

Estudo Comparativo de Transformadas Wavelets para Descrição de Texturas

Ricardo Dutra da Silva Hélio Pedrini
Instituto de Computação - Universidade Estadual de Campinas
Campinas, SP, Brasil, 13084-971

William Robson Schwartz
Department of Computer Science - University of Maryland Institute for Advanced Computer Studies
College Park, MD, USA, 20742-327

Resumo

Este artigo apresenta um estudo comparativo entre trinta e seis bases wavelets para descrição de texturas. O método divide um mosaico de texturas em um conjunto de blocos e os identifica como pertencentes a uma das possíveis regiões de textura. A textura em cada um dos blocos é descrita por características extraídas de coeficientes wavelets. A comparação e a posterior classificação das wavelets visam auxiliar a seleção de bases para uso em segmentação de imagens texturizadas.

Palavras-chave. Descritores de Texturas, Wavelets, Segmentação de Imagens.

1. Introdução

A utilização de técnicas avançadas para obtenção de imagens tem permitido um aumento significativo na quantidade e na resolução das imagens geradas. Por esse fato torna-se imprescindível o desenvolvimento de métodos automáticos ou semi-automáticos para detecção e análise de regiões de interesse, possibilitando redução da intervenção humana e maior rapidez na interpretação das imagens.

A definição de um conjunto de características capazes de descrever, de maneira precisa, as regiões presentes nas imagens é de extrema importância. Nesse aspecto, métodos de análise de texturas têm apresentado resultados significativos, dentre eles, os métodos baseados na *transformada wavelet* [15], a qual provê simultaneamente informações sobre os domínios espacial e de frequência.

Para realizar a transformação wavelet de uma imagem é possível escolher funções de decomposição dentro de um conjunto bastante grande. Este trabalho apresenta algumas funções importantes e pretende auxiliar na seleção de um subconjunto de funções que discriminem o conjunto de regiões texturizadas contidas nas imagens.

O método proposto extrai as informações necessárias diretamente da imagem a ser segmentada, reduzindo, de maneira significativa, a necessidade de intervenção humana durante seu processamento.

O restante do artigo é dividido como segue. Na Seção 2 são apresentados os principais conceitos sobre a análise de texturas e na Seção 3 a teoria das transformadas wavelets é explanada. A revisão teórica é finalizada com a Seção 4, onde são apresentadas medidas para descrição de texturas usando transformadas wavelets. Os métodos de extração de características utilizados na metodologia desenvolvida são descritos em detalhes na Seção 5. Os resultados obtidos a partir da aplicação do método de segmentação sobre um conjunto de mosaicos são descritos na Seção 6. Finalmente, na Seção 7 são apresentadas as conclusões obtidas com este trabalho.

2. Análise de Texturas

A segmentação é uma etapa complexa e bastante importante para a análise automática de imagens, consistindo em particionar a imagem em um conjunto de regiões disjuntas que a compõem. Para que o processo de segmentação seja efetuado de maneira satisfatória é necessário que as propriedades de cada região da imagem sejam descritas de maneira precisa. Entretanto, uma das tarefas mais difíceis é a definição de um conjunto de características capazes de efetuar essa descrição.

Dado que a textura encontra-se entre as características utilizadas pelos seres humanos para interpretar informações visuais sobre a distribuição espacial e a variação de luminosidade, além de descrever o arranjo estrutural das superfícies e relações entre regiões vizinhas, a utilização de informações texturais se apresenta como uma abordagem adequada para a descrição de regiões em imagens.

Embora o sistema visual humano apresente facilidade no reconhecimento de texturas, é extremamente difícil formalizar sua definição ou desenvolver um conjunto de descritores que possam ser utilizados para análise de imagens em diferentes domínios de aplicações. Tal dificuldade é refletida pela grande quantidade de definições e métodos de análise de texturas encontrados na literatura [9, 12, 14].

