	-	-	-	-	-	42,46	-	-	
Classe 2	13,46	57,38	-	-	-	-	-	-	-	29,16	-	-	Eficiência de Recup. 80,98
Classe 3	1,02	2,58	95,93	0,47	-	-	-	-	-	-	-	-	
Classe 4	4,16	-	-	94,50	-	-	-	-	-	1,34	-	-	
Classe 5	-	-	-	-	90,66	5,01	-	3,91	-	-	0,42	-	CA+CH+CV+CD
Classe 6	-	-	-	-	4,21	89,26	-	6,42	-	-	0,11	-	64 cada coef
Classe 7	-	-	-	-	-	-	48,36	-	-	51,64	-	-	256 total
Classe 8	-	-	-	-	0,30	0,13	-	95,58	-	-	3,99	-	
Classe 9	1,14	-	-	0,55	-	-	7,86	-	84,60	5,85	-	-	UNIFORMIZADO
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	-	-	-	0,01	-	7,00	-	-	92,99	-	
Classe 12	0,28	24,57	-	-	-	-	-	-	-	9,58	-	64,93	

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 6o. Nível												Decomp. Wavelet
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Cityblock
Classe1	46,08	-	-	-	-	-	-	-	-	53,92	-	-	
Classe 2	11,41	53,27	-	-	-	-	-	-	-	35,32	-	-	Eficiência de Recup. 77,40
Classe 3	4,10	2,74	92,58	0,08	-	-	-	-	-	0,50	-	-	
Classe 4	3,09	-	-	93,15	-	-	-	-	-	3,76	-	-	
Classe 5	-	-	-	-	87,87	4,63	-	6,99	-	-	0,51	-	CA+CH+CV+CD
Classe 6	-	-	-	-	4,85	82,34	-	12,54	-	-	0,27	-	64 cada coef
Classe 7	-	-	-	-	-	-	47,82	-	-	52,18	-	-	256 total
Classe 8	-	-	-	-	0,13	0,07	-	97,11	-	0,22	2,47	-	
Classe 9	0,09	-	-	-	-	-	2,32	-	80,02	17,57	-	-	NORMALIZADOS
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	-	-	-	0,02	-	8,17	-	-	91,81	-	
Classe 12	0,38	25,01	-	-	-	-	-	-	-	17,28	-	56,69	

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 7o. Nível												Decomp. Wavelet
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Cityblock
Classe1	86,06	0,78	-	-	-	-	-	-	-	13,16	-	-	
Classe 2	17,74	62,74	0,51	0,25	-	-	-	-	0,68	11,37	-	6,71	Eficiência de Recup. 91,36
Classe 3	-	2,45	97,06	0,49	-	-	-	-	-	-	-	-	
Classe 4	7,81	-	-	91,55	-	-	-	-	0,64	-	-	-	
Classe 5	-	-	-	-	83,94	11,91	-	4,15	-	-	-	-	CA+CH+CV+CD
Classe 6	-	-	-	-	6,23	89,82	-	3,95	-	-	-	-	16 cada coef
Classe 7	-	-	-	-	-	-	99,90	-	-	0,10	-	-	64 total
Classe 8	-	-	-	-	0,25	2,80	-	96,44	-	-	0,51	-	
Classe 9	-	0,06	-	9,74	-	-	-	-	90,20	-	-	-	
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	-	-	-	-	-	0,03	-	-	99,97	-	
Classe 12	-	0,39	-	-	-	-	-	-	-	-	-	98,61	MELHOR RESULTADO

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	84,04	0,90	-	-	-	-	-	-	-	15,06	-	-
Classe 2	19,19	54,65	3,39	-	-	-	-	-	0,86	7,47	-	14,44
Classe 3	-	2,89	97,11	-	-	-	-	-	-	-	-	-
Classe 4	3,82	-	-	95,91	-	-	-	-	0,27	-	-	-
Classe 5	-	-	-	-	81,32	12,19	-	6,49	-	-	-	-
Classe 6	-	-	-	-	7,24	89,33	-	3,43	-	-	-	-
Classe 7	0,48	-	-	-	-	-	99,35	-	-	0,17	-	-
Classe 8	-	-	-	-	0,82	4,04	-	95,05	-	-	0,09	-
Classe 9	-	0,67	-	9,52	-	-	-	-	89,81	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	0,19	-	-	-	-	-	-	-	-	-	98,85

Decomp. Wavelet
Distância Euclidiana

Eficiência de Recup.
90,45

CA+CH+CV+CD
16 cada coef
64 total

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	81,83	0,03	-	-	-	-	-	-	-	18,14	-	-
Classe 2	12,49	63,80	-	0,13	-	-	-	-	0,04	21,36	-	2,18
Classe 3	-	3,33	96,67	-	-	-	-	-	-	-	-	-
Classe 4	12,30	0,14	-	83,45	-	-	-	-	4,11	-	-	-
Classe 5	-	-	-	-	83,24	13,00	-	3,76	-	-	-	-
Classe 6	-	-	-	-	6,03	87,65	-	6,30	-	-	0,02	-
Classe 7	-	-	-	-	-	-	99,85	-	-	0,15	-	-
Classe 8	-	-	-	-	0,07	1,41	-	97,78	-	-	0,74	-
Classe 9	0,20	0,22	-	2,71	-	-	0,30	-	96,57	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,86	-	-	99,14	-
Classe 12	-	11,94	-	-	-	-	-	-	-	-	-	87,12

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
89,76

CA+CH+CV+CD
16 cada coef
64 total

UNIFORMIZADO
MELHOR
RESULTADO

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação, Det. Horizontal, Det. Vertical e Det. Diagonal do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	79,09	-	-	-	-	-	-	-	-	20,91	-	-
Classe 2	12,47	62,37	-	0,07	-	-	-	-	-	22,84	-	2,25
Classe 3	-	3,36	96,64	-	-	-	-	-	-	-	-	-
Classe 4	13,69	0,23	-	80,71	-	-	-	-	5,21	0,16	-	-
Classe 5	-	-	-	-	80,57	14,37	-	5,06	-	-	-	-
Classe 6	-	-	-	-	7,44	83,95	-	8,59	-	-	0,02	-
Classe 7	-	-	-	-	-	-	99,57	-	0,11	0,32	-	-
Classe 8	-	-	-	-	0,06	1,05	-	98,61	-	-	0,28	-
Classe 9	0,85	0,28	-	1,97	-	-	0,05	-	96,70	0,15	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,81	-	-	99,19	-
Classe 12	-	15,05	-	-	-	-	-	-	-	-	-	84,08

Decomp. Wavelet
Distância Cityblock

Eficiência de Recup.
88,46

CA+CH+CV+CD
16 cada coef
64 total

NORMALIZADO
MELHOR
RESULTADO

	WAVELET - 2 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	67,46	0,54	-	-	-	-	-	-	-	32,00	-	-
Classe 2	15,79	63,34	3,03	0,13	-	-	-	-	0,69	11,58	-	5,44
Classe 3	-	0,53	95,51	0,95	-	-	-	-	3,01	-	-	-
Classe 4	1,45	-	-	98,55	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	90,09	7,29	-	2,62	-	-	-	-
Classe 6	-	-	-	-	10,54	83,95	-	5,51	-	-	-	-
Classe 7	-	-	-	-	-	-	96,25	-	-	3,75	-	-
Classe 8	-	-	-	-	5,97	7,31	-	83,48	-	-	3,24	-
Classe 9	-	-	-	13,68	-	-	-	-	86,32	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,26	-	-	99,74	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
88,64

CA + MVE da CA
16.387

MELHOR
RESULTADO

	WAVELET - 2 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	49,92	25,76	-	3,12	-	-	8,17	-	-	13,03	-	-
Classe 2	26,34	36,64	2,39	19,36	-	-	5,35	1,32	4,28	-	-	4,32
Classe 3	-	2,03	46,43	-	-	-	-	36,20	1,69	-	13,65	-
Classe 4	3,03	10,71	-	41,80	-	-	26,16	-	12,31	-	-	5,99
Classe 5	-	-	-	-	69,69	30,17	-	0,14	-	-	-	-
Classe 6	-	-	-	-	43,96	41,80	-	7,92	-	-	6,32	-
Classe 7	4,73	0,67	-	17,25	-	-	77,35	-	-	-	-	-
Classe 8	-	-	16,59	-	2,05	10,54	-	66,82	-	-	4,00	-
Classe 9	-	2,14	-	6,02	-	-	-	-	63,76	-	-	28,08
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	3,95	-	-	2,83	-	1,83	-	-	91,39	-
Classe 12	-	3,66	-	0,76	-	-	-	-	29,68	-	-	65,26

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
62,57

CA + MVE da CA
16.387

	WAVELET - 2 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,32	0,18	-	-	-	-	-	-	-	34,50	-	-
Classe 2	14,21	65,01	2,47	0,05	-	-	-	-	0,81	15,68	-	1,77
Classe 3	-	-	97,67	2,33	-	-	-	-	-	-	-	-
Classe 4	1,56	-	-	97,38	-	-	-	-	-	1,06	-	-
Classe 5	-	-	-	-	90,49	5,97	-	3,64	-	-	-	-
Classe 6	-	-	-	-	5,57	89,31	-	5,12	-	-	-	-
Classe 7	-	-	-	-	-	-	77,73	-	-	22,27	-	-
Classe 8	-	-	-	-	1,42	3,91	-	93,57	-	-	1,10	-
Classe 9	-	0,12	-	12,91	-	-	-	-	86,97	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,05	-	-	98,95	-
Classe 12	-	2,54	-	-	-	-	-	-	-	-	-	96,48

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,24CA + MVE da CA
16.387MELHOR
RESULTADO
UNIFORMIZADO

	WAVELET - 2 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,96	0,22	-	-	-	-	-	-	-	33,82	-	-
Classe 2	14,21	63,71	2,08	0,01	-	-	-	-	0,85	15,38	-	3,76
Classe 3	-	0,26	97,71	2,03	-	-	-	-	-	-	-	-
Classe 4	1,26	-	-	97,86	-	-	-	-	-	0,88	-	-
Classe 5	-	-	-	-	88,68	5,90	-	5,42	-	-	-	-
Classe 6	-	-	-	-	6,18	89,60	-	4,22	-	-	-	-
Classe 7	-	-	-	-	-	-	72,06	-	-	27,94	-	-
Classe 8	-	-	-	-	0,75	0,41	-	98,68	-	-	0,16	-
Classe 9	-	-	-	12,19	-	-	-	-	87,81	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,51	-	-	98,49	-
Classe 12	-	4,91	-	-	-	-	-	-	-	-	-	94,19

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,90CA + MVE da CA
16.387MELHOR
RESULTADO
NORMALIZADO

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,33	5,42	-	3,74	-	-	3,99	-	-	21,52	-	-
Classe 2	25,62	45,17	3,09	5,45	-	-	1,93	-	5,38	-	-	13,36
Classe 3	-	1,36	89,90	-	-	-	-	-	8,74	-	-	-
Classe 4	0,38	-	-	85,74	-	-	9,27	-	4,61	-	-	-
Classe 5	-	-	-	-	88,62	11,01	-	0,37	-	-	-	-
Classe 6	-	-	-	-	26,19	64,53	-	8,01	-	-	1,27	-
Classe 7	0,01	-	-	0,39	-	-	99,60	-	-	-	-	-
Classe 8	-	-	-	-	3,81	11,39	-	67,40	-	-	17,40	-
Classe 9	-	-	-	9,99	-	-	-	-	90,01	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,05	-	0,02	-	-	99,93	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância CityblockEficiência de Recup.
82,94CA + MVE da CA
4.099

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	49,82	26,20	-	2,72	-	-	8,57	-	-	12,69	-	-
Classe 2	26,50	36,46	2,80	19,19	-	-	5,58	1,35	4,40	-	-	3,72
Classe 3	-	2,41	40,93	-	-	-	-	40,97	4,37	-	11,19	0,13
Classe 4	3,03	12,15	-	36,75	-	-	25,62	-	7,71	-	-	14,74
Classe 5	-	-	-	-	70,04	29,84	-	0,12	-	-	-	-
Classe 6	-	-	-	-	45,27	41,30	-	8,16	-	-	5,27	-
Classe 7	7,21	1,09	-	20,96	-	-	70,74	-	-	-	-	-
Classe 8	-	-	16,59	-	2,37	11,18	-	66,82	-	-	3,04	-
Classe 9	-	3,25	-	1,66	-	-	-	-	50,43	-	-	44,66
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	4,83	-	-	2,04	-	0,97	-	-	92,16	-
Classe 12	-	4,07	-	5,78	-	-	-	-	36,82	-	-	52,74

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
59,02CA + MVE da CA
4.099

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	69,50	0,19	-	-	-	-	-	-	-	30,31	-	-
Classe 2	15,09	63,84	3,07	0,03	-	-	-	-	0,83	14,09	-	3,05
Classe 3	-	0,07	98,85	1,08	-	-	-	-	-	-	-	-
Classe 4	1,79	-	-	97,52	-	-	-	-	-	0,69	-	-
Classe 5	-	-	-	-	90,50	6,02	-	3,48	-	-	-	-
Classe 6	-	-	-	-	5,59	89,67	-	4,74	-	-	-	-
Classe 7	-	-	-	-	-	-	80,08	-	-	19,92	-	-
Classe 8	-	-	-	-	1,20	3,34	-	94,52	-	-	0,94	-
Classe 9	-	0,11	-	12,41	-	-	-	-	87,48	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,82	-	-	99,18	-
Classe 12	-	2,24	-	-	-	-	-	-	-	-	-	96,78

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,99CA + MVE da CA
4.099

UNIFORMIZADO

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	69,65	0,22	-	-	-	-	-	-	-	30,13	-	-
Classe 2	15,24	63,40	2,30	0,01	-	-	-	-	0,85	13,87	-	4,33
Classe 3	-	0,53	98,83	0,64	-	-	-	-	-	-	-	-
Classe 4	1,25	-	-	97,99	-	-	-	-	-	0,76	-	-
Classe 5	-	-	-	-	88,62	6,09	-	5,29	-	-	-	-
Classe 6	-	-	-	-	6,37	89,93	-	3,70	-	-	-	-
Classe 7	-	-	-	-	-	-	74,51	-	-	25,49	-	-
Classe 8	-	-	-	-	0,64	0,41	-	98,76	-	-	0,19	-
Classe 9	-	-	-	12,06	-	-	-	-	87,94	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,37	-	-	98,63	-
Classe 12	-	4,79	-	-	-	-	-	-	-	-	-	94,31

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
88,55

CA + MVE da CA
4,099

NORMALIZADO

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	52,06	21,65	-	2,67	-	-	7,93	-	-	15,69	-	-
Classe 2	26,14	38,25	3,31	17,03	-	-	5,61	-	4,46	-	-	5,20
Classe 3	-	2,98	65,75	-	-	-	-	17,12	12,00	-	2,15	-
Classe 4	1,79	6,77	-	52,35	-	-	20,07	-	10,22	-	-	8,80
Classe 5	-	-	-	-	77,25	22,68	-	0,07	-	-	-	-
Classe 6	-	-	-	-	42,50	45,63	-	8,61	-	-	3,26	-
Classe 7	3,32	0,09	-	15,26	-	-	81,33	-	-	-	-	-
Classe 8	-	-	16,59	-	3,09	12,28	-	66,82	-	-	1,22	-
Classe 9	-	1,17	0,33	8,19	-	-	-	-	82,77	-	-	7,54
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,01	-	-	0,84	-	0,07	-	-	99,08	-
Classe 12	-	1,82	-	6,49	-	-	-	-	7,72	-	-	83,22

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
70,38

CA + MVE da CA
1,027

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	50,06	24,99	-	2,50	-	-	8,84	-	-	13,61	-	-
Classe 2	26,09	36,84	3,03	18,46	-	-	6,40	1,14	3,64	-	-	4,40
Classe 3	-	2,53	39,93	-	-	-	-	40,86	8,88	-	7,80	-
Classe 4	2,28	14,04	-	36,19	-	-	22,54	-	1,73	-	-	23,22
Classe 5	-	-	-	-	72,86	27,02	-	0,12	-	-	-	-
Classe 6	-	-	-	-	45,30	42,17	-	8,63	-	-	3,90	-
Classe 7	7,57	1,07	-	21,52	-	-	69,84	-	-	-	-	-
Classe 8	-	-	16,59	-	2,99	12,15	-	66,82	-	-	1,45	-
Classe 9	-	2,44	0,37	0,72	-	-	-	-	59,02	-	-	37,45
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	4,14	-	-	1,23	-	0,16	-	-	94,47	-
Classe 12	-	4,89	-	14,23	-	-	-	-	24,22	-	-	56,10

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
60,36

CA + MVE da CA
1,027

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,98	0,24	-	-	-	-	-	-	-	22,78	-	-
Classe 2	17,23	62,57	3,76	0,07	-	-	-	-	0,84	11,31	-	4,22
Classe 3	-	0,37	99,57	0,06	-	-	-	-	-	-	-	-
Classe 4	2,13	-	-	97,72	-	-	-	-	-	0,15	-	-
Classe 5	-	-	-	-	90,21	6,51	-	3,28	-	-	-	-
Classe 6	-	-	-	-	5,54	90,87	-	3,59	-	-	-	-
Classe 7	-	-	-	-	-	-	87,03	-	-	12,97	-	-
Classe 8	-	-	-	-	0,92	3,24	-	95,01	-	-	0,83	-
Classe 9	-	0,13	-	12,11	-	-	-	-	87,76	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,57	-	-	99,43	-
Classe 12	-	1,72	-	-	-	-	-	-	-	-	-	97,34

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
90,37

CA + MVE da CA
1,027

UNIFORMIZADO

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,41	0,36	-	-	-	-	-	-	-	23,23	-	-
Classe 2	17,03	61,34	2,70	0,02	-	-	-	-	0,84	11,51	-	6,56
Classe 3	-	0,54	99,41	0,05	-	-	-	-	-	-	-	-
Classe 4	1,19	-	-	98,29	-	-	-	-	-	0,52	-	-
Classe 5	-	-	-	-	88,20	6,83	-	4,97	-	-	-	-
Classe 6	-	-	-	-	6,28	91,14	-	2,58	-	-	-	-
Classe 7	-	-	-	-	-	-	80,69	-	-	19,31	-	-
Classe 8	-	-	-	-	0,55	0,47	-	98,73	-	-	0,25	-
Classe 9	-	-	-	12,04	-	-	-	-	87,96	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,06	-	-	98,94	-
Classe 12	-	4,54	-	-	-	-	-	-	-	-	-	94,56

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
89,64

CA + MVE da CA
1,027

NORMALIZADO

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	48,54	21,48	-	1,54	-	-	9,87	-	-	18,57	-	-
Classe 2	25,54	36,46	2,86	18,47	-	-	6,99	0,06	3,65	-	-	5,97
Classe 3	-	2,44	44,50	-	-	-	-	36,45	12,00	-	4,61	-
Classe 4	0,95	11,73	-	37,02	-	-	19,07	-	0,05	-	-	31,18
Classe 5	-	-	-	-	74,11	25,58	-	0,31	-	-	-	-
Classe 6	-	-	-	-	47,60	42,58	-	8,49	-	-	1,33	-
Classe 7	6,55	0,93	-	16,62	-	-	75,90	-	-	-	-	-
Classe 8	-	-	16,59	-	4,64	11,81	-	66,78	-	-	0,18	-
Classe 9	-	1,53	3,00	7,51	-	-	-	-	79,38	-	-	8,58
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	3,61	-	-	0,28	-	0,02	-	-	96,09	-
Classe 12	-	3,12	-	25,05	-	-	-	-	0,14	-	-	70,96

Decomp. WAVELET
Distância CityblockEficiência de Recup.
64,36CA + MVE da CA
259

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	48,33	21,98	-	1,49	-	-	10,02	-	-	18,18	-	-
Classe 2	25,46	36,28	2,81	18,76	-	-	7,12	0,24	3,52	-	-	5,81
Classe 3	-	2,39	39,24	-	-	-	-	41,23	11,74	-	5,40	-
Classe 4	0,97	12,61	-	31,77	-	-	19,54	-	0,01	-	-	35,10
Classe 5	-	-	-	-	73,19	26,50	-	0,31	-	-	-	-
Classe 6	-	-	-	-	48,17	41,99	-	8,45	-	-	1,39	-
Classe 7	6,98	1,59	-	17,80	-	-	73,63	-	-	-	-	-
Classe 8	-	-	17,29	-	4,61	11,82	-	66,08	-	-	0,20	-
Classe 9	-	1,65	3,23	5,10	-	-	-	-	77,99	-	-	12,03
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	5,09	-	-	0,30	-	0,03	-	-	94,58	-
Classe 12	-	3,92	-	31,39	-	-	-	-	0,34	-	-	63,70

