

Avaliação da invariância à rotação de descritores texturais extraídos por transformadas wavelets

Ricardo Dutra da Silva¹
William Robson Schwartz²
Hélio Pedrini³

¹ Departamento de Informática, Universidade Federal do Paraná
81531-990 – Curitiba – PR, Brasil
ricardodutr@gmail.com

² Department of Computer Science, University of Maryland
20742-327 – College Park – MD, USA
schwartz@cs.umd.edu

³ Instituto de Computação, Universidade Estadual de Campinas
13084-971 – Campinas – SP, Brasil
helio@ic.unicamp.br

Abstract. Segmentation plays an important role in image analysis. Image segmentation aim at partitioning a set of objects/regions that compose an image, producing a set of higher level structures used to describe these objects/regions. To obtain acceptable segmentation results, a set of descriptors needs to be defined such that regions presenting distinct features can be uniquely identified. Descriptors based on textures have been vastly investigated to accomplish such region identification. The importance presented for these descriptors comes from the fact that textures present structural clues and also are among the main features perceived by the human visual system. An important characteristic that needs to be considered when one chooses a set of descriptors is its invariance to certain transformations, such as rotation, translation, and scaling. Due to its fundamental importance, in this work we conduct experiments using remote sensing images to evaluate and compare several descriptors, extracted from separable and non-separable wavelet transforms, with regard to their invariance to rotation. To evaluate the robustness to rotation, we evaluate how much the elements of the feature vector change when the image is considered under different rotation angles. Then, we compute the coefficient of variation to be able to compare different descriptors.

Keywords: image segmentation, separable and non-separable wavelets, texture descriptors, segmentação de imagens, wavelets separáveis e não-separáveis, descritores de textura.

1. Introdução

O crescente avanço nas técnicas de aquisição de imagens torna essencial a análise automática ou semi-automática de seu conteúdo, que consiste na criação de algoritmos capazes de reproduzir total ou parcialmente a capacidade humana de entendimento e interpretação de imagens. O reconhecimento de objetos e regiões que compõem uma imagem é fundamental para aplicações de visão robótica, monitoração industrial, sensoriamento remoto, diagnóstico médico assistido e recuperação de imagens por conteúdo.

O desenvolvimento de técnicas de segmentação aplicadas a imagens de sensoriamento remoto apresenta grande importância devido ao crescente volume de dados adquiridos a partir de novos sensores de alta resolução. Para tornar essas técnicas mais robustas, a utilização de um conjunto de descritores com alto poder discriminatório é essencial. Uma solução é a geração de um conjunto de descritores contendo um número elevado de variáveis. No entanto, neste caso, os métodos de classificação podem se tornar ineficientes devido ao alto grau de correlação entre as variáveis. Dessa maneira, para manter um número moderado de variáveis torna-se de interesse a utilização de descritores invariantes a certas famílias de transformações.

A extração de descritores de texturas baseados em transformadas wavelets tornou-se um

importante t3pico de estudo em an3lise de imagens. Transformadas wavelets apresentam propriedades que proporcionam uma representa33o contendo simultaneamente informa33es espaciais e de frequ4ncia, al4m do aspecto de multirresolu33o, que permite a extra33o de descritores em diversas escalas (MALLAT, 1989b). Estas propriedades tornam as transformadas wavelets apropriadas, superando outros tipos de transformadas como, por exemplo, a transformada de Fourier.

As wavelets possuem sua energia concentrada no tempo, sendo ondas localizadas de curta dura33o, o que possibilita a an3lise de sinais transit3rios, n3o-estacion3rios ou vari3veis no tempo. Pode-se dizer que wavelets s3o sinais oscilantes e n3o-nulos em um curto intervalo de tempo. Dessa maneira 4 poss4vel obter an3lises localizadas que descrevem melhor os componentes de um sinal. Essa caracter4stica apresenta fundamental import3ncia em segmenta33o de imagens, uma vez que seu objetivo principal 4 a localiza33o de padr3es espec4ficos na imagem.