Informalmente, uma textura está relacionada com as variações, regulares ou aleatórias, nos níveis de cinza ou de cores em uma imagem [7]. Alguns exemplos de textura são mostrados na Figura 1.




Figura 1. Exemplos de texturas.

Normalmente, para a descrição de regiões texturizadas utilizam-se métodos de extração de características, os quais visam obter uma representação simplificada, porém significativa para cada região. Tais métodos são divididos entre as abordagens *espectral*, *estatística* e *estrutural* [10]. Neste artigo é descrito um método baseado na abordagem espectral, que consiste em extrair descritores a partir da representação obtida após a execução de transformações na imagem de entrada. A abordagem espectral a ser descrita baseia-se em transformadas wavelets.

3. Transformadas Wavelets

A transformada wavelet objetiva alterar a representação dos dados de modo a permitir que tanto informações sobre frequências quanto informações espaciais estejam presentes, motivo importante pelo qual passou a ser amplamente utilizada na análise de texturas [1, 2, 11, 13].

A transformada wavelet decompõe um sinal por meio de uma série de funções elementares, criadas a partir de escalamentos e translações de uma função de base, denominada *wavelet mãe*, denotada como

$$\psi_{j,k}(x) = \frac{1}{\sqrt{j}} \psi\left(\frac{x-k}{j}\right) \quad (1)$$

em que j guia o escalamento e k a translação. O conjunto de funções $\psi_{j,k}$ forma uma base para a transformada.

Pela análise de multirresolução [8], a transformação wavelet é realizada por dois conjuntos de funções. Uma função de escala ϕ que relaciona a transformada ao aspecto de multirresolução e uma segunda função ψ que expande as diferenças entre as resoluções. Essas funções são mostradas nas

equações 2 e 3. Dessa forma, a transformada wavelet é obtida pela aplicação de filtros passa-baixa e passa-alta, l e h , cujos coeficientes são formados pelo valores $l(k)$ e $h(k)$ nas equações 2 e 3.

$$\phi(t) = \sqrt{2} \sum_k l(k) \phi(2t - k) \quad (2)$$

$$\psi(t) = \sqrt{2} \sum_k h(k) \phi(2t - k) \quad (3)$$

As transformações bidimensionais utilizadas em imagens são, em sua maioria, obtidas a partir de transformações unidimensionais aplicadas separadamente nas direções vertical e horizontal.

A aplicação dos filtros sobre uma imagem nas direções vertical e horizontal gera um nível de decomposição e produz quatro sub-bandas, LL, LH, HL e HH, como pode ser visto na Figura 2(a). A decomposição pode ser realizada recursivamente na sub-banda LL (Figura 2(b)), obtendo níveis adicionais de decomposição.




Figura 2. Transformadas bidimensionais. (a) decomposição em um nível (b) decomposição em dois níveis.

3.1. Propriedades

Algumas propriedades que diferenciam as funções wavelets são discutidas a seguir.

Suporte. O suporte é a região em que a função é diferente de zero e que quantifica as localizações no tempo e frequência. Pode-se definir o suporte de uma função como o conjunto de valores reais x para os quais uma função $f(x)$ é diferente de zero, tal que

$$\text{supp } f = \{x \in \mathbb{R} | f(x) \neq 0\} \quad (4)$$

As wavelets possuem suporte compacto [3], o que significa que seu suporte no espaço dos números reais, \mathbb{R} , é limitado, variando conforme a wavelet. Devido ao suporte compacto, os coeficientes de uma transformada contêm informações locais de uma função analisada. Se a função analisada fosse mudada em um certo intervalo, somente os coefi-

cientes relacionados com o intervalo modificado sofreriam alteração, a maioria dos coeficientes permaneceria igual.

Momentos de desvanecimento. Os momentos de desvanecimento de uma função estão relacionados a sua capacidade de reproduzir polinômios. Se uma função tem N momentos de desvanecimento, então, para $l = 0, 1, \dots, N-1$,

$$\int x^l f(x) dx = 0 \quad (5)$$

Esses fatores são importantes para o grau de convergência das aproximações wavelet de funções suaves e para a detecção de singularidades usando wavelets [6].