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
62,23CA + MVE da CA
259

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	83,51	0,44	-	-	-	-	-	-	-	16,05	-	-
Classe 2	19,93	58,48	4,39	0,13	-	-	-	-	0,86	7,49	-	8,72
Classe 3	-	0,18	99,82	-	-	-	-	-	-	-	-	-
Classe 4	1,94	-	-	98,05	-	-	-	-	-	0,01	-	-
Classe 5	-	-	-	-	89,03	7,68	-	3,29	-	-	-	-
Classe 6	-	-	-	-	5,75	91,49	-	2,76	-	-	-	-
Classe 7	0,20	-	-	-	-	-	94,37	-	-	5,43	-	-
Classe 8	-	-	-	-	0,78	4,24	-	94,26	-	-	0,72	-
Classe 9	-	0,11	-	12,04	-	-	-	-	87,85	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,13	-	-	99,87	-
Classe 12	-	0,09	-	-	-	-	-	-	-	-	-	98,91

Decomp. WAVELET
Distância CityblockEficiência de Recup.
91,30CA + MVE da CA
259

UNIFORMIZADO

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	82,92	0,55	-	-	-	-	-	-	-	16,53	-	-
Classe 2	19,28	57,01	3,95	0,12	-	-	-	-	0,86	8,24	-	10,54
Classe 3	-	0,27	99,73	-	-	-	-	-	-	-	-	-
Classe 4	1,26	-	-	98,46	-	-	-	-	-	0,28	-	-
Classe 5	-	-	-	-	87,35	7,97	-	4,68	-	-	-	-
Classe 6	-	-	-	-	6,59	91,54	-	1,87	-	-	-	-
Classe 7	-	-	-	-	-	-	91,58	-	-	8,42	-	-
Classe 8	-	-	-	-	0,47	0,79	-	98,35	-	-	0,39	-
Classe 9	-	0,04	-	11,95	-	-	0,03	-	87,98	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,36	-	-	99,64	-
Classe 12	-	2,73	-	-	-	-	-	-	-	-	-	96,32

Decomp. WAVELET
Distância CityblockEficiência de Recup.
90,91CA + MVE da CA
259

NORMALIZADO

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	53,06	21,35	-	0,05	-	-	6,84	-	-	18,70	-	-
Classe 2	25,34	32,28	2,09	12,03	-	-	5,40	-	4,60	-	-	18,26
Classe 3	-	1,89	43,58	-	-	-	-	37,32	9,69	-	7,52	-
Classe 4	-	11,84	-	35,07	-	-	16,79	-	0,47	-	-	35,83
Classe 5	-	-	-	-	58,63	37,56	-	3,81	-	-	-	-
Classe 6	-	-	-	-	52,25	42,25	-	5,50	-	-	-	-
Classe 7	2,66	3,40	-	16,31	-	-	77,63	-	-	-	-	-
Classe 8	-	-	17,76	-	8,84	8,13	-	64,86	-	-	0,41	-
Classe 9	-	3,86	2,86	2,97	-	-	-	-	90,31	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	13,08	-	-	-	-	5,24	-	-	81,68	-
Classe 12	-	15,18	-	19,87	-	-	-	-	-	-	-	64,25

Decomp. WAVELET
Distância CityblockEficiência de Recup.
61,97CA + MVE da CA
67

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	52,93	21,39	-	0,05	-	-	6,88	-	-	18,75	-	-
Classe 2	25,34	32,28	2,09	12,09	-	-	5,40	-	4,60	-	-	18,20
Classe 3	-	1,86	42,97	-	-	-	-	37,99	9,50	-	7,68	-
Classe 4	-	11,88	-	34,67	-	-	16,75	-	0,45	-	-	36,25
Classe 5	-	-	-	-	58,51	37,68	-	3,81	-	-	-	-
Classe 6	-	-	-	-	52,37	42,13	-	5,50	-	-	-	-
Classe 7	2,70	3,46	-	16,38	-	-	77,46	-	-	-	-	-
Classe 8	-	-	18,37	-	8,85	8,13	-	64,36	-	-	0,29	-
Classe 9	-	3,86	2,92	2,99	-	-	-	-	90,23	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	13,80	-	-	-	-	5,29	-	-	80,91	-
Classe 12	-	15,19	-	20,24	-	-	-	-	-	-	-	63,87

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
61,69CA + MVE da CA
67

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	88,31	0,93	-	-	-	-	-	-	-	10,76	-	-
Classe 2	24,08	50,44	6,13	0,02	-	-	-	-	0,62	2,35	-	16,36
Classe 3	-	0,40	99,60	-	-	-	-	-	-	-	-	-
Classe 4	1,80	-	-	98,20	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	88,33	8,78	-	2,89	-	-	-	-
Classe 6	-	-	-	-	6,40	91,00	-	2,60	-	-	-	-
Classe 7	-	-	-	-	-	-	98,66	-	-	-	-	-
Classe 8	-	-	-	-	1,13	6,01	-	92,13	-	-	0,73	-
Classe 9	-	0,14	0,03	12,04	-	-	-	-	87,79	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	1,16	-	-	-	-	-	-	-	-	-	97,90

Decomp. WAVELET
Distância CityblockEficiência de Recup.
91,03CA + MVE da CA
67

UNIFORMIZADO

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	89,01	1,12	-	-	-	-	-	-	-	9,87	-	-
Classe 2	23,67	49,67	5,63	0,03	-	-	-	-	0,59	2,83	-	17,58
Classe 3	-	0,54	99,46	-	-	-	-	-	-	-	-	-
Classe 4	1,38	-	-	98,62	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	87,11	9,04	-	3,85	-	-	-	-
Classe 6	-	-	-	-	7,40	90,49	-	2,11	-	-	-	-
Classe 7	-	-	-	-	-	-	97,72	-	-	2,28	-	-
Classe 8	-	-	-	-	0,79	2,17	-	96,63	-	-	0,41	-
Classe 9	-	0,36	-	11,51	-	-	-	-	88,13	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	4,36	-	-	-	-	-	-	-	-	-	94,76

Decomp. WAVELET
Distância CityblockEficiência de Recup.
90,97CA + MVE da CA
67

NORMALIZADO

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	56,22	11,10	-	-	-	-	13,64	-	-	19,04	-	-
Classe 2	11,73	29,41	0,03	12,92	-	-	15,80	-	6,35	-	0,38	23,38
Classe 3	-	0,09	33,67	-	0,82	-	-	28,89	2,47	-	34,06	-
Classe 4	0,22	18,00	-	46,26	-	-	6,59	-	3,18	-	-	25,75
Classe 5	-	-	1,07	-	62,37	22,21	-	14,35	-	-	-	-
Classe 6	-	-	-	-	29,78	64,35	-	5,87	-	-	-	-
Classe 7	16,40	21,15	-	2,54	-	-	59,91	-	-	-	-	-
Classe 8	-	-	14,85	-	13,36	4,37	-	49,08	-	-	18,34	-
Classe 9	-	6,14	3,30	1,01	-	-	-	0,37	79,82	-	9,36	-
Classe 10	0,02	-	-	-	-	-	-	-	-	99,98	-	-
Classe 11	-	0,38	26,96	-	-	-	-	31,52	7,63	-	33,51	-
Classe 12	-	25,57	-	15,08	-	-	-	-	-	-	-	58,76

Decomp. WAVELET
Distância CityblockEficiência de Recup.
56,11CA + MVE da CA
19

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	56,21	11,10	-	-	-	-	13,64	-	-	19,05	-	-
Classe 2	11,73	29,41	0,03	12,93	-	-	15,80	-	6,35	-	0,38	23,37
Classe 3	-	0,09	33,54	-	0,84	-	-	28,90	2,46	-	34,17	-
Classe 4	0,22	18,04	-	46,19	-	-	6,59	-	3,16	-	-	25,80
Classe 5	-	-	1,07	-	62,36	22,22	-	14,35	-	-	-	-
Classe 6	-	-	-	-	29,78	64,35	-	5,87	-	-	-	-
Classe 7	16,40	21,16	-	2,54	-	-	59,90	-	-	-	-	-
Classe 8	-	-	15,07	-	13,36	4,37	-	48,81	-	-	18,39	-
Classe 9	-	6,14	3,29	1,01	-	-	-	0,38	79,76	-	9,42	-
Classe 10	0,02	-	-	-	-	-	-	-	-	99,98	-	-
Classe 11	-	0,38	27,20	-	-	-	-	31,46	7,66	-	33,30	-
Classe 12	-	25,56	-	15,11	-	-	-	-	-	-	-	58,74

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
56,05CA + MVE da CA
19

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	81,85	6,34	-	-	-	-	1,07	-	-	10,74	-	-
Classe 2	14,25	47,08	5,69	-	-	-	11,68	-	1,13	-	-	20,17
Classe 3	-	1,68	95,20	-	-	-	-	-	1,08	-	-	2,04
Classe 4	-	-	-	94,28	-	-	5,72	-	-	-	-	-
Classe 5	-	-	-	-	82,13	8,36	-	9,47	-	-	0,04	-
Classe 6	-	-	-	-	6,50	87,66	-	5,65	-	-	0,19	-
Classe 7	0,83	0,22	-	-	-	-	98,95	-	-	-	-	-
Classe 8	-	-	-	-	13,95	8,16	-	77,35	-	-	0,54	-
Classe 9	-	0,47	1,72	11,65	-	-	-	-	86,16	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,01	-	0,02	-	-	99,97	-
Classe 12	-	2,34	0,51	-	-	-	-	-	-	-	-	96,15

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,23CA + MVE da CA
19

UNIFORMIZADO

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia da CA do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	81,60	7,08	-	-	-	-	0,88	-	-	10,44	-	-
Classe 2	16,18	46,62	5,73	-	-	-	10,21	-	1,07	-	-	20,19
Classe 3	-	1,93	95,34	-	-	-	-	-	0,64	-	-	2,09
Classe 4	0,69	-	-	95,08	-	-	4,23	-	-	-	-	-
Classe 5	-	-	-	-	80,88	8,50	-	10,56	-	-	0,06	-
Classe 6	-	-	-	-	7,04	88,09	-	4,60	-	-	0,27	-
Classe 7	0,80	0,54	-	-	-	-	98,66	-	-	-	-	-
Classe 8	-	-	-	-	12,48	6,34	-	80,47	-	-	0,71	-
Classe 9	-	0,47	1,34	11,14	-	-	-	-	87,05	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,01	-	0,03	-	-	99,96	-
Classe 12	-	2,34	0,45	-	-	-	-	-	-	-	-	96,25

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,50CA + MVE da CA
19

NORMALIZADO

	WAVELET - 2 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	67,97	0,54	-	-	-	-	-	-	-	31,49	-	-
Classe 2	16,12	63,69	2,72	0,13	-	-	-	-	0,69	11,13	-	5,52
Classe 3	-	0,56	95,40	0,91	-	-	-	-	3,13	-	-	-
Classe 4	1,42	-	-	98,58	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	90,15	7,30	-	2,55	-	-	-	-
Classe 6	-	-	-	-	10,55	84,03	-	5,42	-	-	-	-
Classe 7	-	-	-	-	-	-	96,46	-	-	3,54	-	-
Classe 8	-	-	-	-	5,98	7,34	-	83,47	-	-	3,21	-
Classe 9	-	-	-	13,64	-	-	-	-	86,36	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,24	-	-	99,76	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,74CA + MVE (ca,ch,cv,cd)
16.396MELHOR
RESULTADO

	WAVELET - 2 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	49,95	25,83	-	3,13	-	-	8,08	-	-	13,01	-	-
Classe 2	26,34	36,64	2,36	19,36	-	-	5,35	1,35	4,28	-	-	4,32
Classe 3	-	2,03	46,72	-	-	-	-	35,90	1,69	-	13,66	-
Classe 4	3,03	10,67	-	42,03	-	-	25,92	-	12,33	-	-	6,02
Classe 5	-	-	-	-	69,69	30,17	-	0,14	-	-	-	-
Classe 6	-	-	-	-	43,95	41,83	-	7,91	-	-	6,31	-
Classe 7	4,43	0,66	-	16,86	-	-	78,05	-	-	-	-	-
Classe 8	-	-	16,59	-	2,07	10,54	-	66,82	-	-	3,98	-
Classe 9	-	2,13	-	5,97	-	-	-	-	63,79	-	-	28,11
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	3,79	-	-	2,81	-	1,81	-	-	91,59	-
Classe 12	-	3,66	-	0,76	-	-	-	-	29,70	-	-	65,24

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
62,70CA + MVE (ca,ch,cv,cd)
16.396MELHOR
RESULTADO

	WAVELET - 2 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,42	0,18	-	-	-	-	-	-	-	34,40	-	-
Classe 2	14,21	65,08	2,40	0,05	-	-	-	-	0,81	15,68	-	1,77
Classe 3	-	-	97,65	-	-	-	-	-	-	-	-	-
Classe 4	1,56	-	-	97,38	-	-	-	-	-	1,06	-	-
Classe 5	-	-	-	-	90,50	5,99	-	3,51	-	-	-	-
Classe 6	-	-	-	-	5,56	89,35	-	5,09	-	-	-	-
Classe 7	-	-	-	-	-	-	78,11	-	-	21,89	-	-
Classe 8	-	-	-	-	1,43	3,91	-	93,53	-	-	1,13	-
Classe 9	-	0,12	-	12,91	-	-	-	-	86,97	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,06	-	-	98,94	-
Classe 12	-	2,51	-	-	-	-	-	-	-	-	-	96,51

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,29CA + MVE (ca,ch,cv,cd)
16.396MELHOR
RESULTADO
UNIFORMIZADO

	WAVELET - 2 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	66,02	0,22	-	-	-	-	-	-	-	33,76	-	-
Classe 2	14,24	63,76	2,00	0,01	-	-	-	-	0,85	15,38	-	3,76
Classe 3	-	0,26	97,70	2,04	-	-	-	-	-	-	-	-
Classe 4	1,26	-	-	97,86	-	-	-	-	-	0,88	-	-
Classe 5	-	-	-	-	88,72	5,89	-	5,39	-	-	-	-
Classe 6	-	-	-	-	6,17	89,61	-	4,22	-	-	-	-
Classe 7	-	-	-	-	-	-	72,30	-	-	27,70	-	-
Classe 8	-	-	-	-	0,77	0,41	-	98,66	-	-	0,16	-
Classe 9	-	-	-	12,19	-	-	-	-	87,81	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,51	-	-	98,49	-
Classe 12	-	4,88	-	-	-	-	-	-	-	-	-	94,22

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
87,93

CA + MVE (ca,ch,cv,cd)
16,396

MELHOR
RESULTADO
NORMALIZADO

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,77	5,80	-	3,92	-	-	3,48	-	-	21,03	-	-
Classe 2	25,66	45,21	2,95	5,62	-	-	1,62	-	4,52	-	-	14,42
Classe 3	-	1,45	89,94	-	-	-	-	-	8,61	-	-	-
Classe 4	0,43	-	-	87,17	-	-	8,06	-	4,34	-	-	-
Classe 5	-	-	-	-	88,48	11,18	-	0,34	-	-	-	-
Classe 6	-	-	-	-	26,69	64,41	-	7,77	-	-	1,13	-
Classe 7	-	-	-	0,12	-	-	99,88	-	-	-	-	-
Classe 8	-	-	-	-	3,84	11,39	-	68,34	-	-	16,43	-
Classe 9	-	-	-	9,91	-	-	-	-	90,09	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,03	-	0,02	-	-	99,95	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
83,19

CA + MVE (ca,ch,cv,cd)
4,108

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	49,93	26,25	-	2,77	-	-	8,40	-	-	12,65	-	-
Classe 2	26,54	36,50	2,80	19,23	-	-	5,46	1,35	4,22	-	-	3,90
Classe 3	-	2,41	41,73	-	-	-	-	40,06	4,32	-	11,35	0,13
Classe 4	2,91	12,07	-	37,35	-	-	25,21	-	7,74	-	-	14,72
Classe 5	-	-	-	-	70,06	29,82	-	0,12	-	-	-	-
Classe 6	-	-	-	-	45,26	41,32	-	8,17	-	-	5,25	-
Classe 7	6,32	1,05	-	19,56	-	2,38	11,18	73,07	-	-	-	-
Classe 8	-	-	16,59	-	-	-	-	66,82	-	-	3,03	-
Classe 9	-	2,99	-	1,67	-	-	-	-	50,91	-	-	44,43
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	4,74	-	-	2,04	-	0,95	-	-	92,27	-
Classe 12	-	4,00	-	5,68	-	-	-	-	36,50	-	-	53,23

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
59,43

CA + MVE (ca,ch,cv,cd)
4,108

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	69,86	0,19	-	-	-	-	-	-	-	29,95	-	-
Classe 2	15,23	64,06	2,94	0,03	-	-	-	-	0,83	13,80	-	3,11
Classe 3	-	0,09	98,83	1,08	-	-	-	-	-	-	-	-
Classe 4	1,84	-	-	97,56	-	-	-	-	-	0,60	-	-
Classe 5	-	-	-	-	90,49	6,04	-	3,47	-	-	-	-
Classe 6	-	-	-	-	5,59	89,74	-	4,67	-	-	-	-
Classe 7	-	-	-	-	-	-	81,77	-	-	18,23	-	-
Classe 8	-	-	-	-	1,20	3,26	-	94,58	-	-	0,96	-
Classe 9	-	0,11	-	12,40	-	-	-	-	87,49	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,84	-	-	99,16	-
Classe 12	-	2,19	-	-	-	-	-	-	-	-	-	96,83

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
89,20

CA + MVE (ca,ch,cv,cd)
4,108

UNIFORMIZADO

	WAVELET - 3 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	69,84	0,23	-	-	-	-	-	-	-	29,93	-	-
Classe 2	15,31	63,50	2,15	0,01	-	-	-	-	0,85	13,83	-	4,35
Classe 3	-	0,56	98,78	0,66	-	-	-	-	-	-	-	-
Classe 4	1,25	-	-	98,00	-	-	-	-	-	0,75	-	-
Classe 5	-	-	-	-	88,72	6,09	-	5,19	-	-	-	-
Classe 6	-	-	-	-	6,36	89,99	-	3,65	-	-	-	-
Classe 7	-	-	-	-	-	-	75,62	-	-	24,38	-	-
Classe 8	-	-	-	-	0,65	0,40	-	98,76	-	-	0,19	-
Classe 9	-	-	-	12,05	-	-	-	-	87,95	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,38	-	-	98,62	-
Classe 12	-	4,72	-	-	-	-	-	-	-	-	-	94,38

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
88,68

CA + MVE (ca,ch,cv,cd)
4,108

NORMALIZADO

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 4o. Nível												Decomp. WAVELET
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Cityblock
Classe1	52,15	22,28	-	3,03	-	-	7,39	-	-	15,15	-	-	
Classe 2	26,00	39,04	3,21	17,92	-	-	4,62	-	4,32	-	-	4,89	Eficiência de Recup.
Classe 3	-	3,01	70,05	-	-	-	-	11,55	11,32	-	4,07	-	72,76
Classe 4	0,65	5,26	-	56,57	-	-	19,68	-	12,37	-	-	5,47	CA + MVE (ca,ch,cv,cd)
Classe 5	-	-	-	-	76,81	23,10	-	0,09	-	-	-	-	1.036
Classe 6	-	-	-	-	42,92	45,76	-	8,32	-	-	3,00	-	
Classe 7	0,45	0,03	-	10,32	-	-	89,20	-	-	-	-	-	
Classe 8	-	-	16,59	-	3,27	12,24	-	66,82	-	-	1,08	-	
Classe 9	-	0,16	0,01	12,29	-	-	-	-	86,64	-	-	0,90	
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	-	-	-	0,66	-	0,02	-	-	99,32	-	
Classe 12	-	0,45	-	5,87	-	-	-	-	2,15	-	-	90,74	

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 4o. Nível												Decomp. WAVELET
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Euclidiana
Classe1	50,24	25,14	-	2,44	-	-	8,57	-	-	13,61	-	-	
Classe 2	26,00	36,97	3,05	18,80	-	-	6,28	1,14	3,02	-	-	4,74	Eficiência de Recup.
Classe 3	-	2,55	40,47	-	-	-	-	40,34	8,68	-	7,96	-	61,64
Classe 4	1,05	12,16	-	37,62	-	-	23,08	-	2,35	-	-	23,74	CA + MVE (ca,ch,cv,cd)
Classe 5	-	-	-	-	72,87	27,01	-	0,12	-	-	-	-	1.036
Classe 6	-	-	-	-	45,34	42,19	-	8,59	-	-	3,88	-	
Classe 7	3,80	0,94	-	21,69	-	-	73,57	-	-	-	-	-	
Classe 8	-	-	16,59	-	3,01	12,13	-	66,82	-	-	1,45	-	
Classe 9	-	0,95	0,36	1,62	-	-	-	-	62,97	-	-	34,10	
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	4,15	-	-	1,22	-	0,15	-	-	94,48	-	
Classe 12	-	3,55	-	13,90	-	-	-	-	20,49	-	-	61,48	

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 4o. Nível												Decomp. WAVELET
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Cityblock
Classe1	77,82	0,26	-	-	-	-	-	-	-	21,92	-	-	
Classe 2	17,89	63,41	3,34	0,07	-	-	-	-	0,81	10,26	-	4,22	Eficiência de Recup.
Classe 3	-	0,37	99,55	0,08	-	-	-	-	-	-	-	-	90,80
Classe 4	2,10	-	-	97,82	-	-	-	-	-	0,08	-	-	CA + MVE (ca,ch,cv,cd)
Classe 5	-	-	-	-	90,21	6,55	-	3,24	-	-	-	-	1.036
Classe 6	-	-	-	-	5,63	91,04	-	3,33	-	-	-	-	
Classe 7	-	-	-	-	-	-	89,73	-	-	10,27	-	-	
Classe 8	-	-	-	-	0,90	2,99	-	95,25	-	-	0,86	-	UNIFORMIZADO
Classe 9	-	0,13	-	12,09	-	-	-	-	87,78	-	-	-	
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	-	-	-	-	-	0,54	-	-	99,46	-	
Classe 12	-	1,50	-	-	-	-	-	-	-	-	-	97,53	

	WAVELET - 4 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 4o. Nível												Decomp. WAVELET
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Cityblock
Classe1	77,02	0,35	-	-	-	-	-	-	-	22,63	-	-	
Classe 2	17,69	61,74	2,47	0,04	-	-	-	-	0,82	10,72	-	6,52	Eficiência de Recup.
Classe 3	-	0,54	99,38	0,08	-	-	-	-	-	-	-	-	90,09
Classe 4	1,15	-	-	98,44	-	-	-	-	-	0,41	-	-	CA + MVE (ca,ch,cv,cd)
Classe 5	-	-	-	-	88,55	6,86	-	4,59	-	-	-	-	1.036
Classe 6	-	-	-	-	6,43	91,16	-	2,41	-	-	-	-	
Classe 7	-	-	-	-	-	-	84,16	-	-	15,84	-	-	
Classe 8	-	-	-	-	0,52	0,41	-	98,81	-	-	0,26	-	NORMALIZADO
Classe 9	-	-	-	12,04	-	-	-	-	87,96	-	-	-	
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	-	-	-	-	-	1,06	-	-	98,94	-	
Classe 12	-	4,13	-	-	-	-	-	-	-	-	-	94,97	

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 5o. Nível												Decomp. WAVELET
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12	Distância Cityblock
Classe1	50,32	22,74	-	1,44	-	-	9,04	-	-	16,46	-	-	
Classe 2	25,68	37,15	3,15	19,44	-	-	6,78	0,06	3,30	-	-	4,44	Eficiência de Recup.
Classe 3	-	2,38	45,79	-	-	-	-	34,77	11,03	-	6,03	-	67,76
Classe 4	0,24	9,82	-	45,99	-	-	19,19	-	1,02	-	-	23,74	CA + MVE (ca,ch,cv,cd)
Classe 5	-	-	-	-	74,86	25,07	-	0,07	-	-	-	-	268
Classe 6	-	-	-	-	45,29	45,21	-	8,44	-	-	1,06	-	
Classe 7	1,76	0,48	-	16,57	-	-	81,19	-	-	-	-	-	
Classe 8	-	-	16,59	-	4,31	12,10	-	66,80	-	-	0,20	-	
Classe 9	-	1,13	0,68	8,86	-	-	-	-	87,04	-	-	2,29	
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-	
Classe 11	-	-	2,82	-	-	0,11	-	0,03	-	-	97,04	-	
Classe 12	-	-	-	17,35	-	-	-	-	0,03	-	-	81,69	

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	48,67	22,55	-	1,11	-	-	10,26	-	-	17,41	-	-
Classe 2	25,66	36,32	2,91	18,89	-	-	7,11	0,36	3,30	-	-	5,45
Classe 3	-	2,39	39,58	-	-	-	-	40,79	11,59	-	5,65	-
Classe 4	0,38	10,86	-	37,82	-	-	20,13	-	0,78	-	-	30,03
Classe 5	-	-	-	-	73,71	26,06	-	0,23	-	-	-	-
Classe 6	-	-	-	-	47,83	42,33	-	8,50	-	-	1,34	-
Classe 7	3,92	1,15	-	18,21	-	-	76,72	-	-	-	-	-
Classe 8	-	-	16,59	-	4,59	11,84	-	66,78	-	-	0,20	-
Classe 9	-	1,43	2,85	7,67	-	-	-	-	79,91	-	-	8,14
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	4,92	-	-	0,29	-	0,02	-	-	94,77	-
Classe 12	-	-	-	21,13	-	-	-	-	0,14	-	-	77,88

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
64,54

CA + MVE (ca,ch,cv,cd)
268

	Transformada Wavelet - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	83,28	0,53	-	-	-	-	-	-	-	16,19	-	-
Classe 2	22,24	58,44	4,77	0,13	-	-	-	-	0,86	5,02	-	8,54
Classe 3	-	0,44	99,56	-	-	-	-	-	-	-	-	-
Classe 4	1,83	-	-	98,17	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	89,30	7,81	-	2,89	-	-	-	-
Classe 6	-	-	-	-	5,96	91,68	-	2,36	-	-	-	-
Classe 7	0,05	-	-	-	-	-	97,57	-	-	2,38	-	-
Classe 8	-	-	-	-	0,72	3,91	-	94,37	-	-	1,00	-
Classe 9	-	0,08	-	12,01	-	-	0,03	-	87,88	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,16	-	-	99,84	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
91,59

CA + MVE (ca,ch,cv,cd)
268

MELHOR
RESULTADO
UNIFORMIZADO

	WAVELET - 5 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	82,61	0,62	-	-	-	-	-	-	-	16,77	-	-
Classe 2	21,51	58,25	3,50	0,08	-	-	-	-	0,86	5,60	-	10,20
Classe 3	-	0,74	99,23	0,03	-	-	-	-	-	-	-	-
Classe 4	1,48	-	-	98,52	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	88,10	8,08	-	3,82	-	-	-	-
Classe 6	-	-	-	-	6,59	91,59	-	1,82	-	-	-	-
Classe 7	0,25	-	-	-	-	-	95,58	-	-	4,17	-	-
Classe 8	-	-	-	-	0,22	0,54	-	98,83	-	-	0,41	-
Classe 9	-	0,04	-	11,80	-	-	0,18	-	87,98	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,38	-	-	99,62	-
Classe 12	-	0,62	-	-	-	-	-	-	-	-	-	98,38

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
91,56

CA + MVE (ca,ch,cv,cd)
268

NORMALIZADO

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	52,80	23,71	-	1,00	-	-	3,62	-	-	18,87	-	-
Classe 2	25,41	35,37	2,38	19,93	-	-	5,21	-	4,13	-	-	7,57
Classe 3	-	1,78	53,80	-	-	-	-	26,28	11,33	-	6,81	-
Classe 4	-	13,95	-	47,91	-	-	14,08	-	0,34	-	-	23,72
Classe 5	-	-	-	-	69,57	27,05	-	3,38	-	-	-	-
Classe 6	-	-	-	-	41,89	51,24	-	6,87	-	-	-	-
Classe 7	1,75	1,42	-	16,73	-	-	80,10	-	-	-	-	-
Classe 8	-	-	16,59	-	7,07	9,67	-	66,55	-	-	0,12	-
Classe 9	-	0,54	1,63	2,26	-	-	-	-	95,57	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	8,92	-	-	-	-	0,23	-	-	90,85	-
Classe 12	-	3,63	-	18,71	-	-	-	-	-	-	-	76,91

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
68,39

CA + MVE (ca,ch,cv,cd)
76

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	52,60	21,87	-	0,93	-	-	5,19	-	-	19,41	-	-
Classe 2	25,17	34,05	2,36	18,03	-	-	6,28	-	4,27	-	-	9,84
Classe 3	-	1,85	47,83	-	-	-	-	32,59	10,42	-	7,31	-
Classe 4	-	12,86	-	42,64	-	-	16,35	-	0,38	-	-	27,77
Classe 5	-	-	-	-	65,12	30,90	-	3,98	-	-	-	-
Classe 6	-	-	-	-	46,84	46,74	-	6,42	-	-	-	-
Classe 7	1,90	2,18	-	16,49	-	-	79,43	-	-	-	-	-
Classe 8	-	-	16,59	-	8,26	8,60	-	66,46	-	-	0,09	-
Classe 9	-	1,43	2,67	2,88	-	-	-	-	93,02	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	11,89	-	-	-	-	3,02	-	-	85,09	-
Classe 12	-	2,37	-	19,20	-	-	-	-	-	-	-	77,64

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
65,89

CA + MVE (ca,ch,cv,cd)
76

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	85,21	1,22	-	-	-	-	-	-	-	13,57	-	-
Classe 2	25,67	53,20	7,15	0,04	-	-	-	-	0,86	0,34	-	12,74
Classe 3	-	0,91	99,09	-	-	-	-	-	-	-	-	-
Classe 4	0,56	-	-	99,44	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	88,62	9,28	-	2,10	-	-	-	-
Classe 6	-	-	-	-	6,83	89,63	-	3,54	-	-	-	-
Classe 7	0,52	-	-	-	-	-	99,46	-	-	0,02	-	-
Classe 8	-	-	-	-	1,13	6,57	-	90,92	-	-	1,38	-
Classe 9	-	0,12	-	12,02	-	-	-	-	87,86	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,03	-	-	99,97	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
91,03

CA + MVE (ca,ch,cv,cd)
76

UNIFORMIZADO

	WAVELET - 6 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	84,44	1,57	-	-	-	-	-	-	-	13,99	-	-
Classe 2	25,19	52,72	6,55	0,03	-	-	-	-	0,86	0,96	-	13,69
Classe 3	-	1,41	98,42	0,17	-	-	-	-	-	-	-	-
Classe 4	0,50	-	-	99,50	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	88,40	9,42	-	2,18	-	-	-	-
Classe 6	-	-	-	-	7,52	89,25	-	3,23	-	-	-	-
Classe 7	0,42	-	-	-	-	-	99,03	-	-	0,55	-	-
Classe 8	-	-	-	-	0,66	2,49	-	95,97	-	-	0,88	-
Classe 9	-	0,13	-	11,02	-	-	-	-	88,85	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,12	-	-	99,88	-
Classe 12	-	1,89	-	-	-	-	-	-	-	-	-	97,20

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
91,14

CA + MVE (ca,ch,cv,cd)
76

NORMALIZADO

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	55,30	15,12	-	-	-	-	4,87	-	-	24,71	-	-
Classe 2	25,48	41,17	0,55	9,85	-	-	0,02	-	5,47	-	0,03	17,43
Classe 3	-	0,39	76,00	-	-	-	-	13,37	7,44	-	2,80	-
Classe 4	-	13,46	-	56,87	-	-	4,78	-	4,82	-	-	20,07
Classe 5	-	-	-	-	83,06	13,37	-	3,57	-	-	-	-
Classe 6	-	-	-	-	18,80	74,18	-	7,02	-	-	-	-
Classe 7	9,83	0,41	-	-	-	-	86,80	-	-	-	-	2,96
Classe 8	-	-	12,83	-	8,07	8,58	-	66,43	-	-	4,09	-
Classe 9	-	0,10	4,06	4,73	-	-	-	-	91,11	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	2,01	-	-	-	-	10,66	-	-	87,33	-
Classe 12	-	11,14	-	7,41	-	-	2,21	-	-	-	-	78,55

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
74,73

CA + MVE (ca,ch,cv,cd)
28

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	55,66	15,78	-	-	-	-	5,54	-	-	23,02	-	-
Classe 2	25,36	37,05	1,04	12,02	-	-	0,14	-	4,77	-	0,24	19,38
Classe 3	-	0,48	67,43	-	-	-	-	20,98	6,62	-	4,49	-
Classe 4	-	18,44	-	53,77	-	-	7,53	-	2,79	-	-	17,47
Classe 5	-	-	-	-	82,50	14,67	-	2,83	-	-	-	-
Classe 6	-	-	-	-	20,43	72,52	-	7,05	-	-	-	-
Classe 7	9,42	0,94	-	0,01	-	-	89,09	-	-	-	-	0,54
Classe 8	-	-	12,63	-	7,50	9,32	-	66,54	-	-	4,01	-
Classe 9	-	-	3,89	3,06	-	-	-	-	93,05	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	3,15	-	-	-	-	11,18	-	-	85,67	-
Classe 12	-	11,05	-	4,82	-	-	0,28	-	-	-	-	83,02

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
73,86

CA + MVE (ca,ch,cv,cd)
28

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,26	7,83	-	-	-	-	0,35	-	-	15,56	-	-
Classe 2	25,69	48,38	5,28	-	-	-	-	-	1,44	-	-	19,21
Classe 3	-	1,39	92,69	1,81	-	-	-	-	2,12	-	-	1,99
Classe 4	-	-	-	96,53	-	-	3,47	-	-	-	-	-
Classe 5	-	-	-	-	88,39	9,52	-	2,00	-	-	0,09	-
Classe 6	-	-	-	-	8,12	83,31	-	6,23	-	-	2,34	-
Classe 7	-	-	-	-	-	-	100,00	-	-	-	-	-
Classe 8	-	-	-	-	4,17	7,87	-	83,03	-	-	4,93	-
Classe 9	-	0,37	0,59	10,74	-	-	-	-	88,30	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,74	-	0,86	-	-	98,40	-
Classe 12	-	15,84	0,44	-	-	-	-	-	-	-	-	82,80

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
86,51

CA + MVE (ca,ch,cv,cd)
28

UNIFORMIZADO

	WAVELET - 7 Níveis de Dec. - Coeficientes de Aproximação + Média, Variância e Energia do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	74,34	8,52	-	-	-	-	0,80	-	-	16,34	-	-
Classe 2	24,90	48,19	4,32	0,24	-	-	0,20	-	2,51	1,06	-	18,58
Classe 3	-	1,43	90,92	3,08	-	-	-	-	1,85	-	-	2,72
Classe 4	0,07	-	-	97,87	-	-	2,06	-	-	-	-	-
Classe 5	-	-	-	-	87,83	9,40	-	2,59	-	-	0,18	-
Classe 6	-	-	-	-	9,00	79,94	-	5,76	-	-	5,30	-
Classe 7	0,11	-	-	-	-	-	99,89	-	-	-	-	-
Classe 8	-	-	-	-	4,34	6,36	-	84,33	-	-	4,97	-
Classe 9	-	1,22	0,03	9,45	-	-	-	-	89,30	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	1,28	-	1,20	-	-	97,52	-
Classe 12	-	20,27	8,60	-	-	-	-	-	1,03	-	-	69,46

Decomp. WAVELET
Distância CityblockEficiência de Recup.
84,97CA + MVE (ca,ch,cv,cd)
28

NORMALIZADO

	WAVELET - 2 Níveis de Dec. - Média, Variância e Energia do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	50,53	26,37	-	3,11	-	-	7,92	-	-	12,07	-	-
Classe 2	26,31	36,71	1,95	19,78	-	-	4,83	1,62	4,22	-	-	4,58
Classe 3	-	1,62	44,53	-	-	-	-	38,34	0,40	-	15,11	-
Classe 4	3,24	10,83	-	41,10	-	-	25,73	-	9,62	-	-	9,48
Classe 5	-	-	-	-	69,66	30,23	-	0,11	-	-	-	-
Classe 6	-	-	-	-	44,36	42,27	-	7,74	-	-	5,63	-
Classe 7	5,40	0,83	-	16,51	-	-	77,26	-	-	-	-	-
Classe 8	-	-	16,59	-	2,38	10,50	-	66,81	-	-	3,72	-
Classe 9	-	2,91	-	1,59	-	-	-	-	54,91	-	-	40,59
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	5,76	-	-	2,77	-	1,72	-	-	89,75	-
Classe 12	-	3,73	-	1,49	-	-	-	-	40,45	-	-	53,69

Decomp. WAVELET
Distância CyblockEficiência de Recup.
60,60MVE (ca,ch,cv,cd)
12

img 128 x 128

	WAVELET - 2 Níveis de Dec. - Média, Variância e Energia do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	49,75	26,25	-	2,88	-	-	8,49	-	-	12,63	-	-
Classe 2	26,36	36,04	2,24	19,47	-	-	5,84	1,53	4,22	-	-	4,30
Classe 3	-	1,62	39,71	-	-	-	-	43,00	0,58	-	15,09	-
Classe 4	3,21	11,89	-	36,39	-	-	28,34	-	8,79	-	-	11,38
Classe 5	-	-	-	-	68,60	31,26	-	0,14	-	-	-	-
Classe 6	-	-	-	-	44,70	41,04	-	7,86	-	-	6,40	-
Classe 7	7,06	1,51	-	20,29	-	-	71,14	-	-	-	-	-
Classe 8	-	-	16,59	-	2,05	10,54	-	66,82	-	-	4,00	-
Classe 9	-	3,82	-	1,82	-	-	-	-	49,34	-	-	45,02
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	7,77	-	-	2,89	-	1,89	-	-	87,45	-
Classe 12	-	3,74	-	2,36	-	-	-	-	42,22	-	-	51,06

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
58,11MVE (ca,ch,cv,cd)
12

	WAVELET - 2 Níveis de Dec. - Média, Variância e Energia do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	64,09	26,31	-	6,20	-	-	-	-	-	3,40	-	-
Classe 2	19,50	43,51	0,01	8,44	-	-	-	-	24,28	-	-	4,26
Classe 3	-	1,52	69,84	-	8,36	-	4,08	1,72	0,04	-	14,44	-
Classe 4	0,13	5,92	-	93,69	-	-	-	-	0,26	-	-	-
Classe 5	-	-	-	-	82,10	17,14	-	0,48	-	-	0,28	-
Classe 6	-	-	-	-	21,98	71,43	-	1,94	-	-	4,65	-
Classe 7	-	0,04	-	0,02	-	-	99,91	-	0,03	-	-	-
Classe 8	-	-	-	-	6,15	7,25	-	70,08	11,77	-	4,75	-
Classe 9	-	10,94	-	1,08	-	-	-	-	79,02	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,10	-	10,99	19,94	-	7,21	-	-	61,76	-
Classe 12	-	0,35	-	-	-	-	-	-	5,46	-	-	93,21

Decomp. WAVELET
Distância CityblockEficiência de Recup.
77,39MVE (ca,ch,cv,cd)
12

UNIFORMIZADO

	WAVELET - 2 Níveis de Dec. - Média, Variância e Energia do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	60,47	24,41	-	12,26	-	-	-	-	-	2,86	-	-
Classe 2	17,54	48,71	0,01	10,53	-	-	0,02	-	17,93	-	-	5,26
Classe 3	-	0,99	62,05	-	12,13	0,09	2,09	2,15	-	-	20,48	0,02
Classe 4	1,06	6,87	-	91,23	-	-	-	-	0,84	-	-	-
Classe 5	-	-	-	-	78,60	20,62	-	0,37	-	-	0,41	-
Classe 6	-	-	-	-	21,25	71,65	-	1,93	-	-	5,17	-
Classe 7	-	0,36	-	0,05	-	-	98,60	-	0,99	-	-	-
Classe 8	-	0,14	-	-	6,30	6,28	0,05	69,65	13,11	-	4,47	-
Classe 9	-	9,74	-	8,72	-	-	0,05	0,04	76,55	-	-	4,90
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	1,75	-	18,57	20,20	-	6,09	-	-	53,39	-
Classe 12	-	0,06	-	-	-	-	-	-	0,44	-	-	98,50

Decomp. WAVELET
Distância CityblockEficiência de Recup.
##MVE (ca,ch,cv,cd)
12

NORMALIZADO

WAVELET - 3 Níveis de Dec. - Média, Variância e Energia do 3o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	50,55	26,36	-	3,13	-	-	7,42	-	-	12,54	-	-
Classe 2	26,53	36,93	2,46	19,85	-	-	4,40	1,53	4,08	-	-	4,22
Classe 3	-	2,36	45,87	-	-	-	-	35,84	3,53	-	12,10	0,30
Classe 4	2,80	11,49	-	41,83	-	-	22,08	-	7,68	-	-	14,12
Classe 5	-	-	-	-	70,08	29,80	-	0,12	-	-	-	-
Classe 6	-	-	-	-	45,24	41,69	-	8,09	-	-	4,98	-
Classe 7	3,66	0,72	-	15,62	-	-	80,00	-	-	-	-	-
Classe 8	-	-	16,59	-	2,60	11,06	-	66,82	-	-	2,93	-
Classe 9	-	2,69	-	1,22	-	-	-	-	53,71	-	-	42,38
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	3,52	-	-	1,96	-	0,59	-	-	93,93	-
Classe 12	-	3,73	-	4,57	-	-	-	-	35,49	-	-	55,58

Decomp. WAVELET
Distância Cyblock

Eficiência de Recup.
61,42

MVE (ca,ch,cv,cd)
12
img 64 x 64

WAVELET - 3 Níveis de Dec. - Média, Variância e Energia do 3o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	49,91	26,28	-	2,77	-	-	8,43	-	-	12,61	-	-
Classe 2	26,56	36,46	2,80	19,23	-	-	5,48	1,35	4,22	-	-	3,90
Classe 3	-	2,41	41,12	-	-	-	-	40,67	4,26	-	11,44	0,10
Classe 4	2,93	12,17	-	36,87	-	-	25,34	-	7,49	-	-	15,20
Classe 5	-	-	-	-	69,99	29,89	-	0,12	-	-	-	-
Classe 6	-	-	-	-	45,32	41,25	-	8,18	-	-	5,25	-
Classe 7	6,62	1,09	-	19,92	-	-	72,37	-	-	-	-	-
Classe 8	-	-	16,59	-	2,38	11,18	-	66,82	-	-	3,03	-
Classe 9	-	3,04	-	1,55	-	-	-	-	49,21	-	-	46,20
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	4,99	-	-	2,04	-	0,95	-	-	92,02	-
Classe 12	-	4,13	-	6,14	-	-	-	-	38,15	-	-	51,00