Regularidade. A regularidade da função é útil para obter algumas características como a suavidade na reconstrução. A suavidade também corresponde a uma melhor localização das frequências dos filtros.

Simetria. A simetria da função é outro fator de diferenciação. A simetria é responsável por características de defasagem do sinal. Esta propriedade pode ser explorada para a quantização de imagens em aplicações de compressão e, também, para processar bordas usando extensão simétrica.

3.2. Famílias de funções

A possibilidade de construir funções wavelets é muito grande, fato percebido pela quantidade de funções já existentes. As funções costumam ser separadas em famílias que compartilham propriedades semelhantes. A opção por uma função ou conjunto de funções está em geral condicionada à aplicação.

As famílias wavelets são divididas conforme as características ou propriedades que compartilham. Uma das formas de classificar tais famílias refere-se a elas serem ortogonais ou biortogonais.

Wavelets ortogonais. Se para o conjunto de funções $\{\psi_{j,k}\}$, o produto interno para qualquer par $\langle \psi_{j,k}, \psi_{j,l} \rangle = 0$, $k \neq l$, então a transformada wavelet é chamada ortogonal. O conjunto de base neste caso é igual ao seu conjunto dual $\tilde{\psi}_{j,k}$. Entre as famílias de wavelets ortogonais estão as famílias Daubechies, Symlets, Coiflets, entre outras. Wavelets ortogonais não podem ser simétricas, exceto pela wavelet de Haar. No entanto, é possível projetar wavelets com maior ou menor assimetria.

As características das wavelets de Daubechies [4, 5] são analisadas de acordo com a ordem N das suas funções. O suporte das funções ϕ e ψ da Daubechies, dbN , é dado por $2N-1$ e o número de momentos de desvanecimento é igual a N . A maioria destas funções é não-simétrica exceto pela $db1$ que é a mesma wavelet de Haar. A regularidade aumenta conforme a ordem da função.

Apesar do nome Symlets, as wavelets $symN$ são apenas quase-simétricas. Ingrid Daubechies propôs mudanças em suas wavelets de modo que fosse diminuída a assimetria [5]. Fora a simetria, as outras propriedades das Symlets são semelhantes às das Daubechies.

As Coiflets de ordem N , $coifN$, possuem funções ψ com $2N$ momentos iguais a zero e funções ϕ com $2N-1$ momentos iguais a zero. O suporte destas funções é igual a $6N-1$. As funções ϕ e ψ das Coiflets possuem maior simetria em relação às mesmas funções Daubechies.

Wavelets biortogonais. Para as wavelets biortogonais, o conjunto de base e o conjunto dual são diferentes. Essas wavelets apresentam duas ordens, N_r e N_d , que estão relacionadas às bases e suas duais. As vantagens em relação às wavelets ortogonais consiste em uma maior flexibilidade das biortogonais. Essas wavelets podem possuir simetria e perfeita reconstrução, algo incompatível para o caso ortogonal.

São usados pares de funções de escala, ϕ e $\tilde{\phi}$, e wavelets, ψ e $\tilde{\psi}$. As ordens N_r e N_d estão relacionadas à reconstrução e à decomposição. Os suportes são $2N_r+1$ e $2N_d+1$, enquanto os momentos de desvanecimento para a decomposição são N_d .

4. Descritores de Texturas Usando Wavelets

Texturas podem ser representadas a partir de medidas extraídas dos coeficientes de uma transformada. Um descritor bastante utilizado para caracterizar texturas é a *energia*. Calculada para uma sub-banda S_b (LL, LH, HL ou HH), composta por N coeficientes, a energia é descrita pela equação 6, onde $S_b(x, y)$ representa o coeficiente da sub-banda S_b na coordenada (x, y) .

$$E_{S_b} = \frac{1}{N} \sum_{x,y} (S_b(x, y))^2 \quad (6)$$

O *desvio médio* (equação 7) é uma alternativa à energia, sendo formado pela média dos valores absolutos dos coeficientes em S_b . O desvio médio é uma medida semelhante à energia mas que evita o cálculo de potências.

$$DM_{S_b} = \frac{1}{N} \sum_{x,y} |S_b(x, y)| \quad (7)$$

5. Metodologia Proposta

A metodologia deste trabalho envolve a avaliação da segmentação de regiões de textura em imagens de mosaicos através de diversas bases wavelets. O objetivo principal é a classificação das bases pela capacidade de melhor descrever regiões de textura. A ordenação das wavelets pelo seu poder de descrição deve servir como critério para escolha de

um subconjunto de bases para uso em segmentação de imagens texturizadas.

Cada mosaico é composto por R regiões, de $N \times N$ pixels, que pertencem a um conjunto de T texturas diferentes. O algoritmo de segmentação divide a imagem em um conjunto de blocos de textura de tamanho $N' \times N'$, com $N' \leq N$. Os blocos devem ser discriminados e rotulados como pertencentes a uma das T texturas que formam cada mosaico.

O desvio médio dos coeficientes em cada sub-banda wavelet é utilizado para formar os descritores das regiões componentes de um mosaico. Para a extração desses descritores, os blocos de textura são decompostos por uma base wavelet, gerando as sub-bandas (Figura 2) para cada bloco. Após a decomposição do bloco, são extraídos os desvios médios das sub-bandas.

Em imagens com cores a decomposição é realizada em cada banda de cor. No final, os blocos de textura são descritos por um vetor de características com dimensão igual ao número de sub-bandas da decomposição multiplicado pelo número de bandas de cor.

A última etapa do método consiste em agrupar regiões com descritores semelhantes em T conjuntos de texturas usando o algoritmo de agrupamento *k-means*.

6. Resultados Experimentais

Os testes de discriminação de texturas utilizando transformadas wavelets foram aplicados em um conjunto de mosaicos sintéticos, produzidos a partir de um conjunto de texturas. As texturas que compõem as imagens foram obtidas da coleção Vision Texture Database [16], as quais pertencem às classes cortiça, tecido, alimento, metal, rocha e madeira.

Cada mosaico construído tem dimensões de 512×512 pixels e blocos de textura de 64×64 pixels, formando, desta forma, mosaicos compostos por 64 regiões de textura. O subconjunto de texturas que constituem um determinado mosaico foi tomado aleatoriamente dentro do conjunto disponível, podendo conter texturas pertencentes a diferentes classes. O objetivo é avaliar as bases wavelets na caracterização de texturas independentemente da natureza destas.

Formado o subconjunto de texturas para um mosaico específico, cada um dos blocos de 64×64 pixels foi preenchido com uma região de igual tamanho de uma imagem escolhida aleatoriamente dentro do subconjunto formador do mosaico. A região de preenchimento também foi obtida aleatoriamente dentro de cada imagem de textura, evitando a escolha de um região única, o que tornaria o processo de segmentação trivial.

O modo de obtenção dos mosaicos permitiu que regiões obtidas de uma mesma imagem de textura contivessem variações significativas das posições dos padrões texturais e,

também, permitiu que houvesse variações de coloração e luminosidade. Exemplos de mosaicos são mostrados na Figura 3.




Figura 3. Exemplos de mosaicos. Os mosaicos (a), (b) e (c) são compostos respectivamente por 2, 3 e 4 regiões de textura.

Pode-se observar na Figura 3(a) que existe variação significativa nos padrões de formação das texturas para cada um dos blocos. Nas Figuras 3(b) e 3(c), além da variação dos padrões de textura, é possível perceber variações de orientação e de luminosidade.

Para a tarefa de segmentação foram utilizados 275 mosaicos compostos por 2, 3 ou 4 texturas diferentes. A divisão exata contabiliza 91, 92 e 92 mosaicos compostos por 2, 3 e 4 texturas, respectivamente. O algoritmo foi executado com blocos de tamanho 64×64 pixels e também 32×32 pixels.