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
58,92

MVE (ca,ch,cv,cd)
12

WAVELET - 3 Níveis de Dec. - Média, Variância e Energia do 3o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,61	21,72	-	6,89	-	-	-	-	-	5,78	-	-
Classe 2	13,84	40,89	0,02	17,50	-	-	-	-	11,44	-	-	16,31
Classe 3	-	6,00	74,34	-	5,88	0,30	0,62	0,38	0,02	-	4,47	7,99
Classe 4	0,76	4,97	-	93,88	-	-	-	-	0,39	-	-	-
Classe 5	-	-	-	-	69,06	28,43	-	1,33	-	-	1,18	-
Classe 6	-	-	-	-	34,92	54,14	-	2,90	-	-	8,04	-
Classe 7	-	0,21	-	0,24	-	-	99,55	-	-	-	-	-
Classe 8	-	0,09	-	-	4,83	6,39	-	77,36	9,72	-	1,61	-
Classe 9	-	0,60	-	3,15	-	-	-	-	92,75	-	-	3,50
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	8,73	33,90	-	2,48	-	-	54,89	-
Classe 12	-	8,61	-	-	-	-	-	-	7,52	-	-	83,02

Decomp. WAVELET
Distância Cyblock

Eficiência de Recup.
75,46

MVE (ca,ch,cv,cd)
12

UNIFORMIZADO

WAVELET - 3 Níveis de Dec. - Média, Variância e Energia do 3o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	60,99	17,93	-	14,25	-	-	-	-	-	6,83	-	-
Classe 2	12,50	36,37	0,03	22,80	-	-	-	-	13,95	-	-	14,35
Classe 3	-	3,56	64,71	-	11,59	3,28	2,17	0,75	0,15	-	11,82	1,97
Classe 4	1,94	5,11	-	92,29	-	-	-	-	0,66	-	-	-
Classe 5	-	-	-	-	64,79	32,39	-	0,89	-	-	1,93	-
Classe 6	-	-	-	-	38,50	50,82	-	2,49	-	-	8,19	-
Classe 7	0,01	1,25	0,04	0,93	-	-	96,81	0,02	0,77	-	-	0,17
Classe 8	-	0,09	-	-	4,76	5,74	-	75,19	12,16	-	2,06	-
Classe 9	-	1,44	-	9,03	-	-	-	-	86,43	-	-	3,10
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,05	-	18,95	35,75	-	2,87	-	-	42,38	-
Classe 12	-	5,79	-	-	-	-	0,03	-	5,01	-	-	88,30

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
##

MVE (ca,ch,cv,cd)
12

NORMALIZADO

WAVELET - 4 Níveis de Dec. - Média, Variância e Energia do 4o. Nível												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	50,91	25,78	-	2,88	-	-	7,56	-	-	12,87	-	-
Classe 2	26,27	37,09	3,03	19,73	-	-	5,14	1,20	3,42	-	-	4,12
Classe 3	-	2,55	44,31	-	-	-	-	36,17	7,32	-	9,63	0,02
Classe 4	0,79	11,41	-	42,64	-	-	21,24	-	4,06	-	-	19,86
Classe 5	-	-	-	-	72,53	27,37	-	0,10	-	-	-	-
Classe 6	-	-	-	-	45,76	42,17	-	8,43	-	-	3,64	-
Classe 7	0,91	0,57	-	18,49	-	-	80,03	-	-	-	-	-
Classe 8	-	-	16,59	-	3,23	12,08	-	66,82	-	-	1,28	-
Classe 9	-	1,18	0,12	2,66	-	-	-	-	74,70	-	-	21,34
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	3,85	-	-	1,09	-	0,09	-	-	94,97	-
Classe 12	-	2,07	-	12,70	-	-	-	-	15,58	-	-	68,99

Decomp. WAVELET
Distância Cyblock

Eficiência de Recup.
64,60

MVE (ca,ch,cv,cd)
12
img 32 x 32

	WAVELET - 4 Níveis de Dec. - Média, Variância e Energia do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	50,23	25,14	-	2,45	-	-	8,57	-	-	13,61	-	-
Classe 2	26,00	36,97	3,05	18,80	-	-	6,28	1,14	3,02	-	-	4,74
Classe 3	-	2,55	40,39	-	-	-	-	40,42	8,67	-	7,97	-
Classe 4	1,05	12,20	-	37,58	-	-	23,08	-	2,34	-	-	23,75
Classe 5	-	-	-	-	72,86	27,02	-	0,12	-	-	-	-
Classe 6	-	-	-	-	45,35	42,18	-	8,59	-	-	3,88	-
Classe 7	3,80	0,94	-	21,75	-	-	73,51	-	-	-	-	-
Classe 8	-	-	16,59	-	3,01	12,13	-	66,82	-	-	1,45	-
Classe 9	-	0,95	0,36	1,61	-	-	-	62,89	-	-	-	34,19
Classe 10	-	-	-	-	-	-	-	-	100,00	-	-	-
Classe 11	-	-	4,16	-	-	1,22	-	0,15	-	94,47	-	-
Classe 12	-	3,55	-	13,93	-	-	-	-	20,54	-	-	61,40

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
61,61MVE (ca,ch,cv,cd)
12

	WAVELET - 4 Níveis de Dec. - Média, Variância e Energia do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	66,26	21,91	-	7,51	-	-	-	-	-	4,32	-	-
Classe 2	15,07	44,06	4,51	20,96	-	-	-	-	7,12	-	-	8,28
Classe 3	-	14,46	70,35	-	5,29	1,34	0,09	0,46	-	-	2,19	5,82
Classe 4	0,36	5,58	-	92,16	-	-	-	-	1,90	-	-	-
Classe 5	-	-	-	-	63,76	30,45	-	2,38	-	-	3,41	-
Classe 6	-	-	-	-	35,37	45,21	-	4,25	-	-	15,17	-
Classe 7	-	-	0,01	0,98	-	-	99,01	-	-	-	-	-
Classe 8	-	0,01	-	0,66	4,13	6,06	8,96	74,60	2,70	-	2,61	0,27
Classe 9	-	0,34	-	6,72	-	-	-	92,49	-	-	-	0,45
Classe 10	-	-	-	-	-	-	-	-	100,00	-	-	-
Classe 11	-	-	-	-	9,38	23,22	-	2,31	-	-	65,09	-
Classe 12	-	1,45	0,53	-	-	-	0,10	-	6,98	-	-	89,96

Decomp. WAVELET
Distância CyblockEficiência de Recup.
75,25MVE (ca,ch,cv,cd)
12

UNIFORMIZADO

	WAVELET - 4 Níveis de Dec. - Média, Variância e Energia do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	63,14	18,99	-	12,03	-	-	-	-	-	5,84	-	-
Classe 2	16,49	40,44	4,83	21,22	-	-	1,38	-	9,70	-	-	5,94
Classe 3	-	13,63	62,27	-	6,96	5,10	1,24	1,06	0,29	-	3,36	6,09
Classe 4	1,17	5,99	-	87,61	-	-	-	0,01	5,22	-	-	-
Classe 5	-	-	-	-	57,77	30,40	-	2,63	-	-	9,20	-
Classe 6	-	-	0,05	-	35,46	39,76	-	4,53	-	-	20,20	-
Classe 7	0,02	1,00	0,08	5,74	-	-	91,84	0,55	0,70	-	-	0,07
Classe 8	-	0,73	-	2,18	3,74	5,06	9,95	72,89	2,19	-	3,20	0,06
Classe 9	-	1,29	-	11,94	-	-	0,04	-	85,77	-	-	0,96
Classe 10	-	-	-	-	-	-	-	-	100,00	-	-	-
Classe 11	-	-	-	-	17,28	24,09	-	3,11	-	-	55,52	-
Classe 12	-	2,71	1,27	-	-	-	1,35	0,11	6,59	-	-	87,04

Decomp. WAVELET
Distância CityblockEficiência de Recup.
##MVE (ca,ch,cv,cd)
12

NORMALIZADO

	WAVELET - 5 Níveis de Dec. - Média, Variância e Energia do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	50,14	23,03	-	1,36	-	-	9,29	-	-	16,18	-	-
Classe 2	25,68	36,91	3,12	19,62	-	-	6,77	0,30	3,09	-	-	4,51
Classe 3	-	2,31	40,97	-	-	-	-	39,34	10,59	-	6,79	-
Classe 4	0,24	10,39	-	43,73	-	-	19,38	-	0,82	-	-	25,44
Classe 5	-	-	-	-	74,29	25,64	-	0,07	-	-	-	-
Classe 6	-	-	-	-	45,74	44,71	-	8,42	-	-	1,13	-
Classe 7	2,12	0,67	-	17,06	-	-	80,15	-	-	-	-	-
Classe 8	-	-	16,59	-	4,28	12,13	-	66,80	-	-	0,20	-
Classe 9	-	1,15	0,82	8,00	-	-	-	-	85,76	-	-	4,27
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	4,30	-	-	0,12	-	0,04	-	-	95,54	-
Classe 12	-	-	-	20,26	-	-	-	-	0,07	-	-	78,75

Decomp. WAVELET
Distância CyblockEficiência de Recup.
66,48MVE (ca,ch,cv,cd)
12

img 16 x 16

	WAVELET - 5 Níveis de Dec. - Média, Variância e Energia do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	48,67	22,55	-	1,11	-	-	10,26	-	-	17,41	-	-
Classe 2	25,66	36,32	2,91	18,89	-	-	7,11	0,36	3,30	-	-	5,45
Classe 3	-	2,39	39,56	-	-	-	-	40,81	11,59	-	5,65	-
Classe 4	0,38	10,86	-	37,82	-	-	20,13	-	0,78	-	-	30,03
Classe 5	-	-	-	-	73,71	26,06	-	0,23	-	-	-	-
Classe 6	-	-	-	-	47,83	42,33	-	8,50	-	-	1,34	-
Classe 7	3,92	1,15	-	18,21	-	-	76,72	-	-	-	-	-
Classe 8	-	-	16,59	-	4,59	11,84	-	66,78	-	-	0,20	-
Classe 9	-	1,43	2,85	7,67	-	-	-	-	79,91	-	-	8,14
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	4,92	-	-	0,29	-	0,02	-	-	94,77	-
Classe 12	-	-	-	21,13	-	-	-	-	0,14	-	-	77,88

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
64,54MVE (ca,ch,cv,cd)
12

	WAVELET - 5 Níveis de Dec. - Média, Variância e Energia do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	61,78	27,53	-	2,70	-	-	0,98	-	-	7,01	-	-
Classe 2	20,74	46,11	9,45	17,20	-	-	1,11	-	3,08	-	-	2,31
Classe 3	-	13,18	59,40	2,23	1,93	0,88	-	0,67	0,55	-	4,51	16,65
Classe 4	0,01	3,84	-	76,00	-	-	18,23	-	1,92	-	-	-
Classe 5	-	-	-	-	67,87	19,39	-	4,17	-	-	8,57	-
Classe 6	-	-	-	-	30,90	56,25	-	4,94	-	-	7,91	-
Classe 7	0,03	0,15	-	14,39	-	-	85,43	-	-	-	-	-
Classe 8	-	0,06	2,11	3,72	5,65	7,64	1,61	68,37	7,60	-	3,24	-
Classe 9	-	0,75	0,01	5,75	-	-	1,48	-	92,00	-	-	0,01
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	15,62	9,88	-	3,44	-	-	71,06	-
Classe 12	-	1,76	5,63	0,01	-	-	1,70	-	0,46	-	-	89,44

Decomp. WAVELET
Distância CyblockEficiência de Recup.
72,81MVE (ca,ch,cv,cd)
12

UNIFORMIZADO

	WAVELET - 5 Níveis de Dec. - Média, Variância e Energia do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	59,43	27,81	-	2,66	-	-	0,96	-	-	9,14	-	-
Classe 2	20,56	41,05	6,66	18,87	-	-	6,49	0,06	4,05	0,21	-	2,05
Classe 3	-	9,43	55,72	5,66	3,15	3,10	1,02	2,41	2,28	-	6,14	11,09
Classe 4	0,03	6,39	-	69,59	-	-	17,40	-	6,59	-	-	-
Classe 5	-	-	-	-	59,20	20,98	-	4,00	-	-	15,82	-
Classe 6	-	-	0,01	-	31,81	48,90	-	5,68	-	-	13,34	0,26
Classe 7	0,03	0,34	-	23,01	-	-	75,13	-	1,49	-	-	-
Classe 8	-	0,29	0,30	3,23	4,74	6,50	4,82	68,96	7,10	-	4,05	0,01
Classe 9	-	0,64	-	14,14	-	-	4,27	-	80,95	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,15	-	23,22	12,91	-	4,00	-	-	59,72	-
Classe 12	-	2,86	5,67	0,10	-	0,13	4,44	-	0,74	-	-	85,06

Decomp. WAVELET
Distância CityblockEficiência de Recup.
##MVE (ca,ch,cv,cd)
12

NORMALIZADO

	WAVELET - 6 Níveis de Dec. - Média, Variância e Energia do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	52,74	23,77	-	1,00	-	-	3,65	-	-	18,84	-	-
Classe 2	25,41	35,34	2,41	19,93	-	-	5,21	-	4,10	-	-	7,60
Classe 3	-	1,78	53,14	-	-	-	-	26,92	11,25	-	6,91	-
Classe 4	-	14,06	-	47,68	-	-	14,00	-	0,34	-	-	23,92
Classe 5	-	-	-	-	69,51	27,10	-	3,39	-	-	-	-
Classe 6	-	-	-	-	42,01	51,11	-	6,88	-	-	-	-
Classe 7	1,77	1,49	-	16,78	-	-	79,96	-	-	-	-	-
Classe 8	-	-	16,59	-	7,08	9,66	-	66,55	-	-	0,12	-
Classe 9	-	0,57	1,67	2,21	-	-	-	-	95,55	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	9,18	-	-	-	-	0,25	-	-	90,57	-
Classe 12	-	3,65	-	18,99	-	-	-	-	-	-	-	76,62

Decomp. WAVELET
Distância CyblockEficiência de Recup.
68,23MVE (ca,ch,cv,cd)
12

img 8 x 8

	WAVELET - 6 Níveis de Dec. - Média, Variância e Energia do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	52,60	21,87	-	0,93	-	-	5,19	-	-	19,41	-	-
Classe 2	25,17	34,05	2,36	18,03	-	-	6,28	-	4,27	-	-	9,84
Classe 3	-	1,85	47,83	-	-	-	-	32,59	10,42	-	7,31	-
Classe 4	-	12,86	-	42,64	-	-	16,35	-	0,38	-	-	27,77
Classe 5	-	-	-	-	65,12	30,90	-	3,98	-	-	-	-
Classe 6	-	-	-	-	46,84	46,74	-	6,42	-	-	-	-
Classe 7	1,90	2,18	-	16,49	-	-	79,43	-	-	-	-	-
Classe 8	-	-	16,59	-	8,26	8,60	-	66,46	-	-	0,09	-
Classe 9	-	1,43	2,67	2,88	-	-	-	-	93,02	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	11,89	-	-	-	-	3,02	-	-	85,09	-
Classe 12	-	2,37	-	19,20	-	-	-	-	-	-	-	77,64

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
65,89MVE (ca,ch,cv,cd)
12

	WAVELET - 6 Níveis de Dec. - Média, Variância e Energia do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	58,64	15,90	-	4,06	-	-	2,93	-	-	18,47	-	-
Classe 2	23,43	44,14	6,44	14,36	-	-	2,07	-	8,46	0,30	-	0,80
Classe 3	-	4,91	68,62	7,50	-	0,05	-	0,11	5,13	-	0,19	13,49
Classe 4	-	1,73	0,08	73,90	-	-	23,01	-	1,28	-	-	-
Classe 5	-	-	-	-	71,84	12,07	-	3,98	-	-	12,11	-
Classe 6	-	-	-	-	16,75	63,16	-	11,60	-	-	8,49	-
Classe 7	0,41	0,87	-	34,44	-	-	60,76	-	3,52	-	-	-
Classe 8	-	-	6,97	4,65	5,07	10,77	-	68,93	0,01	-	3,32	0,28
Classe 9	-	7,18	0,56	1,46	-	-	1,63	-	89,01	-	-	0,16
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	13,87	7,68	-	3,67	-	-	74,78	-
Classe 12	-	0,23	14,17	0,02	-	-	-	-	2,69	-	-	82,21

Decomp. WAVELET
Distância CyblockEficiência de Recup.
71,33MVE (ca,ch,cv,cd)
12

UNIFORMIZADO

	WAVELET - 6 Níveis de Dec. - Média, Variância e Energia do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	56,03	14,42	-	5,22	-	-	3,26	-	-	21,07	-	-
Classe 2	23,76	39,51	5,80	17,82	-	-	3,19	-	7,73	1,29	-	0,90
Classe 3	-	5,66	65,36	10,98	0,09	0,50	-	0,53	3,87	-	0,84	12,17
Classe 4	0,03	3,89	0,34	72,65	-	-	21,41	-	1,68	-	-	-
Classe 5	-	-	-	-	65,29	12,64	-	4,25	-	-	17,82	-
Classe 6	-	-	0,18	-	15,96	59,18	-	11,30	-	-	13,38	-
Classe 7	0,63	1,48	-	39,08	-	-	45,69	-	13,12	-	-	-
Classe 8	-	0,48	4,28	9,52	4,77	9,21	-	67,82	-	-	3,92	-
Classe 9	-	5,59	0,34	4,00	-	-	5,63	-	84,40	-	-	0,04
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,04	-	18,85	11,39	-	4,25	-	-	65,47	-
Classe 12	-	0,90	15,05	0,71	-	-	0,98	-	2,37	-	-	79,48

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
##

MVE (ca,ch,cv,cd)
12

NORMALIZADO

	WAVELET - 7 Níveis de Dec. - Média, Variância e Energia do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	55,30	15,12	-	-	-	-	4,87	-	-	24,71	-	-
Classe 2	25,48	41,17	0,55	9,85	-	-	0,02	-	5,47	-	0,03	17,43
Classe 3	-	0,39	75,97	-	-	-	-	13,40	7,43	-	2,81	-
Classe 4	-	13,46	-	56,84	-	-	4,76	-	4,83	-	-	20,11
Classe 5	-	-	-	-	83,06	13,38	-	3,56	-	-	-	-
Classe 6	-	-	-	-	18,81	74,17	-	7,02	-	-	-	-
Classe 7	9,83	0,41	-	-	-	-	86,80	-	-	-	-	2,96
Classe 8	-	-	12,87	-	8,07	8,58	-	66,43	-	-	4,05	-
Classe 9	-	0,10	4,06	4,73	-	-	-	-	91,11	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	2,03	-	-	-	-	10,71	-	-	87,26	-
Classe 12	-	11,14	-	7,42	-	-	2,22	-	-	-	-	78,53

Decomp. WAVELET
Distância Cyblock

Eficiência de Recup.
74,72

MVE (ca,ch,cv,cd)
12

img 4 x 4

MELHOR
RESULTADO

	WAVELET - 7 Níveis de Dec. - Média, Variância e Energia do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	55,66	15,78	-	-	-	-	5,54	-	-	23,02	-	-
Classe 2	25,36	37,05	1,04	12,02	-	-	0,14	-	4,77	-	0,24	19,38
Classe 3	-	0,48	67,43	-	-	-	-	20,98	6,62	-	4,49	-
Classe 4	-	18,44	-	53,77	-	-	7,53	-	2,79	-	-	17,47
Classe 5	-	-	-	-	82,50	14,67	-	2,83	-	-	-	-
Classe 6	-	-	-	-	20,43	72,52	-	7,05	-	-	-	-
Classe 7	9,42	0,94	-	0,01	-	-	89,09	-	-	-	-	0,54
Classe 8	-	-	12,63	-	7,50	9,32	-	66,54	-	-	4,01	-
Classe 9	-	-	3,89	3,06	-	-	-	-	93,05	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	3,15	-	-	-	-	11,18	-	-	85,67	-
Classe 12	-	11,05	-	4,82	-	-	0,28	-	-	-	-	83,02

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
73,86

MVE (ca,ch,cv,cd)
12

	WAVELET - 7 Níveis de Dec. - Média, Variância e Energia do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	62,46	13,18	-	0,27	-	-	3,77	-	-	20,32	-	-
Classe 2	21,20	44,43	2,38	3,03	-	-	0,63	-	9,76	3,65	-	14,92
Classe 3	-	-	78,96	1,93	-	-	-	-	13,34	-	-	5,77
Classe 4	-	-	0,08	82,31	-	-	6,67	-	10,94	-	-	-
Classe 5	-	-	-	-	84,50	11,61	-	1,56	-	-	2,33	-
Classe 6	-	-	-	-	12,52	71,00	-	7,06	-	-	9,42	-
Classe 7	1,88	0,47	-	3,89	-	-	93,76	-	-	-	-	-
Classe 8	-	-	-	-	2,96	5,41	-	67,23	5,97	-	18,43	-
Classe 9	-	1,26	8,49	9,26	-	-	-	-	79,01	-	-	1,98
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	1,89	4,31	-	7,53	-	-	86,27	-
Classe 12	-	9,50	17,56	1,57	-	-	0,22	-	19,58	-	-	50,96