Os 275 mosaicos foram segmentados usando 36 wavelets diferentes, pertencentes a 5 famílias: Haar, Daubechies, Symlets, Coiflets e Biortogonais. Os nomes específicos das wavelets são mostrados na Tabela 1. Como as wavelets foram executadas com blocos de 64×64 pixels e 32×32 pixels, o total de testes, para cada wavelet, foi de 550.

Família	Wavelets
Daubechies	1 (Haar), 2-10
Symlets	2-8
Coiflets	1-5
Biortogonal	1.1, 1.3, 1.5, 2.2, 2.4, 2.6, 2.8, 3.1, 3.3, 3.5, 3.7, 3.9, 4.4, 5.5, 6.8

Tabela 1. Conjunto de wavelets utilizadas nos testes de segmentação.

As transformações foram executadas com dois níveis de decomposição em imagens com modelo de cores HSV (matiz, saturação e valor de intensidade), em que a intensidade (luminância) e a informação de cores (crominância) estão melhor relacionadas com a percepção visual humana, per-

mitindo explorar mais convenientemente as propriedades de cores.

A análise dos resultados da segmentação baseou-se nas imagens *groundtruth* de cada mosaico. As regiões das imagens segmentadas foram comparadas com as regiões das imagens *groundtruth*. Para todos os mosaicos, as wavelets foram classificadas da que teve a melhor segmentação para a que teve a pior segmentação, podendo haver empate.

Os resultados finais são resumidos na Tabela 2, a qual mostra a classificação de cada base até a 20ª posição. Esta tabela mostra que algumas wavelets biortogonais apresentam os melhores resultados para a descrição de texturas. Em especial, as primeiras cinco colocadas são as wavelets biortogonais: bior3.1, bior3.3, bior3.5, bior3.7 e bior1.1.

Nas outras famílias, entre as bases com melhor posicionamento, destacam-se:

- Daubechies: db1 e db2, linhas 6 e 9;
- Symlets: sym2 e sym5, nas linhas 11 e 13;
- Coiflets: coif5, na linha 14.

Na família Daubechies, as bases com melhores resultados foram db1 e db2, as mais simples da família. Curiosamente, a base db1 é a base de Haar, que é também a mais simples de todas as bases wavelets e a única com simetria entre as bases ortogonais, propriedade também presente nas bases biortogonais.

Pelos resultados é possível perceber que não existe uma base que possa ser considerada indiscutivelmente a melhor. Uma base wavelet não mantém constante seu posicionamento em relação às outras bases. De uma imagem para outra, uma mesma base pode obter resultados bastante diferentes, podendo ser a melhor wavelet para uma imagem e figurar entre as piores em outra.

No entanto, resultados extremos não são comuns. As bases tendem a seguir um comportamento relativamente estável. Existe uma flutuação entre as bases mas aquelas que obtêm melhores resultados tendem a se manter em um grupo líder, possibilitando a escolha final entre as bases com melhores resultados.

7. Conclusões e Trabalhos Futuros

Este artigo analisou um conjunto de trinta e seis bases wavelets para a tarefa de segmentação de imagens usando mosaicos de texturas. O objetivo foi selecionar entre as bases wavelets aquelas que melhor responderam à tarefa de caracterização das texturas e que, consequentemente, obtiveram melhor segmentação dos mosaicos.

Algumas wavelets biortogonais mostraram resultados superiores aos de outras famílias, principalmente as wavelets bior3.1 e bior3.3. Como pode ser observado na Tabela 2, ainda outras três wavelets biortogonais são classificadas como melhores antes da wavelet db1, de Daube-

chies, que aparece na sexta linha. As bases simétricas ou quase-simétricas obtiveram melhor classificação, fato que pode justificar uma investigação mais formal dessa propriedade e um estudo matemático das características das bases para discriminação de texturas.