Decomp. WAVELET
Distância Cyblock

Eficiência de Recup.
75,07

MVE (ca,ch,cv,cd)
12

img 4 x 4

MELHOR
RESULTADO
UNIFORMIZADO

	WAVELET - 7 Níveis de Dec. - Média, Variância e Energia do 7o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	61,57	12,40	-	1,60	-	-	3,35	-	-	21,08	-	-
Classe 2	14,52	40,45	1,62	4,75	-	-	2,32	-	13,28	11,72	-	11,34
Classe 3	-	-	77,47	2,86	-	-	-	-	13,88	-	-	5,79
Classe 4	0,03	0,82	1,01	80,87	-	-	4,38	-	12,89	-	-	-
Classe 5	-	-	-	-	82,50	11,99	-	1,62	-	-	3,89	-
Classe 6	-	-	0,07	-	13,97	64,68	-	6,87	-	-	14,41	-
Classe 7	1,47	1,40	-	8,46	-	-	88,00	-	0,11	-	-	0,56
Classe 8	-	-	-	-	3,12	5,50	0,02	67,38	6,33	-	17,65	-
Classe 9	-	3,00	5,45	13,06	-	-	-	-	77,35	-	-	1,14
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	3,76	5,43	-	8,85	-	-	81,96	-
Classe 12	-	9,15	18,74	0,72	-	-	6,05	-	15,26	-	-	49,44

Decomp. WAVELET
Distância Cyblock

Eficiência de Recup.
72,64

MVE (ca,ch,cv,cd)
12

img 4 x 4

NORMALIZADO

	WAVELET - 2 Níveis de Dec. - Coef. De Aproximação do 2o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	62,78	0,49	-	-	-	-	-	-	-	36,73	-	-
Classe 2	15,54	66,33	2,22	-	-	-	-	-	0,82	12,31	-	2,78
Classe 3	-	1,02	97,13	1,40	-	-	-	-	0,45	-	-	-
Classe 4	1,01	-	-	97,78	-	-	-	-	-	1,21	-	-
Classe 5	-	-	-	-	88,54	6,62	-	4,84	-	-	-	-
Classe 6	-	-	-	-	6,91	87,38	-	5,71	-	-	-	-
Classe 7	-	-	-	-	-	-	80,89	-	-	19,11	-	-
Classe 8	-	-	-	-	3,03	4,48	-	91,43	-	-	1,06	-
Classe 9	-	0,14	-	14,38	-	-	-	-	85,48	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,58	-	-	99,42	-
Classe 12	-	0,66	-	-	-	-	-	-	-	-	-	98,34

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
87,96

CA + Entropia (img)
16,385
img 128 x 128

máximo 3,3906E+06
mínimo -8,19E+03

	WAVELET - 2 Níveis de Dec. - Coef. De Aproximação do 2o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	60,52	17,35	0,14	7,35	-	-	8,36	-	-	6,28	-	-
Classe 2	19,18	50,33	6,47	-	-	-	-	-	0,14	-	-	23,88
Classe 3	1,06	20,96	77,87	-	-	-	-	-	-	-	-	0,11
Classe 4	0,07	-	-	77,90	-	-	-	-	7,84	14,19	-	-
Classe 5	-	-	-	-	70,76	6,00	-	23,24	-	-	-	-
Classe 6	-	-	-	-	4,89	87,63	-	5,90	-	-	1,58	-
Classe 7	1,46	-	-	-	-	-	86,24	-	-	12,30	-	-
Classe 8	-	-	-	-	10,95	3,88	-	84,65	-	-	0,52	-
Classe 9	-	3,08	-	12,04	-	-	-	-	75,92	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	2,20	-	1,66	-	-	96,14	-
Classe 12	-	31,91	-	-	-	-	-	-	0,15	-	-	67,26

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
77,94

CA + Entropia (img)
16,385

	WAVELET - 2 Níveis de Dec. - Coef. De Aproximação do 2o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,34	0,18	-	-	-	-	-	-	-	34,48	-	-
Classe 2	14,21	65,01	2,47	0,05	-	-	-	-	0,81	15,68	-	1,77
Classe 3	-	-	97,68	2,32	-	-	-	-	-	-	-	-
Classe 4	1,55	-	-	97,38	-	-	-	-	-	1,07	-	-
Classe 5	-	-	-	-	90,49	5,97	-	3,54	-	-	-	-
Classe 6	-	-	-	-	5,56	89,33	-	5,11	-	-	-	-
Classe 7	-	-	-	-	-	-	77,62	-	-	22,38	-	-
Classe 8	-	-	-	-	1,42	3,91	-	93,57	-	-	1,10	-
Classe 9	-	0,12	-	12,91	-	-	-	-	86,97	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,05	-	-	98,95	-
Classe 12	-	2,55	-	-	-	-	-	-	-	-	-	96,47

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
88,23

CA + Entropia (img)
16,385

UNIFORMIZADO

máximo 1
mínimo 0

	WAVELET - 2 Níveis de Dec. - Coef. De Aproximação do 2o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,95	0,22	-	-	-	-	-	-	-	33,83	-	-
Classe 2	14,24	63,71	2,05	0,01	-	-	-	-	0,85	15,38	-	3,76
Classe 3	-	0,26	97,71	2,03	-	-	-	-	-	-	-	-
Classe 4	1,26	-	-	97,86	-	-	-	-	-	0,88	-	-
Classe 5	-	-	-	-	88,68	5,90	-	5,42	-	-	-	-
Classe 6	-	-	-	-	6,18	89,60	-	4,22	-	-	-	-
Classe 7	-	-	-	-	-	-	71,98	-	-	28,02	-	-
Classe 8	-	-	-	-	0,76	0,41	-	98,67	-	-	0,16	-
Classe 9	-	-	-	12,19	-	-	-	-	87,81	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,51	-	-	98,49	-
Classe 12	-	4,92	-	-	-	-	-	-	-	-	-	94,18

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
87,89

CA + Entropia (img)
16,385

NORMALIZADO

	WAVELET - 3 Níveis de Dec. - Coef. De Aproximação do 3o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	64,82	0,88	-	-	-	-	-	-	-	34,30	-	-
Classe 2	20,17	65,64	2,73	-	-	-	-	-	0,76	6,83	-	3,87
Classe 3	-	0,91	98,64	0,45	-	-	-	-	-	-	-	-
Classe 4	-	-	-	97,82	-	-	-	-	-	2,18	-	-
Classe 5	-	-	-	-	88,49	6,94	-	4,57	-	-	-	-
Classe 6	-	-	-	-	6,64	88,34	-	5,02	-	-	-	-
Classe 7	-	-	-	-	-	-	84,90	-	-	15,10	-	-
Classe 8	-	-	-	-	2,79	4,59	-	91,59	-	-	1,03	-
Classe 9	-	0,14	-	14,03	-	-	-	-	85,83	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,45	-	-	99,55	-
Classe 12	-	0,41	-	-	-	-	-	-	-	-	-	98,59

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
88,68

CA + Entropia (img)
4,097
img 128 x 128

WAVELET - 3 Níveis de Dec. - Coef. De Aproximação do 3o. Nível + Entropia da imagem total (Entropia Global)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	60,43	17,38	0,24	7,32	-	-	9,23	-	-	5,40	-	-
Classe 2	18,62	49,91	7,47	-	-	-	-	-	0,14	-	-	23,86
Classe 3	0,97	19,81	79,14	-	-	-	-	-	-	-	-	0,08
Classe 4	0,07	-	-	77,92	-	-	-	-	8,03	13,98	-	-
Classe 5	-	-	-	-	71,14	6,23	-	22,63	-	-	-	-
Classe 6	-	-	-	-	4,96	87,87	-	5,38	-	-	1,79	-
Classe 7	1,32	-	-	-	-	-	93,14	-	-	5,54	-	-
Classe 8	-	-	-	-	11,23	4,12	-	84,12	-	-	0,53	-
Classe 9	-	3,08	-	12,04	-	-	-	-	75,92	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	2,48	-	1,51	-	-	96,01	-
Classe 12	-	31,98	-	-	-	-	-	-	0,11	-	-	67,23

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
78,57

CA + Entropia (img)
4.097

WAVELET - 3 Níveis de Dec. - Coef. De Aproximação do 3o. Nível + Entropia da imagem total (Entropia Global)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	69,37	0,19	-	-	-	-	-	-	-	30,44	-	-
Classe 2	15,07	64,05	2,98	0,03	-	-	-	-	0,83	14,11	-	2,93
Classe 3	-	0,06	98,86	1,08	-	-	-	-	-	-	-	-
Classe 4	1,72	-	-	97,51	-	-	-	-	-	0,77	-	-
Classe 5	-	-	-	-	90,50	6,00	-	3,50	-	-	-	-
Classe 6	-	-	-	-	5,56	89,70	-	4,74	-	-	-	-
Classe 7	-	-	-	-	-	-	79,59	-	-	20,41	-	-
Classe 8	-	-	-	-	1,20	3,25	-	94,62	-	-	0,93	-
Classe 9	-	0,12	-	12,41	-	-	-	-	87,47	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,82	-	-	99,18	-
Classe 12	-	2,27	-	-	-	-	-	-	-	-	-	96,75

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
88,97

CA + Entropia (img)
4.097

UNIFORMIZADO

WAVELET - 3 Níveis de Dec. - Coef. De Aproximação do 3o. Nível + Entropia da imagem total (Entropia Global)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	69,64	0,22	-	-	-	-	-	-	-	30,14	-	-
Classe 2	15,24	63,45	2,25	0,01	-	-	-	-	0,85	13,87	-	4,33
Classe 3	-	0,53	98,83	0,64	-	-	-	-	-	-	-	-
Classe 4	1,25	-	-	97,98	-	-	-	-	-	0,77	-	-
Classe 5	-	-	-	-	88,60	6,09	-	5,31	-	-	-	-
Classe 6	-	-	-	-	6,37	89,93	-	3,70	-	-	-	-
Classe 7	-	-	-	-	-	-	74,28	-	-	25,72	-	-
Classe 8	-	-	-	-	0,64	0,41	-	98,76	-	-	0,19	-
Classe 9	-	-	-	12,06	-	-	-	-	87,94	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,38	-	-	98,62	-
Classe 12	-	4,82	-	-	-	-	-	-	-	-	-	94,28

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
88,53

CA + Entropia (img)
4.097

NORMALIZADO

WAVELET - 4 Níveis de Dec. - Coef. De Aproximação do 4o. Nível + Entropia da imagem total (Entropia Global)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	67,73	3,49	-	-	-	-	-	-	-	28,78	-	-
Classe 2	25,60	63,06	2,74	-	-	-	-	-	0,21	0,73	-	7,66
Classe 3	-	0,80	99,20	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	97,80	-	-	-	-	-	2,20	-	-
Classe 5	-	-	-	-	88,09	7,61	-	4,30	-	-	-	-
Classe 6	-	-	-	-	5,99	90,24	-	3,77	-	-	-	-
Classe 7	-	-	-	-	-	-	89,96	-	-	10,04	-	-
Classe 8	-	-	-	-	2,40	5,01	-	91,70	-	-	0,89	-
Classe 9	-	0,14	-	13,56	-	-	-	-	86,30	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,27	-	-	99,73	-
Classe 12	-	0,25	-	-	-	-	-	-	-	-	-	98,75

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
89,38

CA + Entropia (img)
1.025

img 128 x 128

MELHOR
RESULTADO

WAVELET - 4 Níveis de Dec. - Coef. De Aproximação do 4o. Nível + Entropia da imagem total (Entropia Global)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	60,41	17,35	0,33	7,31	-	-	10,77	-	-	3,83	-	-
Classe 2	18,18	48,94	8,56	-	-	-	-	-	0,14	-	-	24,18
Classe 3	0,91	18,88	80,07	-	-	-	-	-	-	-	-	0,14
Classe 4	0,12	-	-	78,10	-	-	-	-	8,14	13,64	-	-
Classe 5	-	-	-	-	71,28	6,72	-	22,00	-	-	-	-
Classe 6	-	-	-	-	5,04	88,59	-	4,54	-	-	1,83	-
Classe 7	1,15	-	-	-	-	-	95,65	-	-	3,20	-	-
Classe 8	-	-	-	-	11,89	4,29	-	83,32	-	-	0,50	-
Classe 9	-	3,08	-	12,04	-	-	-	-	75,92	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	2,78	-	1,34	-	-	95,88	-
Classe 12	-	31,93	-	-	-	-	-	-	0,04	-	-	67,35

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
78,79

CA + Entropia (img)
1.025

	WAVELET - 4 Níveis de Dec. - Coef. De Aproximação do 4o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,57	0,27	-	-	-	-	-	-	-	23,16	-	-
Classe 2	17,25	62,70	3,62	0,06	-	-	-	-	0,82	11,33	-	4,22
Classe 3	-	0,36	99,59	0,05	-	-	-	-	-	-	-	-
Classe 4	2,07	-	-	97,71	-	-	-	-	-	0,22	-	-
Classe 5	-	-	-	-	90,13	6,52	-	3,35	-	-	-	-
Classe 6	-	-	-	-	5,48	90,94	-	3,58	-	-	-	-
Classe 7	-	-	-	-	-	-	86,37	-	-	13,63	-	-
Classe 8	-	-	-	-	0,87	3,11	-	95,23	-	-	0,79	-
Classe 9	-	0,14	-	12,13	-	-	-	-	87,73	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,57	-	-	99,43	-
Classe 12	-	1,85	-	-	-	-	-	-	-	-	-	97,21

Decomp. WAVELET
Distância CityblockEficiência de Recup.
90,30CA + Entropia (img)
1.025UNIFORMIZADO
MELHOR
RESULTADO

	WAVELET - 4 Níveis de Dec. - Coef. De Aproximação do 4o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,29	0,36	-	-	-	-	-	-	-	23,35	-	-
Classe 2	17,02	61,50	2,64	0,04	-	-	-	-	0,82	11,52	-	6,46
Classe 3	-	0,53	99,42	0,05	-	-	-	-	-	-	-	-
Classe 4	1,19	-	-	98,28	-	-	-	-	-	0,53	-	-
Classe 5	-	-	-	-	88,13	6,84	-	5,03	-	-	-	-
Classe 6	-	-	-	-	6,28	91,15	-	2,57	-	-	-	-
Classe 7	-	-	-	-	-	-	80,09	-	-	19,91	-	-
Classe 8	-	-	-	-	0,55	0,45	-	98,77	-	-	0,23	-
Classe 9	-	-	-	12,04	-	-	-	-	87,96	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,07	-	-	98,93	-
Classe 12	-	4,60	-	-	-	-	-	-	-	-	-	94,50

Decomp. WAVELET
Distância CityblockEficiência de Recup.
89,59CA + Entropia (img)
1.025NORMALIZADO
MELHOR
RESULTADO

	WAVELET - 5 Níveis de Dec. - Coef. De Aproximação do 5o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	68,29	7,67	-	-	-	-	-	-	-	24,04	-	-
Classe 2	26,05	58,22	3,11	-	-	-	-	-	0,14	-	-	12,48
Classe 3	-	0,42	99,58	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	96,90	-	-	-	-	-	3,10	-	-
Classe 5	-	-	-	-	86,68	8,87	-	4,45	-	-	-	-
Classe 6	-	-	-	-	5,21	92,06	-	2,73	-	-	-	-
Classe 7	-	-	-	-	-	-	96,06	-	-	3,94	-	-
Classe 8	-	-	-	-	2,36	5,98	-	91,00	-	-	0,66	-
Classe 9	-	0,14	3,71	12,04	-	-	-	-	79,68	-	-	4,43
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,06	-	-	99,94	-
Classe 12	-	0,01	-	-	-	-	-	-	-	-	-	98,99

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,95CA + Entropia (img)
257

img 128 x 128

	WAVELET - 5 Níveis de Dec. - Coef. De Aproximação do 5o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	60,13	17,34	0,43	7,53	-	-	12,95	-	-	1,62	-	-
Classe 2	17,55	48,37	9,56	-	-	-	-	-	0,14	-	-	24,38
Classe 3	0,90	17,87	81,00	-	-	-	-	-	-	-	-	0,23
Classe 4	0,12	-	-	78,09	-	-	-	-	8,58	13,21	-	-
Classe 5	-	-	-	-	70,77	7,21	-	22,02	-	-	-	-
Classe 6	-	-	-	-	4,93	89,09	-	3,93	-	-	2,05	-
Classe 7	0,86	-	-	-	-	-	97,65	-	-	1,49	-	-
Classe 8	-	-	-	-	12,92	4,58	-	82,05	-	-	0,45	-
Classe 9	-	3,08	-	12,07	-	-	-	-	75,89	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	3,55	-	1,05	-	-	95,40	-
Classe 12	-	32,13	-	-	-	-	-	-	0,01	-	-	67,16

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
78,80CA + Entropia (img)
257

	WAVELET - 5 Níveis de Dec. - Coef. De Aproximação do 5o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	83,28	0,46	-	-	-	-	-	-	-	16,26	-	-
Classe 2	20,23	59,09	3,73	0,13	-	-	-	-	0,86	7,48	-	8,48
Classe 3	-	0,13	99,87	-	-	-	-	-	-	-	-	-
Classe 4	1,87	-	-	98,03	-	-	-	-	-	0,10	-	-
Classe 5	-	-	-	-	88,91	7,66	-	3,43	-	-	-	-
Classe 6	-	-	-	-	5,60	91,84	-	2,56	-	-	-	-
Classe 7	0,02	-	-	-	-	-	93,33	-	-	6,65	-	-
Classe 8	-	-	-	-	0,64	3,59	-	95,12	-	-	0,65	-
Classe 9	-	0,14	-	12,02	-	-	0,02	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,15	-	-	99,85	-
Classe 12	-	0,34	-	-	-	-	-	-	-	-	-	98,66

Decomp. WAVELET
Distância CityblockEficiência de Recup.
91,32CA + Entropia (img)
257

UNIFORMIZADO

	WAVELET - 5 Níveis de Dec. - Coef. De Aproximação do 5o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	82,89	0,59	-	-	-	-	-	-	-	16,52	-	-
Classe 2	20,06	57,46	3,57	0,11	-	-	-	-	0,86	7,52	-	10,42
Classe 3	-	0,24	99,76	-	-	-	-	-	-	-	-	-
Classe 4	1,16	-	-	98,40	-	-	-	-	-	0,44	-	-
Classe 5	-	-	-	-	87,14	7,90	-	4,96	-	-	-	-
Classe 6	-	-	-	-	6,40	91,73	-	1,87	-	-	-	-
Classe 7	-	-	-	-	-	-	90,59	-	-	9,41	-	-
Classe 8	-	-	-	-	0,47	0,70	-	98,49	-	-	0,34	-
Classe 9	-	-	-	11,99	-	-	0,05	-	87,96	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,40	-	-	99,60	-
Classe 12	-	3,20	-	-	-	-	-	-	-	-	-	95,85

Decomp. WAVELET
Distância CityblockEficiência de Recup.
90,82CA + Entropia (img)
257

NORMALIZADO

	WAVELET - 6 Níveis de Dec. - Coef. De Aproximação do 6o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	69,28	11,35	-	-	-	-	0,95	-	-	18,42	-	-
Classe 2	25,30	51,30	3,48	-	-	-	-	-	0,14	-	-	19,78
Classe 3	-	0,77	99,23	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	95,12	-	-	-	-	-	4,88	-	-
Classe 5	-	-	-	-	84,10	9,68	-	6,22	-	-	-	-
Classe 6	-	-	-	-	4,52	92,25	-	3,17	-	-	0,06	-
Classe 7	0,28	-	-	-	-	-	99,12	-	-	0,60	-	-
Classe 8	-	-	-	-	4,11	6,64	-	88,76	-	-	0,49	-
Classe 9	-	0,28	2,80	12,04	-	-	-	-	75,92	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,04	-	-	99,96	-
Classe 12	-	6,32	-	-	-	-	-	-	-	-	-	92,80

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,32CA + Entropia (img)
65

img 128 x 128

	WAVELET - 6 Níveis de Dec. - Coef. De Aproximação do 6o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	59,68	17,17	0,56	8,02	-	-	14,15	-	-	0,42	-	-
Classe 2	17,02	46,96	11,02	-	-	-	-	-	0,14	-	-	24,86
Classe 3	1,06	19,08	79,79	-	-	-	-	-	-	-	-	0,07
Classe 4	0,05	-	-	75,37	-	-	-	-	11,07	13,51	-	-
Classe 5	-	-	-	-	68,45	7,65	-	23,90	-	-	-	-
Classe 6	-	-	-	-	4,98	88,05	-	4,28	-	-	2,69	-
Classe 7	0,31	-	-	-	-	-	99,63	-	-	0,06	-	-
Classe 8	-	-	-	-	13,83	4,88	-	81,02	-	-	0,27	-
Classe 9	-	3,08	-	12,61	-	-	-	-	75,35	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	5,01	-	0,71	-	-	94,28	-
Classe 12	-	32,94	-	-	-	-	-	-	0,46	-	-	65,92