A escolha de bases wavelets não é uma tarefa simples. Muitas bases possuem características e capacidades equiparáveis. Este trabalho, no entanto, ajuda na escolha de um subconjunto de bases dentro de um conjunto bastante grande, tendo como aplicação as tarefas de descrição de texturas para segmentação de imagens.

O estudo realizado neste trabalho possibilitará uma investigação mais profunda em questões relacionadas à caracterização de textura em imagens baseada em transformadas wavelets, tais como níveis de decomposição, descritores de características, dimensionalidade dos vetores de características e métodos de classificação.

8. Agradecimentos

Os autores são gratos à FAPESP, ao CNPq e à CAPES pelo apoio financeiro.

Referências

- [1] S. Arivazhagan and L. Ganesan. Texture segmentation using wavelet transform. *Pattern Recognition Letters*, 24(16):3197–3203, Dezembro 2003.
- [2] C. Busch. Wavelet based texture segmentation of multimodal tomographic images. *Computers & Graphics*, 21(3):347–358, 1997.
- [3] O. Christensen and K. L. Christensen. *Approximation Theory: From Taylor Polynomials to Wavelets*. Springer-Verlag, Maio 2004.
- [4] I. Daubechies. The wavelet transform, time-frequency localization and signal analysis. *IEEE Transactions on Information Theory*, 36:961–1005, Setembro 1990.
- [5] I. Daubechies. *Ten Lectures on Wavelets*, volume 91 of *CBMS-NSF Regional Conference Series in Applied Mathematics*. SIAM, Philadelphia, PA, Estados Unidos, 1992.
- [6] J. Gomes and L. Velho. *From Fourier Analysis to Wavelets*. SIGGRAPH'98 Course Notes, SIGGRAPH-ACM publication, Orlando, FL, Estados Unidos, Julho 1998.
- [7] E. Gose, R. Johnsonbaugh, and S. Jost. *Pattern Recognition and Image Analysis*. Prentice Hall PTR, Upper Saddle River, NJ, Estados Unidos, 1996.
- [8] S. G. Mallat. A Theory for Multiresolution Signal Decomposition: the Wavelet Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7):674–693, Julho 1989.
- [9] M. Nadler and E. P. Smith. *Pattern Recognition Engineering*. John Wiley & Sons, Inc, New York, NY, Estados Unidos, 1993.
- [10] C. Palm. Color texture classification by integrative co-occurrence matrices. *Pattern Recognition*, 37(5):965–976, Maio 2004.