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
77,88CA + Entropia (img)
65

	WAVELET - 6 Níveis de Dec. - Coef. De Aproximação do 6o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	87,14	1,13	-	-	-	-	-	-	-	11,73	-	-
Classe 2	25,59	52,11	4,98	-	-	-	-	-	0,50	1,20	-	15,62
Classe 3	-	0,18	99,82	-	-	-	-	-	-	-	-	-
Classe 4	1,59	-	-	98,41	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	87,97	8,57	-	3,46	-	-	-	-
Classe 6	-	-	-	-	5,83	91,96	-	2,21	-	-	-	-
Classe 7	-	-	-	-	-	-	97,60	-	-	2,40	-	-
Classe 8	-	-	-	-	0,90	4,36	-	94,23	-	-	0,51	-
Classe 9	-	0,14	0,21	12,04	-	-	-	-	87,61	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	1,36	-	-	-	-	-	-	-	-	-	97,70

Decomp. WAVELET
Distância CityblockEficiência de Recup.
91,21CA + Entropia (img)
65

img 128 x 128

UNIFORMIZADO

	WAVELET - 6 Níveis de Dec. - Coef. De Aproximação do 6o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	87,87	1,26	-	-	-	-	-	-	-	10,87	-	-
Classe 2	25,03	50,71	4,84	-	-	-	-	-	0,51	1,86	-	17,05
Classe 3	-	0,37	99,63	-	-	-	-	-	-	-	-	-
Classe 4	1,15	-	-	98,85	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	86,55	8,89	-	4,56	-	-	-	-
Classe 6	-	-	-	-	7,00	91,21	-	1,79	-	-	-	-
Classe 7	-	-	-	-	-	-	96,54	-	-	3,46	-	-
Classe 8	-	-	-	-	0,76	1,39	-	97,47	-	-	0,38	-
Classe 9	-	0,14	-	12,04	-	-	-	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	5,95	-	-	-	-	-	-	-	-	-	93,17

Decomp. WAVELET
Distância CityblockEficiência de Recup.
90,82CA + Entropia (img)
65

NORMALIZADO

	WAVELET - 7 Níveis de Dec. - Coef. De Aproximação do 7o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	66,05	17,61	-	0,20	-	-	5,83	-	-	10,31	-	-
Classe 2	23,64	48,55	5,18	-	-	-	-	-	0,14	-	-	22,49
Classe 3	0,43	8,60	89,96	-	-	-	-	-	-	-	-	1,01
Classe 4	-	-	-	88,24	-	-	-	-	3,40	8,36	-	-
Classe 5	-	-	-	-	71,91	7,14	-	20,82	-	-	0,13	-
Classe 6	-	-	-	-	4,38	88,29	-	2,65	-	-	4,68	-
Classe 7	0,24	-	-	-	-	-	99,76	-	-	-	-	-
Classe 8	-	-	-	-	15,51	5,37	-	78,49	-	-	0,63	-
Classe 9	-	0,59	2,49	12,04	-	-	-	-	75,92	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	0,03	3,09	-	0,44	-	-	96,44	-
Classe 12	-	13,97	-	-	-	-	-	-	-	-	-	85,22

Decomp. WAVELET
Distância CityblockEficiência de Recup.
82,40CA + Entropia (img)
17

img 128 x 128

	WAVELET - 7 Níveis de Dec. - Coef. De Aproximação do 7o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	58,32	17,14	0,96	8,87	-	-	14,61	-	-	0,10	-	-
Classe 2	16,25	45,51	12,53	-	-	-	-	-	0,14	-	-	25,57
Classe 3	1,80	16,99	74,26	-	-	-	-	-	-	-	-	6,95
Classe 4	0,01	-	-	73,70	-	-	3,88	-	12,14	10,27	-	-
Classe 5	-	-	-	-	61,36	6,45	-	32,03	-	-	0,16	-
Classe 6	-	-	-	-	5,41	82,39	-	2,96	-	-	9,24	-
Classe 7	0,39	-	-	0,03	-	-	99,25	-	-	0,33	-	-
Classe 8	-	-	-	-	19,21	4,31	-	76,12	-	-	0,36	-
Classe 9	-	3,08	-	13,15	-	-	-	-	74,81	-	-	8,96
Classe 10	-	-	-	-	-	-	0,08	-	-	99,92	-	-
Classe 11	-	-	-	-	0,07	10,28	-	0,26	-	-	89,39	-
Classe 12	-	32,69	0,48	-	-	-	-	-	1,25	-	-	64,85

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
74,99CA + Entropia (img)
17

	WAVELET - 7 Níveis de Dec. - Coef. De Aproximação do 7o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	77,17	9,25	-	-	-	-	0,81	-	-	12,77	-	-
Classe 2	24,87	48,32	5,42	-	-	-	1,12	-	0,09	-	-	20,18
Classe 3	-	1,25	96,98	-	-	-	-	-	-	-	-	1,77
Classe 4	-	-	-	97,72	-	-	2,28	-	-	-	-	-
Classe 5	-	-	-	-	79,97	8,63	-	11,30	-	-	0,10	-
Classe 6	-	-	-	-	6,79	88,48	-	4,11	-	-	0,62	-
Classe 7	0,21	-	-	-	-	-	99,79	-	-	-	-	-
Classe 8	-	-	-	-	9,34	5,38	-	84,47	-	-	0,81	-
Classe 9	-	0,14	2,43	12,04	-	-	-	-	82,90	-	-	2,49
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,11	-	0,09	-	-	99,80	-
Classe 12	-	0,81	0,25	-	-	-	-	-	-	-	-	97,94

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,80CA + Entropia (img)
17

img 128 x 128

UNIFORMIZADO

	WAVELET - 7 Níveis de Dec. - Coef. De Aproximação do 7o. Nível + Entropia da imagem total (Entropia Global)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	77,71	9,38	-	-	-	-	0,80	-	-	12,11	-	-
Classe 2	24,73	48,33	5,43	-	-	-	1,18	-	0,16	-	-	20,17
Classe 3	-	1,55	96,27	0,13	-	-	-	-	-	-	-	2,05
Classe 4	-	-	-	97,95	-	-	2,05	-	-	-	-	-
Classe 5	-	-	-	-	77,14	8,41	-	14,35	-	-	0,10	-
Classe 6	-	-	-	-	7,36	88,72	-	2,67	-	-	1,25	-
Classe 7	0,27	-	-	-	-	-	99,73	-	-	-	-	-
Classe 8	-	-	-	-	8,12	3,49	-	87,53	-	-	0,86	-
Classe 9	-	0,14	2,03	12,04	-	-	-	-	84,34	-	-	1,45
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,20	-	0,19	-	-	99,61	-
Classe 12	-	1,61	0,25	-	-	-	-	-	-	-	-	97,14

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,87CA + Entropia (img)
17

NORMALIZADO

	WAVELET - 2 Níveis de Dec. - Coef. De Aproximação do 2o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	62,70	0,17	-	-	-	-	-	-	-	37,13	-	-
Classe 2	13,18	65,92	2,29	-	-	-	-	-	0,83	15,77	-	2,01
Classe 3	-	0,95	96,85	1,37	-	-	-	-	0,83	-	-	-
Classe 4	1,22	-	-	97,82	-	-	-	-	-	0,96	-	-
Classe 5	-	-	-	-	88,69	6,59	-	4,72	-	-	-	-
Classe 6	-	-	-	-	7,13	87,05	-	5,82	-	-	-	-
Classe 7	-	-	-	-	-	-	79,87	-	-	20,13	-	-
Classe 8	-	-	-	-	2,91	4,44	-	91,44	-	-	1,21	-
Classe 9	-	0,12	-	14,44	-	-	-	-	85,44	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,67	-	-	99,33	-
Classe 12	-	0,78	-	-	-	-	-	-	-	-	-	98,22

Decomp. WAVELET
Distância CyblockEficiência de Recup.
87,78CA + Entropia (ca)
16,385

img 128 x 128

WAVELET - 2 Níveis de Dec. - Coef. De Aproximação do 2o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	53,28	2,48	-	-	-	-	-	-	-	44,24	-	-
Classe 2	13,07	66,70	0,35	-	-	-	-	-	0,82	14,42	-	4,64
Classe 3	-	7,22	90,58	-	-	-	-	-	2,20	-	-	-
Classe 4	4,90	-	-	94,45	-	-	-	-	-	0,65	-	-
Classe 5	-	-	-	-	84,24	7,01	-	8,75	-	-	-	-
Classe 6	-	-	-	-	7,33	84,41	-	8,26	-	-	-	-
Classe 7	3,96	0,14	-	-	-	-	58,85	-	-	37,05	-	-
Classe 8	-	-	-	-	0,19	0,31	-	99,34	-	-	0,16	-
Classe 9	-	0,67	-	10,13	-	-	-	-	89,20	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,91	-	-	99,09	-
Classe 12	-	5,84	-	-	-	-	-	-	-	-	-	93,43

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
84,46CA + Entropia (ca)
16,385

WAVELET - 2 Níveis de Dec. - Coef. De Aproximação do 2o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,34	0,18	-	-	-	-	-	-	-	34,48	-	-
Classe 2	14,21	65,01	2,47	0,05	-	-	-	-	0,81	15,68	-	1,77
Classe 3	-	-	97,68	2,32	-	-	-	-	-	-	-	-
Classe 4	1,55	-	-	97,38	-	-	-	-	-	1,07	-	-
Classe 5	-	-	-	-	90,49	5,97	-	3,54	-	-	-	-
Classe 6	-	-	-	-	5,56	89,35	-	5,09	-	-	-	-
Classe 7	-	-	-	-	-	-	77,61	-	-	22,39	-	-
Classe 8	-	-	-	-	1,42	3,91	-	93,57	-	-	1,10	-
Classe 9	-	0,12	-	12,92	-	-	-	-	86,96	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,05	-	-	98,95	-
Classe 12	-	2,54	-	-	-	-	-	-	-	-	-	96,48

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,24CA + Entropia (ca)
16,385

UNIFORMIZADO

WAVELET - 2 Níveis de Dec. - Coef. De Aproximação do 2o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	65,95	0,22	-	-	-	-	-	-	-	33,83	-	-
Classe 2	14,24	63,71	2,05	0,01	-	-	-	-	0,85	15,38	-	3,76
Classe 3	-	0,26	97,71	2,03	-	-	-	-	-	-	-	-
Classe 4	1,26	-	-	97,86	-	-	-	-	-	0,88	-	-
Classe 5	-	-	-	-	88,68	5,90	-	5,42	-	-	-	-
Classe 6	-	-	-	-	6,18	89,60	-	4,22	-	-	-	-
Classe 7	-	-	-	-	-	-	71,98	-	-	28,02	-	-
Classe 8	-	-	-	-	0,76	0,41	-	98,67	-	-	0,16	-
Classe 9	-	-	-	12,19	-	-	-	-	87,81	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,51	-	-	98,49	-
Classe 12	-	4,92	-	-	-	-	-	-	-	-	-	94,18

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,89CA + Entropia (ca)
16,385

NORMALIZADO

WAVELET - 3 Níveis de Dec. - Coef. De Aproximação do 3o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	66,13	0,26	-	-	-	-	-	-	-	33,61	-	-
Classe 2	13,99	65,12	2,87	-	-	-	-	-	0,85	14,40	-	2,77
Classe 3	-	0,91	98,30	0,68	-	-	-	-	0,11	-	-	-
Classe 4	1,23	-	-	97,96	-	-	-	-	-	0,81	-	-
Classe 5	-	-	-	-	88,62	7,07	-	4,31	-	-	-	-
Classe 6	-	-	-	-	6,93	87,82	-	5,25	-	-	-	-
Classe 7	-	-	-	-	-	-	83,38	-	-	16,62	-	-
Classe 8	-	-	-	-	2,66	4,49	-	91,52	-	-	1,33	-
Classe 9	-	0,13	-	13,97	-	-	-	-	85,90	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,59	-	-	99,41	-
Classe 12	-	0,69	-	-	-	-	-	-	-	-	-	98,31

Decomp. WAVELET
Distância CyblockEficiência de Recup.
88,54CA + Entropia (ca)
4,097

img 128 x 128

WAVELET - 3 Níveis de Dec. - Coef. De Aproximação do 3o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	53,77	1,62	-	-	-	-	-	-	-	44,61	-	-
Classe 2	9,40	64,48	0,77	0,11	-	-	-	-	0,86	19,73	-	4,65
Classe 3	-	5,85	92,21	-	-	-	-	-	1,94	-	-	-
Classe 4	5,26	0,25	-	94,46	-	-	-	-	-	0,03	-	-
Classe 5	-	-	-	-	84,71	7,57	-	7,72	-	-	-	-
Classe 6	-	-	-	-	7,59	85,27	-	7,14	-	-	-	-
Classe 7	4,43	3,26	-	-	-	-	70,85	-	-	21,46	-	-
Classe 8	-	-	-	-	0,20	0,37	-	99,21	-	-	0,22	-
Classe 9	-	0,86	-	8,57	-	-	0,04	-	90,53	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,77	-	-	99,23	-
Classe 12	-	5,40	-	-	-	-	-	-	-	-	-	93,86

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
85,72CA + Entropia (ca)
4,097

	WAVELET - 3 Níveis de Dec. - Coef. De Aproximação do 3o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	69,41	0,19	-	-	-	-	-	-	-	30,40	-	-
Classe 2	15,13	64,00	3,03	0,03	-	-	-	-	0,83	14,05	-	2,93
Classe 3	-	0,07	98,87	1,06	-	-	-	-	-	-	-	-
Classe 4	1,75	-	-	97,51	-	-	-	-	-	0,74	-	-
Classe 5	-	-	-	-	90,50	6,00	-	3,50	-	-	-	-
Classe 6	-	-	-	-	5,56	89,70	-	4,74	-	-	-	-
Classe 7	-	-	-	-	-	-	79,59	-	-	20,41	-	-
Classe 8	-	-	-	-	1,20	3,25	-	94,62	-	-	0,93	-
Classe 9	-	0,12	-	12,42	-	-	-	-	87,46	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,82	-	-	99,18	-
Classe 12	-	2,26	-	-	-	-	-	-	-	-	-	96,76

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,97CA + Entropia (ca)
4,097

UNIFORMIZADO

	WAVELET - 3 Níveis de Dec. - Coef. De Aproximação do 3o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	69,66	0,22	-	-	-	-	-	-	-	30,12	-	-
Classe 2	15,24	63,40	2,30	0,01	-	-	-	-	0,85	13,87	-	4,33
Classe 3	-	0,53	98,84	0,63	-	-	-	-	-	-	-	-
Classe 4	1,25	-	-	97,99	-	-	-	-	-	0,76	-	-
Classe 5	-	-	-	-	88,60	6,09	-	5,31	-	-	-	-
Classe 6	-	-	-	-	6,37	89,93	-	3,70	-	-	-	-
Classe 7	-	-	-	-	-	-	74,28	-	-	25,72	-	-
Classe 8	-	-	-	-	0,64	0,41	-	98,76	-	-	0,19	-
Classe 9	-	-	-	12,06	-	-	-	-	87,94	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,38	-	-	98,62	-
Classe 12	-	4,82	-	-	-	-	-	-	-	-	-	94,28

Decomp. WAVELET
Distância CityblockEficiência de Recup.
88,53CA + Entropia (ca)
4,097

NORMALIZADO

	WAVELET - 4 Níveis de Dec. - Coef. De Aproximação do 4o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	73,31	0,27	-	-	-	-	-	-	-	26,42	-	-
Classe 2	15,47	63,86	3,26	0,02	-	-	-	-	0,86	12,55	-	3,98
Classe 3	-	0,84	99,13	0,03	-	-	-	-	-	-	-	-
Classe 4	1,41	-	-	98,32	-	-	-	-	-	0,27	-	-
Classe 5	-	-	-	-	88,48	7,95	-	3,57	-	-	-	-
Classe 6	-	-	-	-	6,57	89,27	-	4,16	-	-	-	-
Classe 7	-	-	-	-	-	-	88,14	-	-	11,86	-	-
Classe 8	-	-	-	-	2,20	4,82	-	91,56	-	-	1,42	-
Classe 9	-	0,14	-	13,29	-	-	0,05	-	86,52	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,50	-	-	99,50	-
Classe 12	-	0,56	-	-	-	-	-	-	-	-	-	98,44

Decomp. WAVELET
Distância CityblockEficiência de Recup.
89,71CA + Entropia (ca)
1,025

img 128 x 128

	WAVELET - 4 Níveis de Dec. - Coef. De Aproximação do 4o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	59.59	1.69	-	-	-	-	-	-	-	38.72	-	-
Classe 2	10.43	64,24	1,31	0,11	-	-	-	-	0.86	17,47	-	5.58
Classe 3	-	4.90	94,08	-	-	-	-	-	1.02	-	-	-
Classe 4	4.89	0.23	-	94,88	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	84,66	8.75	-	6.59	-	-	-	-
Classe 6	-	-	-	-	7.53	87,10	-	5.37	-	-	-	-
Classe 7	3.09	2.98	-	-	-	-	84,42	-	-	9.51	-	-
Classe 8	-	-	-	-	0.30	0.68	-	98,75	-	-	0.27	-
Classe 9	-	0.86	-	8.17	-	-	0.29	-	90,68	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0.43	-	-	99,57	-
Classe 12	-	4.08	-	-	-	-	-	-	-	-	-	95,16

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
87,76CA + Entropia (ca)
1,025

	WAVELET - 4 Níveis de Dec. - Coef. De Aproximação do 4o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,75	0,27	-	-	-	-	-	-	-	22,98	-	-
Classe 2	17,41	62,68	3,64	0,06	-	-	-	-	0,82	11,17	-	4,22
Classe 3	-	0,36	99,59	0,05	-	-	-	-	-	-	-	-
Classe 4	2,10	-	-	97,71	-	-	-	-	-	0,19	-	-
Classe 5	-	-	-	-	90,12	6,52	-	3,36	-	-	-	-
Classe 6	-	-	-	-	5,47	90,95	-	3,58	-	-	-	-
Classe 7	-	-	-	-	-	-	86,31	-	-	13,69	-	-
Classe 8	-	-	-	-	0,86	3,10	-	95,25	-	-	0,79	-
Classe 9	-	0,14	-	12,14	-	-	0,01	-	87,71	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,57	-	-	99,43	-
Classe 12	-	1,84	-	-	-	-	-	-	-	-	-	97,22

Decomp. WAVELET
Distância CityblockEficiência de Recup.
90,31CA + Entropia (ca)
1,025

UNIFORMIZADO

WAVELET - 4 Níveis de Dec. - Coef. De Aproximação do 4o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	76,47	0,35	-	-	-	-	-	-	-	23,18	-	-
Classe 2	17,07	61,50	2,64	0,04	-	-	-	-	0,82	11,47	-	6,46
Classe 3	-	0,53	99,42	0,05	-	-	-	-	-	-	-	-
Classe 4	1,19	-	-	98,29	-	-	-	-	-	0,52	-	-
Classe 5	-	-	-	-	88,15	6,83	-	5,02	-	-	-	-
Classe 6	-	-	-	-	6,28	91,15	-	2,57	-	-	-	-
Classe 7	-	-	-	-	-	-	80,04	-	-	19,96	-	-
Classe 8	-	-	-	-	0,55	0,45	-	98,77	-	-	0,23	-
Classe 9	-	-	-	12,03	-	-	0,01	-	87,96	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,07	-	-	98,93	-
Classe 12	-	4,60	-	-	-	-	-	-	-	-	-	94,50

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
89,60

CA + Entropia (ca)
1,025

NORMALIZADO

WAVELET - 5 Níveis de Dec. - Coef. De Aproximação do 5o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	81,09	0,40	-	-	-	-	-	-	-	18,51	-	-
Classe 2	17,58	61,57	3,58	0,11	-	-	-	-	0,86	9,64	-	6,66
Classe 3	-	0,35	99,65	-	-	-	-	-	-	-	-	-
Classe 4	1,58	-	-	98,34	-	-	-	-	-	0,08	-	-
Classe 5	-	-	-	-	87,79	9,16	-	3,05	-	-	-	-
Classe 6	-	-	-	-	6,31	90,58	-	3,11	-	-	-	-
Classe 7	0,15	-	-	-	-	-	94,39	-	-	5,46	-	-
Classe 8	-	-	-	-	1,36	5,74	-	91,52	-	-	1,38	-
Classe 9	-	0,14	-	12,06	-	-	0,24	-	87,56	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,16	-	-	99,84	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância Cyblock

Eficiência de Recup.
90,94

CA + Entropia (ca)
257

img 128 x 128

WAVELET - 5 Níveis de Dec. - Coef. De Aproximação do 5o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	71,74	1,73	-	-	-	-	-	-	-	26,53	-	-
Classe 2	13,32	62,58	2,15	0,11	-	-	-	-	0,86	13,65	-	7,33
Classe 3	-	3,57	96,43	-	-	-	-	-	-	-	-	-
Classe 4	4,31	-	-	95,69	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	83,43	10,30	-	6,27	-	-	-	-
Classe 6	-	-	-	-	7,42	88,80	-	3,78	-	-	-	-
Classe 7	1,40	2,37	-	-	-	-	91,87	-	-	4,36	-	-
Classe 8	-	-	-	-	0,45	1,34	-	97,89	-	-	0,32	-
Classe 9	-	0,88	-	8,53	-	-	0,19	-	90,40	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,03	-	-	99,97	-
Classe 12	-	0,90	-	-	-	-	-	-	-	-	-	98,22

Decomp. WAVELET
Distância Euclidiana

Eficiência de Recup.
89,75

CA + Entropia (ca)
257

WAVELET - 5 Níveis de Dec. - Coef. De Aproximação do 5o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	83,33	0,46	-	-	-	-	-	-	-	16,21	-	-
Classe 2	20,79	58,96	3,92	0,13	-	-	-	-	0,86	6,86	-	8,48
Classe 3	-	0,13	99,87	-	-	-	-	-	-	-	-	-
Classe 4	1,85	-	-	98,08	-	-	-	-	-	0,07	-	-
Classe 5	-	-	-	-	88,93	7,63	-	3,44	-	-	-	-
Classe 6	-	-	-	-	5,57	91,85	-	2,58	-	-	-	-
Classe 7	0,03	-	-	-	-	-	93,26	-	-	6,71	-	-
Classe 8	-	-	-	-	0,64	3,58	-	95,13	-	-	0,65	-
Classe 9	-	0,14	-	12,00	-	-	0,04	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,15	-	-	99,85	-
Classe 12	-	0,31	-	-	-	-	-	-	-	-	-	98,69

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
91,31

CA + Entropia (ca)
257

UNIFORMIZADO

WAVELET - 5 Níveis de Dec. - Coef. De Aproximação do 5o. Nível + Entropia (CA)												
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	83,17	0,58	-	-	-	-	-	-	-	16,25	-	-
Classe 2	20,45	57,41	3,65	0,12	-	-	-	-	0,86	7,11	-	10,40
Classe 3	-	0,26	99,74	-	-	-	-	-	-	-	-	-
Classe 4	1,16	-	-	98,44	-	-	-	-	-	0,40	-	-
Classe 5	-	-	-	-	87,16	7,90	-	4,94	-	-	-	-
Classe 6	-	-	-	-	6,42	91,71	-	1,87	-	-	-	-
Classe 7	-	-	-	-	-	-	90,53	-	-	9,47	-	-
Classe 8	-	-	-	-	0,46	0,69	-	98,51	-	-	0,34	-
Classe 9	-	-	-	11,94	-	-	0,10	-	87,96	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,36	-	-	99,64	-
Classe 12	-	3,14	-	-	-	-	-	-	-	-	-	95,91

Decomp. WAVELET
Distância Cityblock

Eficiência de Recup.
90,85

CA + Entropia (ca)
257

NORMALIZADO

	WAVELET - 6 Níveis de Dec. - Coef. De Aproximação do 6o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	87,90	0,59	-	-	-	-	-	-	-	11,51	-	-
Classe 2	21,75	53,80	4,65	0,07	-	-	-	-	0,63	4,83	-	14,27
Classe 3	-	0,35	99,65	-	-	-	-	-	-	-	-	-
Classe 4	1,71	-	-	98,29	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	87,37	10,03	-	2,60	-	-	-	-
Classe 6	-	-	-	-	6,38	90,75	-	2,87	-	-	-	-
Classe 7	-	-	-	-	-	-	97,71	-	-	2,29	-	-
Classe 8	-	-	-	-	0,91	6,60	-	91,57	-	-	0,92	-
Classe 9	-	0,14	0,12	12,04	-	-	-	-	87,70	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância CyblockEficiência de Recup.
91,15CA + Entropia (ca)
65

img 128 x 128

**MELHOR
RESULTADO**

	WAVELET - 6 Níveis de Dec. - Coef. De Aproximação do 6o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	84,04	0,90	-	-	-	-	-	-	-	15,06	-	-
Classe 2	19,19	54,65	3,39	-	-	-	-	-	0,86	7,47	-	14,44
Classe 3	-	2,89	97,11	-	-	-	-	-	-	-	-	-
Classe 4	3,82	-	-	95,91	-	-	-	-	0,27	-	-	-
Classe 5	-	-	-	-	81,32	12,19	-	6,49	-	-	-	-
Classe 6	-	-	-	-	7,24	89,33	-	3,43	-	-	-	-
Classe 7	0,48	-	-	-	-	-	99,35	-	-	0,17	-	-
Classe 8	-	-	-	-	0,82	4,04	-	95,05	-	-	0,09	-
Classe 9	-	0,67	-	9,52	-	-	-	-	89,81	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	0,19	-	-	-	-	-	-	-	-	-	98,85

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
90,45CA + Entropia (ca)
65

	WAVELET - 6 Níveis de Dec. - Coef. De Aproximação do 6o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	87,24	1,13	-	-	-	-	-	-	-	11,63	-	-
Classe 2	25,92	51,82	5,49	-	-	-	-	-	0,48	0,83	-	15,46
Classe 3	-	0,28	99,72	-	-	-	-	-	-	-	-	-
Classe 4	2,10	-	-	97,90	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	87,93	8,67	-	3,40	-	-	-	-
Classe 6	-	-	-	-	6,02	91,79	-	2,19	-	-	-	-
Classe 7	-	-	-	-	-	-	97,41	-	-	2,59	-	-
Classe 8	-	-	-	-	0,90	4,42	-	94,23	-	-	0,45	-
Classe 9	-	0,14	0,50	12,04	-	-	-	-	87,32	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	1,08	-	-	-	-	-	-	-	-	-	97,98

Decomp. WAVELET
Distância CyblockEficiência de Recup.
91,11CA + Entropia (ca)
65

img 128 x 128

UNIFORMIZADO
MELHOR
RESULTADO

	WAVELET - 6 Níveis de Dec. - Coef. De Aproximação do 6o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	84,04	0,90	-	-	-	-	-	-	-	15,06	-	-
Classe 2	19,19	54,65	3,39	-	-	-	-	-	0,86	7,47	-	14,44
Classe 3	-	2,89	97,11	-	-	-	-	-	-	-	-	-
Classe 4	3,82	-	-	95,91	-	-	-	-	0,27	-	-	-
Classe 5	-	-	-	-	81,32	12,19	-	6,49	-	-	-	-
Classe 6	-	-	-	-	7,24	89,33	-	3,43	-	-	-	-
Classe 7	0,48	-	-	-	-	-	99,35	-	-	0,17	-	-
Classe 8	-	-	-	-	0,82	4,04	-	95,05	-	-	0,09	-
Classe 9	-	0,67	-	9,52	-	-	-	-	89,81	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	0,19	-	-	-	-	-	-	-	-	-	98,85

Decomp. WAVELET
Distância CityblockEficiência de Recup.
90,45CA + Entropia (ca)
65NORMALIZADO
MELHOR
RESULTADO

	WAVELET - 7 Níveis de Dec. - Coef. De Aproximação do 7o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	84,98	4,88	-	-	-	-	0,15	-	-	9,99	-	-
Classe 2	18,45	47,25	5,10	-	-	-	9,84	-	0,81	-	-	18,55
Classe 3	-	1,44	96,35	0,74	-	-	-	-	-	-	-	1,47
Classe 4	0,52	-	-	98,08	-	-	1,40	-	-	-	-	-
Classe 5	-	-	-	-	80,52	10,04	-	9,32	-	-	0,12	-
Classe 6	-	-	-	-	7,40	87,39	-	4,55	-	-	0,66	-
Classe 7	0,18	0,10	-	-	-	-	99,72	-	-	-	-	-
Classe 8	-	-	-	-	8,87	6,58	-	83,67	-	-	0,88	-
Classe 9	-	0,14	1,48	12,04	-	-	-	-	86,34	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	0,05	-	0,04	-	-	99,91	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância CyblockEficiência de Recup.
88,60CA + Entropia (ca)
17

img 128 x 128

	WAVELET - 7 Níveis de Dec. - Coef. De Aproximação do 7o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	85,37	3,46	-	-	-	-	0,18	-	-	10,99	-	-
Classe 2	17,16	49,65	4,88	-	-	-	9,34	-	0,86	-	-	18,11
Classe 3	-	3,15	96,61	-	-	-	-	-	0,11	-	-	0,13
Classe 4	-	-	-	94,02	-	-	5,98	-	-	-	-	-
Classe 5	-	-	-	-	77,91	11,73	-	10,26	-	-	0,10	-
Classe 6	-	-	-	-	8,09	88,67	-	2,46	-	-	0,78	-
Classe 7	0,78	0,23	-	-	-	-	98,95	-	-	0,04	-	-
Classe 8	-	-	-	-	9,49	5,61	-	84,17	-	-	0,73	-
Classe 9	-	1,00	0,95	10,74	-	-	-	87,31	-	-	-	-
Classe 10	-	-	-	-	-	-	-	-	100,00	-	-	-
Classe 11	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET
Distância EuclidianaEficiência de Recup.
88,47CA + Entropia (ca)
17

	WAVELET - 7 Níveis de Dec. - Coef. De Aproximação do 7o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	78,13	7,72	-	-	-	-	1,60	-	-	12,55	-	-
Classe 2	20,79	47,62	6,65	-	-	-	5,35	-	0,23	-	-	19,36
Classe 3	-	1,84	95,16	0,12	-	-	-	-	-	-	-	2,88
Classe 4	2,98	-	-	93,98	-	-	3,04	-	-	-	-	-
Classe 5	-	-	-	-	79,10	8,13	-	12,71	-	-	0,06	-
Classe 6	-	-	-	-	5,78	88,88	-	4,83	-	-	0,51	-
Classe 7	0,02	-	-	-	-	-	99,98	-	-	-	-	-
Classe 8	-	-	-	-	8,98	6,07	-	84,27	-	-	0,68	-
Classe 9	-	0,14	3,28	12,04	-	-	-	83,26	-	-	-	1,28
Classe 10	-	-	-	-	-	-	-	-	100,00	-	-	-
Classe 11	-	-	-	-	-	0,06	-	0,01	-	-	99,93	-
Classe 12	-	0,11	0,57	-	-	-	-	-	-	-	-	98,32

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,39CA + Entropia (ca)
17

img 128 x 128

UNIFORMIZADO

	WAVELET - 7 Níveis de Dec. - Coef. De Aproximação do 7o. Nível + Entropia (CA)											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe1	78,43	8,22	-	-	-	-	1,48	-	-	11,87	-	-
Classe 2	21,05	47,50	6,55	-	-	-	5,21	-	0,25	-	-	19,44
Classe 3	-	2,04	94,42	0,45	-	-	-	-	-	-	-	3,09
Classe 4	4,24	-	-	94,20	-	-	1,56	-	-	-	-	-
Classe 5	-	-	-	-	76,44	7,97	-	15,54	-	-	0,05	-
Classe 6	-	-	-	-	6,57	88,98	-	3,54	-	-	0,91	-
Classe 7	0,05	0,16	-	-	-	-	99,79	-	-	-	-	-
Classe 8	-	-	-	-	8,24	4,10	-	87,01	-	-	0,65	-
Classe 9	-	0,14	2,60	12,04	-	-	-	84,66	-	-	-	0,56
Classe 10	-	-	-	-	-	-	-	-	100,00	-	-	-
Classe 11	-	-	-	-	-	0,10	-	0,07	-	-	99,83	-
Classe 12	-	0,76	0,53	-	-	-	-	-	-	-	-	97,71

Decomp. WAVELET
Distância CityblockEficiência de Recup.
87,41CA + Entropia (ca)
17

NORMALIZADO

	Transf. Wavelet Packet - 5 Níveis de Dec. - Coeficientes de Aproximação + Entropia (nós finais do 5o. Nível) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	52,28	-	-	-	-	-	47,72	-	-	-	-	-
Classe 2	-	100,00	-	-	-	-	-	-	-	-	-	-
Classe 3	-	-	99,98	-	-	-	-	0,02	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	91,51	6,67	-	1,78	-	-	0,04	-
Classe 6	-	-	-	-	8,21	88,50	-	1,05	-	-	2,24	-
Classe 7	0,16	-	-	-	-	-	96,60	-	3,24	-	-	-
Classe 8	-	-	-	-	3,47	5,01	-	80,42	-	-	11,10	-
Classe 9	-	-	-	-	-	-	11,02	-	88,98	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,13	-	3,78	11,02	-	9,65	-	-	75,42	-
Classe 12	0,07	-	-	-	0,63	-	-	-	-	-	-	98,30

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
89,33

CA + E
1,280
16 x 16 + 1024 vls de Entropia
NORMALIZADO

	Transf. Wavelet Packet - 5 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	89,82	-	-	-	-	-	10,18	-	-	-	-	-
Classe 2	2,44	97,52	-	-	-	-	-	-	0,04	-	-	-
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	93,19	4,98	-	1,83	-	-	-	-
Classe 6	-	-	-	-	1,74	95,75	-	2,50	-	-	0,01	-
Classe 7	0,12	-	-	-	-	-	99,88	-	-	-	-	-
Classe 8	-	-	-	-	9,92	3,51	-	78,28	-	-	8,29	-
Classe 9	-	0,14	-	-	-	-	12,04	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	7,18	-	8,86	-	-	83,96	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
93,77

CA + Eall
1,621
16 x 16 + 1365 vls de Entropia

**3o. Melhor resultado
dos testes com a TWP**

	Transf. Wavelet Packet - 5 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	54,19	-	-	-	-	-	45,81	-	-	-	-	-
Classe 2	-	100,00	-	-	-	-	-	-	-	-	-	-
Classe 3	-	-	99,93	-	-	-	-	0,07	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	91,30	7,20	-	1,35	-	-	0,15	-
Classe 6	-	-	-	-	8,06	86,83	-	1,14	-	-	3,97	-
Classe 7	-	-	-	-	-	-	94,53	-	5,47	-	-	-
Classe 8	-	-	0,02	-	2,94	5,23	-	80,42	-	-	11,39	-
Classe 9	-	-	-	-	-	-	13,78	-	86,22	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,33	-	4,57	11,04	-	9,24	-	-	74,82	-
Classe 12	0,03	-	-	-	0,22	0,10	-	-	-	-	-	98,65

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
88,91

CA + Eall
1,621
16 x 16 + 1365 vls de Entropia
UNIFORMIZADO

	Transf. Wavelet Packet - 5 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	54,04	-	-	-	-	-	45,96	-	-	-	-	-
Classe 2	-	100,00	-	-	-	-	-	-	-	-	-	-
Classe 3	-	-	99,75	-	0,01	-	-	0,22	-	-	0,02	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	91,10	7,07	-	1,66	-	-	0,17	-
Classe 6	-	-	-	-	8,15	86,95	-	1,20	-	-	3,70	-
Classe 7	-	-	-	-	-	-	94,70	-	5,30	-	-	-
Classe 8	-	-	0,07	-	2,90	4,26	-	80,42	-	-	12,35	-
Classe 9	-	-	-	-	-	-	12,64	-	87,36	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,77	-	4,16	10,80	-	9,49	-	-	74,78	-
Classe 12	0,13	-	-	-	1,06	2,13	-	-	-	-	-	95,68

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
88,73

CA + Eall
1,621
16 x 16 + 1365 vls de Entropia
NORMALIZADO

	Transf. Wavelet Packet - 4 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	95,75	0,30	-	-	-	-	3,95	-	-	-	-	-
Classe 2	18,58	81,20	-	-	-	-	-	-	0,13	-	-	0,09
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	92,52	5,40	-	2,08	-	-	-	-
Classe 6	-	-	-	-	3,33	93,55	-	3,12	-	-	-	-
Classe 7	0,42	-	-	-	-	-	99,58	-	-	-	-	-
Classe 8	-	-	-	-	10,49	3,63	-	79,05	-	-	6,83	-
Classe 9	-	0,14	-	-	-	-	12,04	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	1,29	-	5,38	-	-	93,33	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
93,48

CA + Eall
1,365
32 x 32 + 341 vls de Entropia

**4o. Melhor resultado
dos testes com a TWP**

	Transf. Wavelet Packet - 4 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	98,27	-	-	-	-	-	1,73	-	-	-	-	-
Classe 2	11,95	87,92	-	-	-	-	-	-	0,13	-	-	-
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	93,66	5,17	-	1,17	-	-	-	-
Classe 6	-	-	-	-	3,80	93,30	-	2,90	-	-	-	-
Classe 7	1,31	-	-	-	-	-	98,69	-	-	-	-	-
Classe 8	-	-	-	-	9,21	2,27	-	81,20	-	-	7,32	-
Classe 9	-	-	-	0,08	-	-	9,07	-	90,85	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	1,53	-	6,32	-	-	92,15	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
94,59

CA + Eall
1.365
32 x 32 + 341 vls de Entropia
UNIFORMIZADO

	Transf. Wavelet Packet - 4 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	98,49	-	-	-	-	-	1,51	-	-	-	-	-
Classe 2	15,43	84,40	-	-	-	-	-	-	0,16	-	-	0,01
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	91,72	5,52	-	2,76	-	-	-	-
Classe 6	-	-	-	-	4,63	93,28	-	2,09	-	-	-	-
Classe 7	2,14	-	-	-	-	-	97,86	-	-	-	-	-
Classe 8	-	-	-	-	8,47	1,03	-	84,23	-	-	6,27	-
Classe 9	-	-	-	-	-	-	8,33	-	91,67	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	1,15	-	6,07	-	-	92,78	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
94,45

CA + Eall
1.365
32 x 32 + 341 vls de Entropia
NORMALIZADO

	Transf. Wavelet Packet - 3 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	95,72	1,00	-	-	-	-	3,28	-	-	-	-	-
Classe 2	24,89	74,19	-	-	-	-	-	-	0,28	-	-	0,64
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	90,64	5,92	-	3,44	-	-	-	-
Classe 6	-	-	-	-	5,04	90,34	-	4,62	-	-	-	-
Classe 7	1,23	-	-	-	-	-	98,77	-	-	-	-	-
Classe 8	-	-	-	-	4,94	3,86	-	87,10	-	-	4,10	-
Classe 9	-	0,14	-	4,56	-	-	7,48	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,84	-	-	98,16	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
93,48

CA + Eall
4.181
64 x 64 + 85 vls de Entropia

**5o. Melhor resultado
dos testes com a TWP**

	Transf. Wavelet Packet - 3 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	90,30	0,09	-	-	-	-	-	-	-	9,61	-	-
Classe 2	23,57	68,66	1,03	0,01	-	-	-	-	0,85	3,93	-	1,95
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	1,09	-	-	98,76	-	-	-	-	-	0,15	-	-
Classe 5	-	-	-	-	90,84	5,86	-	3,30	-	-	-	-
Classe 6	-	-	-	-	5,37	89,88	-	4,75	-	-	-	-
Classe 7	4,16	-	-	-	-	-	93,90	-	-	1,94	-	-
Classe 8	-	-	-	-	1,47	3,17	-	93,97	-	-	1,39	-
Classe 9	-	0,13	-	11,96	-	-	0,20	-	87,71	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,03	-	-	98,97	-
Classe 12	-	1,78	-	-	-	-	-	-	-	-	-	97,22

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
92,52

CA + Eall
4.181
64 x 64 + 85 vls de Entropia
UNIFORMIZADO

	Transf. Wavelet Packet - 3 Níveis de Dec. - Coeficientes de Aproximação + Entropia (todos os nós) - Log Energy											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	89,19	0,12	-	-	-	-	-	-	-	10,69	-	-
Classe 2	22,90	67,15	0,87	-	-	-	-	-	0,85	4,53	-	3,70
Classe 3	-	0,16	99,84	-	-	-	-	-	-	-	-	-
Classe 4	0,86	-	-	98,99	-	-	-	-	-	0,15	-	-
Classe 5	-	-	-	-	88,97	5,97	-	5,06	-	-	-	-
Classe 6	-	-	-	-	6,12	90,22	-	3,66	-	-	-	-
Classe 7	3,03	-	-	-	-	-	91,28	-	-	5,69	-	-
Classe 8	-	-	-	-	1,02	0,42	-	98,27	-	-	0,29	-
Classe 9	-	-	-	11,98	-	-	0,06	-	87,96	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	1,50	-	-	98,50	-
Classe 12	-	4,37	-	-	-	-	-	-	-	-	-	94,69

Decomp. WAVELET PACKET
Distância Cityblock

Eficiência de Recup.
92,09

CA + Eall
4.181
64 x 64 + 85 vls de Entropia
NORMALIZADO

APÊNDICE F – Matrizes de confusão obtidas com o algoritmo *Best Tree* após decomposição com a Transformada *Wavelet Packet* usando Entropia de Shannon e *Log Energy*.