linha	wavelet	classificação																			
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	bior3.1	295	71	44	22	18	15	12	9	7	9	10	1	5	5	3	2	0	6	5	5
2	bior3.3	287	95	31	24	16	22	10	12	8	8	4	5	3	1	2	3	3	4	3	4
3	bior3.5	261	75	46	33	21	17	11	13	12	3	10	7	4	6	4	2	5	5	5	3
4	bior3.7	256	74	41	36	19	19	13	11	10	6	11	9	4	5	10	3	3	6	4	4
5	bior1.1	238	82	47	40	29	22	13	16	3	9	6	6	9	5	4	6	3	2	1	0
6	db1	237	79	47	44	30	20	13	18	3	9	6	6	7	5	5	6	3	1	1	0
7	bior1.5	219	61	40	39	29	24	25	18	12	10	17	9	5	6	5	6	8	4	2	3
8	bior2.2	217	74	59	42	39	23	9	12	16	11	9	3	3	6	7	1	3	3	5	0
9	db2	208	70	60	53	30	22	21	13	15	8	8	4	4	7	4	4	2	4	2	2
10	bior2.4	205	59	41	43	32	29	13	17	12	12	19	9	10	12	8	2	8	3	6	3
11	sym2	204	71	58	57	30	23	21	13	12	10	9	4	4	7	4	4	2	6	1	2
12	bior2.6	202	55	37	45	30	18	26	15	17	18	8	9	10	10	10	5	8	5	4	5
13	sym5	199	57	48	40	29	27	23	14	23	7	16	7	7	6	9	4	8	3	5	4
14	coif5	196	73	59	44	37	24	20	17	10	13	8	7	3	9	5	2	5	6	0	3
15	db3	196	60	44	36	36	16	20	22	21	22	16	8	9	4	13	8	4	3	5	2
16	sym3	194	62	45	35	35	19	20	22	18	22	15	7	11	5	12	8	4	4	5	2
17	bior2.8	194	53	43	44	33	24	21	13	20	11	11	16	10	3	11	11	7	9	2	6
18	bior1.3	192	59	43	38	28	34	23	18	14	10	15	10	9	11	5	6	7	5	8	6
19	coif1	190	60	46	58	39	29	18	17	21	12	7	13	3	8	7	5	1	1	3	4
20	sym4	189	47	53	47	25	24	23	21	14	16	16	10	9	6	13	7	5	2	7	3
21	bior4.4	189	47	47	44	36	26	19	16	16	19	11	13	13	11	4	10	9	5	7	3
22	db4	186	61	41	31	37	27	16	18	28	15	13	16	15	6	5	10	4	6	3	3
23	db10	180	67	42	33	37	25	24	23	17	21	15	15	10	5	3	7	4	7	5	4
24	sym6	177	45	49	43	23	25	21	23	15	18	11	14	12	9	7	9	8	7	12	6
25	coif4	169	47	51	37	49	30	30	30	21	16	12	11	4	12	8	4	2	6	2	3
26	coif2	168	50	49	45	27	31	24	20	11	16	18	13	12	10	12	5	9	8	4	2
27	db5	167	63	42	37	32	17	15	25	19	14	15	25	12	11	9	11	8	9	1	8
28	sym7	165	48	49	40	35	25	20	30	14	17	4	18	18	9	11	8	5	6	4	7
29	db9	163	64	38	30	34	21	24	24	29	23	9	17	17	7	11	6	11	4	6	2
30	db7	163	61	41	36	33	25	19	25	18	18	8	18	17	10	13	7	13	11	3	2
31	bior6.8	163	48	40	40	34	33	24	18	19	18	12	16	14	9	13	11	7	7	3	5
32	bior5.5	163	42	47	45	30	22	22	22	21	16	15	8	16	11	17	8	9	9	5	4
33	sym8	163	38	50	41	32	22	27	20	23	13	10	22	9	10	11	7	9	9	7	5
34	coif3	159	51	57	31	34	26	24	31	24	14	17	8	9	11	10	13	8	7	5	2
35	db6	158	62	41	37	34	25	23	18	22	16	14	21	14	14	12	5	10	9	5	2
36	db8	154	73	45	21	28	26	25	22	25	25	16	10	21	11	9	9	8	6	6	2

Tabela 2. Quantidade de vezes que cada wavelet obteve a n-ésima melhor segmentação. Foram realizados 550 testes para cada wavelet.

- [11] W. Qian, L. Li, and L. P. Clarke. Image feature extraction for mass detection in digital mammography: Influence of wavelet analysis. *Medical Physics*, 26(3):402–408, Março 1999.
- [12] T. Randen and J. H. Husoy. Filtering for texture classification: a comparative study. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(4):291–310, Abril 1999.
- [13] E. Salari and Z. Ling. Texture segmentation using hierarchical wavelet decomposition. *Proceedings of the IEEE International Symposium on Industrial Electronics*, 1:216–220, Julho 1995.
- [14] M. Tuceryan and A. K. Jain. Texture analysis. In C. H. Chen, L. F. Pau, and P. Wang, editors, *The Handbook of Pattern Recognition and Computer Vision*, pages 207–248. World Scientific Publishing Co., Agosto. 1998.
- [15] M. Unser. Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing*, 4(11):1459–1560, 1995.
- [16] VisTex. Vision Texture Database. <http://vismod.media.mit.edu/vismod/imagery/VisionTexture/distribution.html>.