	BEST TREE - 2 Níveis de Dec. - CA Integral + Entropia dos nós do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	51,06	17,56	-	3,71	-	-	8,97	-	-	18,70	-	-
Classe 2	20,50	31,97	2,95	3,54	-	-	3,51	5,22	18,48	-	-	13,83
Classe 3	-	3,58	33,31	-	22,34	-	-	19,44	3,80	-	0,02	17,51
Classe 4	7,12	2,29	-	51,45	-	-	36,93	-	2,21	-	-	-
Classe 5	-	-	13,85	-	58,83	4,45	-	12,10	-	-	10,77	-
Classe 6	-	-	-	-	3,70	57,69	-	0,80	-	-	37,81	-
Classe 7	5,74	0,75	-	18,42	-	-	75,09	-	-	-	-	-
Classe 8	-	1,00	2,91	-	12,24	1,06	-	63,87	-	-	2,56	16,36
Classe 9	-	14,41	3,64	-	-	-	-	1,03	70,72	-	-	10,20
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	9,29	43,34	-	2,23	-	-	45,14	-
Classe 12	-	14,89	10,77	-	-	-	-	24,74	11,67	-	-	37,71

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
16400
Eficiência de Recup.
56,40

	BEST TREE - 2 Níveis de Dec. - CA Integral + Entropia dos nós do 2o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	82,52	0,11	-	-	-	-	-	-	-	17,37	-	-
Classe 2	14,65	66,05	2,26	-	-	-	-	-	0,84	14,07	-	2,13
Classe 3	-	0,63	98,75	0,02	-	-	-	-	0,60	-	-	-
Classe 4	0,16	-	-	98,67	-	-	-	-	-	1,17	-	-
Classe 5	-	-	-	-	89,19	6,29	-	4,52	-	-	-	-
Classe 6	-	-	-	-	6,63	87,70	-	5,67	-	-	-	-
Classe 7	1,45	-	-	-	-	-	93,11	-	-	5,44	-	-
Classe 8	-	-	-	-	3,04	4,37	-	91,32	-	-	1,27	-
Classe 9	-	0,13	-	13,31	-	-	0,12	-	86,44	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,69	-	-	99,31	-
Classe 12	-	0,66	-	-	-	-	-	-	-	-	-	98,34

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
16400
Eficiência de Recup.
90,95

	BEST TREE - 3 Níveis de Dec. - CA Integral + Entropia dos nós do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	51,55	16,95	-	3,64	-	-	8,71	-	-	19,15	-	-
Classe 2	20,24	32,06	2,86	3,13	-	-	4,19	5,31	18,46	-	-	13,75
Classe 3	-	4,74	33,64	-	21,76	-	-	18,63	3,66	-	-	17,57
Classe 4	7,10	2,76	-	56,72	-	-	30,58	-	2,84	-	-	-
Classe 5	-	-	12,57	-	59,83	4,13	-	11,60	-	-	11,87	-
Classe 6	-	-	-	-	3,17	56,85	-	0,86	-	-	39,12	-
Classe 7	3,94	0,86	-	15,94	-	-	79,26	-	-	-	-	-
Classe 8	-	0,56	2,17	-	11,59	1,38	-	64,49	-	-	3,34	16,47
Classe 9	-	14,59	2,83	-	-	-	-	1,01	70,29	-	-	11,28
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	9,26	43,22	-	2,49	-	-	45,03	-
Classe 12	-	14,71	7,83	-	-	-	-	25,80	11,76	-	-	39,71

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
4160
Eficiência de Recup.
57,45

	BEST TREE - 3 Níveis de Dec. - CA Integral + Entropia dos nós do 3o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	70,71	0,26	-	-	-	-	-	-	-	29,03	-	-
Classe 2	17,62	65,56	2,77	-	-	-	-	-	0,86	10,41	-	2,78
Classe 3	-	0,65	99,10	0,17	-	-	-	-	0,08	-	-	-
Classe 4	1,64	-	-	98,28	-	-	-	-	-	0,08	-	-
Classe 5	-	-	-	-	88,68	7,07	-	4,25	-	-	-	-
Classe 6	-	-	-	-	6,95	87,81	-	5,24	-	-	-	-
Classe 7	-	-	-	-	-	-	84,41	-	-	15,59	-	-
Classe 8	-	-	-	-	2,66	4,45	-	91,55	-	-	1,34	-
Classe 9	-	0,12	-	13,90	-	-	0,08	-	85,90	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,59	-	-	99,41	-
Classe 12	-	0,70	-	-	-	-	-	-	-	-	-	98,30

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
4160
Eficiência de Recup.
89,14

	BEST TREE - 4 Níveis de Dec. - CA Integral + Entropia dos nós do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	51,67	16,51	-	3,62	-	-	8,53	-	-	19,67	-	-
Classe 2	19,30	31,96	3,48	2,48	-	-	5,99	5,04	18,28	-	-	13,47
Classe 3	-	5,22	31,77	-	21,70	-	-	18,38	4,00	-	-	18,93
Classe 4	4,67	3,23	-	57,50	-	-	31,66	-	2,94	-	-	-
Classe 5	-	-	14,27	-	59,24	3,83	-	10,20	-	-	12,46	-
Classe 6	-	-	-	-	2,83	56,07	-	1,13	-	-	39,97	-
Classe 7	2,18	2,15	-	21,02	-	-	74,65	-	-	-	-	-
Classe 8	-	-	3,02	-	10,09	1,78	-	64,24	-	-	4,63	16,24
Classe 9	-	14,44	3,39	-	-	-	-	1,37	69,09	-	-	11,71
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	9,38	42,77	-	3,15	-	-	44,70	-
Classe 12	-	14,13	9,46	-	-	-	-	27,12	11,89	-	-	37,21

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
1280
Eficiência de Recup.
56,51

	BEST TREE - 4 Níveis de Dec. - CA Integral + Entropia dos nós do 4o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	74,33	0,28	-	-	-	-	-	-	-	25,39	-	-
Classe 2	15,70	63,96	3,22	0,01	-	-	-	-	0,86	12,25	-	4,00
Classe 3	-	0,80	99,20	-	-	-	-	-	-	-	-	-
Classe 4	1,44	-	-	98,31	-	-	-	-	-	0,25	-	-
Classe 5	-	-	-	-	88,49	7,96	-	3,55	-	-	-	-
Classe 6	-	-	-	-	6,59	89,27	-	4,14	-	-	-	-
Classe 7	-	-	-	-	-	-	88,36	-	-	11,64	-	-
Classe 8	-	-	-	-	2,20	4,82	-	91,57	-	-	1,41	-
Classe 9	-	0,14	-	13,28	-	-	0,06	-	86,52	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,49	-	-	99,51	-
Classe 12	-	0,53	-	-	-	-	-	-	-	-	-	98,47

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
1280

Eficiência de Recup.
89,83

	BEST TREE - 5 Níveis de Dec. - CA Integral + Entropia dos nós do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	51,47	14,69	-	2,79	-	-	9,79	-	-	21,26	-	-
Classe 2	16,65	32,63	4,34	2,37	-	-	8,51	5,10	17,23	-	-	13,17
Classe 3	-	5,04	31,98	-	20,96	-	-	18,76	4,59	-	0,02	18,65
Classe 4	1,23	3,85	-	60,77	-	-	31,88	-	2,27	-	-	-
Classe 5	-	-	16,02	-	57,95	3,00	-	8,87	-	-	14,16	-
Classe 6	-	-	-	-	2,44	58,85	-	1,99	-	-	36,72	-
Classe 7	2,62	4,69	-	20,02	-	-	72,67	-	-	-	-	-
Classe 8	-	-	6,10	-	8,50	2,71	-	64,32	-	-	5,39	12,98
Classe 9	-	11,73	4,22	-	-	-	-	0,80	65,95	-	-	17,30
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	11,30	37,56	-	4,22	-	-	46,92	-
Classe 12	-	10,28	11,16	-	-	-	-	27,49	15,14	-	-	35,78

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
1280

Eficiência de Recup.
56,61

	BEST TREE - 5 Níveis de Dec. - CA Integral + Entropia dos nós do 5o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	81,16	0,40	-	-	-	-	-	-	-	18,44	-	-
Classe 2	17,74	61,57	3,58	0,11	-	-	-	-	0,86	9,48	-	6,66
Classe 3	-	0,35	99,65	-	-	-	-	-	-	-	-	-
Classe 4	1,59	-	-	98,34	-	-	-	-	-	0,07	-	-
Classe 5	-	-	-	-	87,79	9,16	-	3,05	-	-	-	-
Classe 6	-	-	-	-	6,31	90,61	-	3,08	-	-	-	-
Classe 7	0,16	-	-	-	-	-	94,40	-	-	5,44	-	-
Classe 8	-	-	-	-	1,36	5,74	-	91,54	-	-	1,36	-
Classe 9	-	0,14	-	12,08	-	-	0,23	-	87,55	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,16	-	-	99,84	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
1280

Eficiência de Recup.
90,95

	BEST TREE - 6 Níveis de Dec. - CA Integral + Entropia dos nós do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	53,18	13,90	-	2,48	-	-	7,91	-	-	22,53	-	-
Classe 2	13,09	32,03	3,53	3,10	-	-	11,17	4,75	20,87	-	-	11,46
Classe 3	-	4,63	34,08	-	21,97	-	-	18,10	5,47	-	0,20	15,55
Classe 4	0,04	1,78	-	64,35	-	-	33,23	-	0,60	-	-	-
Classe 5	-	-	19,99	-	51,99	2,06	-	7,21	1,79	-	15,57	1,39
Classe 6	-	-	-	-	2,22	59,73	-	2,94	-	-	35,11	-
Classe 7	2,97	7,30	-	18,88	-	-	70,85	-	-	-	-	-
Classe 8	-	-	2,90	-	7,04	2,90	-	64,38	-	-	6,38	16,40
Classe 9	-	10,15	5,44	-	0,78	-	-	0,53	61,62	-	-	21,48
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,11	-	13,44	31,41	-	6,31	-	-	48,73	-
Classe 12	-	6,76	9,72	-	-	-	-	31,87	18,12	-	-	33,35

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
4160

Eficiência de Recup.
56,19

	BEST TREE - 6 Níveis de Dec. - CA Integral + Entropia dos nós do 6o. Nível											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	87,91	0,59	-	-	-	-	-	-	-	11,50	-	-
Classe 2	21,76	53,80	4,65	0,07	-	-	-	-	0,66	4,82	-	14,24
Classe 3	-	0,26	99,74	-	-	-	-	-	-	-	-	-
Classe 4	1,71	-	-	98,29	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	87,37	10,03	-	2,60	-	-	-	-
Classe 6	-	-	-	-	6,38	90,75	-	2,87	-	-	-	-
Classe 7	-	-	-	-	-	-	97,71	-	-	2,29	-	-
Classe 8	-	-	-	-	0,91	6,60	-	91,57	-	-	0,92	-
Classe 9	-	0,14	0,11	12,04	-	-	-	-	87,71	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	-	-	-	100,00	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
4160

Eficiência de Recup.
91,15

	BEST TREE - 2 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	50,47	18,00	-	3,79	-	-	9,09	-	-	18,65	-	-
Classe 2	20,91	32,01	2,73	3,72	-	-	2,89	5,10	18,71	-	-	13,93
Classe 3	-	3,20	31,82	-	23,46	0,09	-	18,79	4,27	-	0,02	18,35
Classe 4	7,05	2,19	-	49,13	-	-	39,92	-	1,71	-	-	-
Classe 5	-	-	17,25	-	57,28	4,69	-	11,44	-	-	9,34	-
Classe 6	-	-	0,02	-	3,91	55,74	-	0,82	-	-	39,51	-
Classe 7	6,28	0,58	-	20,02	-	-	73,12	-	-	-	-	-
Classe 8	-	1,10	3,33	-	12,09	0,96	-	63,55	-	-	2,25	16,72
Classe 9	-	14,49	4,02	-	-	-	-	1,43	70,64	-	-	9,42
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,01	-	8,65	45,36	-	1,96	-	-	44,02	-
Classe 12	-	14,90	11,50	-	-	-	-	26,90	11,62	-	-	34,86

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
16405

Eficiência de Recup.
55,22

	BEST TREE - 2 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	86,61	0,49	-	-	-	-	-	-	-	12,90	-	-
Classe 2	16,85	69,82	0,69	-	-	-	-	-	0,70	9,89	-	2,05
Classe 3	-	0,23	99,77	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	98,41	-	-	-	-	-	1,59	-	-
Classe 5	-	-	-	-	89,38	6,18	-	4,44	-	-	-	-
Classe 6	-	-	-	-	6,22	88,28	-	5,50	-	-	-	-
Classe 7	1,28	-	-	-	-	-	95,72	-	-	3,00	-	-
Classe 8	-	-	-	-	3,64	4,30	-	90,54	-	-	1,52	-
Classe 9	-	0,14	-	12,44	-	-	0,26	-	87,16	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,69	-	-	99,31	-
Classe 12	-	0,21	-	-	-	-	-	-	-	-	-	98,79

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
16405

Eficiência de Recup.
91,98

	BEST TREE - 3 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	50,84	17,74	-	3,69	-	-	9,04	-	-	18,69	-	-
Classe 2	20,78	31,98	2,57	3,50	-	-	3,30	5,27	18,65	-	-	13,95
Classe 3	-	3,52	32,14	-	23,16	0,01	-	19,38	3,95	-	0,02	17,82
Classe 4	7,11	2,24	-	50,94	-	-	37,63	-	2,08	-	-	-
Classe 5	-	-	15,75	-	57,90	4,54	-	11,66	-	-	10,15	-
Classe 6	-	-	-	-	3,74	56,04	-	0,82	-	-	39,40	-
Classe 7	5,72	0,64	-	18,95	-	-	74,69	-	-	-	-	-
Classe 8	-	0,96	2,84	-	12,03	1,07	-	63,70	-	-	2,53	16,87
Classe 9	-	14,53	3,92	-	-	-	-	1,17	70,56	-	-	9,82
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	8,72	44,86	-	2,14	-	-	44,28	-
Classe 12	-	14,87	10,97	-	-	-	-	26,42	11,70	-	-	35,82

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
4181

Eficiência de Recup.
55,74

tempo
1200

	BEST TREE - 3 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	93,49	0,90	-	-	-	-	0,98	-	-	4,63	-	-
Classe 2	24,15	70,55	0,19	-	-	-	-	-	0,47	1,88	-	2,76
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	99,29	-	-	-	-	-	0,71	-	-
Classe 5	-	-	-	-	89,96	6,16	-	3,88	-	-	-	-
Classe 6	-	-	-	-	5,35	90,00	-	4,65	-	-	-	-
Classe 7	1,53	-	-	-	-	-	98,26	-	-	0,21	-	-
Classe 8	-	-	-	-	3,99	4,41	-	89,62	-	-	1,98	-
Classe 9	-	0,14	-	7,38	-	-	4,68	-	87,80	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,70	-	-	99,30	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
4181

Eficiência de Recup.
93,11

tempo
1760,5
29,34167 min

	BEST TREE - 4 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	51,31	17,24	-	3,69	-	-	8,86	-	-	19,00	-	-
Classe 2	20,56	32,05	2,45	3,44	-	-	3,58	5,34	18,69	-	-	13,89
Classe 3	-	3,75	32,52	-	23,16	-	-	19,25	3,77	-	0,02	17,53
Classe 4	6,59	2,47	-	52,40	-	-	36,45	-	2,09	-	-	-
Classe 5	-	-	15,89	-	58,23	4,37	-	11,27	-	-	10,24	-
Classe 6	-	-	-	-	3,54	56,04	-	0,86	-	-	39,56	-
Classe 7	5,03	0,77	-	18,40	-	-	75,80	-	-	-	-	-
Classe 8	-	0,41	2,68	-	11,65	1,30	-	64,19	-	-	2,83	16,94
Classe 9	-	14,50	3,74	-	-	-	-	1,34	70,46	-	-	9,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	8,72	44,54	-	2,22	-	-	44,52	-
Classe 12	-	14,66	10,07	-	-	-	-	27,32	11,82	-	-	35,91

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
1365

Eficiência de Recup.
56,12

	BEST TREE - 4 Níveis de Dec. - CA + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	93,62	2,12	-	-	-	-	4,26	-	-	-	-	-
Classe 2	25,09	70,62	0,05	-	-	-	-	-	0,14	0,05	-	4,05
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	99,91	-	-	-	-	-	0,09	-	-
Classe 5	-	-	-	-	90,75	6,28	-	2,97	-	-	-	-
Classe 6	-	-	-	-	4,13	92,64	-	3,23	-	-	-	-
Classe 7	0,57	-	-	-	-	-	99,43	-	-	-	-	-
Classe 8	-	-	-	-	4,91	4,46	-	87,85	-	-	2,78	-
Classe 9	-	0,14	-	4,13	-	-	7,91	-	87,82	-	-	-
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	-	-	0,93	-	-	99,07	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
1365

Eficiência de Recup.
93,39

	BEST TREE - 5 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	51,15	17,01	-	3,01	-	-	9,32	-	-	19,51	-	-
Classe 2	20,20	32,16	2,66	3,63	-	-	3,79	5,36	18,58	-	-	13,62
Classe 3	-	3,76	33,00	-	23,03	-	-	18,64	3,69	-	0,04	17,84
Classe 4	4,34	2,56	-	54,17	-	-	36,89	-	2,04	-	-	-
Classe 5	-	-	16,36	-	58,40	4,03	-	10,48	-	-	10,73	-
Classe 6	-	-	-	-	3,29	57,49	-	0,95	-	-	38,27	-
Classe 7	3,85	1,26	-	17,55	-	-	77,34	-	-	-	-	-
Classe 8	-	-	2,67	-	11,22	1,53	-	64,85	-	-	3,14	16,59
Classe 9	-	14,02	3,90	-	-	-	-	1,08	70,52	-	-	10,48
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	9,35	42,63	-	1,87	-	-	46,15	-
Classe 12	-	13,65	9,38	-	-	-	-	28,47	12,36	-	-	35,94

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
1621

Eficiência de Recup.
56,76

	BEST TREE - 5 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	87,52	4,59	-	-	-	-	7,89	-	-	-	-	-
Classe 2	22,95	70,98	-	-	-	-	-	-	0,14	-	-	5,93
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	90,75	6,22	-	3,03	-	-	-	-
Classe 6	-	-	-	-	2,48	94,86	-	2,66	-	-	-	-
Classe 7	0,04	-	-	-	-	-	99,96	-	-	-	-	-
Classe 8	-	-	-	-	9,01	4,84	-	82,31	-	-	3,84	-
Classe 9	-	0,16	-	-	-	-	12,04	-	80,66	-	-	7,14
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	1,25	-	1,21	-	-	97,54	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
1621

Eficiência de Recup.
91,97

	BEST TREE - 6 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	51,76	16,67	-	2,63	-	-	9,37	-	-	19,57	-	-
Classe 2	19,85	32,50	2,69	3,70	-	-	3,95	5,02	18,64	-	-	13,65
Classe 3	-	3,80	33,90	-	22,71	-	-	18,29	3,69	-	0,16	17,45
Classe 4	1,84	2,42	-	56,38	-	-	37,84	-	1,52	-	-	-
Classe 5	-	-	17,96	-	57,77	3,41	-	9,52	-	-	11,34	-
Classe 6	-	-	-	-	3,14	58,34	-	1,06	-	-	37,46	-
Classe 7	0,73	1,37	-	18,51	-	-	79,39	-	-	-	-	-
Classe 8	-	-	2,85	-	10,37	1,87	-	64,87	-	-	3,45	16,59
Classe 9	-	13,46	4,25	-	-	-	-	1,49	71,51	-	-	9,29
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	0,02	-	10,46	38,28	-	1,58	-	-	49,66	-
Classe 12	-	13,02	9,36	-	-	-	-	30,37	12,23	-	-	34,82

Decomp. WAVELET PACKET
Entropia SHANNON
Algoritmo BEST TREE
5525

Eficiência de Recup.
57,58

	BEST TREE - 6 Níveis de Dec. - CA Integral + Entropia de todos os nós											
	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Classe 1	77,88	6,32	-	-	-	-	15,80	-	-	-	-	-
Classe 2	18,76	71,21	-	-	-	-	-	-	0,14	-	-	9,89
Classe 3	-	-	100,00	-	-	-	-	-	-	-	-	-
Classe 4	-	-	-	100,00	-	-	-	-	-	-	-	-
Classe 5	-	-	-	-	89,88	5,29	-	4,83	-	-	-	-
Classe 6	-	-	-	-	1,14	95,41	-	3,38	-	-	0,07	-
Classe 7	-	-	-	-	-	-	100,00	-	-	-	-	-
Classe 8	-	-	-	-	11,43	5,09	-	78,73	-	-	4,75	-
Classe 9	-	2,47	-	-	-	-	12,04	-	76,53	-	-	8,96
Classe 10	-	-	-	-	-	-	-	-	-	100,00	-	-
Classe 11	-	-	-	-	-	6,08	-	2,67	-	-	91,25	-
Classe 12	-	-	-	-	-	-	-	-	-	-	-	99,00

Decomp. WAVELET PACKET
Entropia LOG ENERGY
Algoritmo BEST TREE
5525

Eficiência de Recup.
89,99