Este trabalho compara as varia33es de descritores extra4dos a partir de diferentes transformadas wavelets para avaliar sua robustez quanto 3 rota33o. Transformadas wavelets separ3veis e n3o-separ3veis s3o exploradas nos experimentos. Em muitos problemas de an3lise de texturas (SILVA et al., 2008) 4 importante que os resultados sejam independentes quanto 3 orienta33o da textura, o que justifica a relev3ncia do trabalho realizado.

O restante do trabalho est3 organizado como segue. A se33o 2 apresenta uma breve descri33o dos principais t3picos relacionados ao trabalho. A metodologia empregada 4 apresentada na se33o 3. Os testes e resultados obtidos com a aplica33o da metodologia em imagens de sensoriamento remoto s3o descritos e avaliados na se33o 4. A se33o 5 apresenta as conclus3es e propostas para trabalhos futuros.

2. Transformada Wavelets e Descritores de Texturas

A defici4ncia da transformada de Fourier em fornecer informa33es de um sinal nos dom4nios da frequ4ncia e do tempo levou 3 busca de transforma33es com a capacidade de obter an3lises localizadas, descrevendo melhor as partes de um sinal (GOMES; VELHO, 1998; GRAPS, 1995). A teoria de wavelets destacou-se entre os m4todos por prover simultaneamente informa33es sobre os dom4nios espacial e de frequ4ncia (CASTAÑON, 2003).

A primeira men33o ao sistema ortogonal de fun33es mais simples encontrado na literatura surgiu no ap4ndice da tese de Albert Haar (HAAR, 1910). Atualmente, essas fun33es s3o conhecidas como as wavelets de Haar. Entre as d4cadas de 1960 e 1980, importantes trabalhos foram desenvolvidos por Coifman, Grossmann e Morlet (COIFMAN, 1990; GROSSMANN; MORLET, 1984; MORLET et al., 1984). O termo wavelet foi introduzido por Morlet (MORLET et al., 1984). Ap3s 1980, Yves Meyer e Stephane Mallat aplicaram a id4ia em uma teoria chamada multirresolu33o (MALLAT, 1989a, 1989b). Mallat descobriu importantes rela33es entre bancos de filtros, algoritmos de pir3mide e bases wavelets ortonormais. Baseando-se nos trabalhos de Mallat, Ingrid Daubechies desenvolveu uma fam4lia de fun33es wavelets de base ortonormal que se tornou bastante importante (DAUBECHIES, 1992).

Muitos dos esfor3os de pesquisa em wavelets bidimensionais baseiam-se em filtros separ3veis, constru4dos por produtos tensoriais dos filtros unidimensionais. Mais recentemente, a procura por filtros n3o-separ3veis verdadeiramente bidimensionais ou mesmo multidimensionais, tornou-se o objetivo de algumas pesquisas (CUI; LI; ZHOU, 2004; HE; LAI, 2000; KOVACEVIC; VETTERLI, 1992; LENDERS; SJOSTROM, 1999; LINDEMANN, 2005). No entanto, a constru33o de tais esquemas 4 bem mais complexa do que no caso unidimensional, al4m de exigirem maior custo para execu33o computacionalmente.

Os m4todos de descri33o de texturas podem ser divididos em estat4sticos, estruturais e

espectrais. Os métodos estatísticos dividem as texturas em, por exemplo, suaves e grossas, entre outras possíveis divisões. Nos métodos estruturais, a classificação baseia-se em como são formadas as texturas a partir de elementos mais primitivos, como linhas. Métodos espectrais consideram a extração de descritores a partir de representações obtidas pela aplicação de transformações como Fourier, Gabor e wavelets.

Uma deficiência da maioria dos métodos de análise de texturas reside no fato de que a imagem é analisada em uma única resolução (WOUWER; SCHEUNDERS; DYCK, 1999). Eles surgiram baseados em estudos do sistema visual humano (BECK; SUTTER; IVRY, 1987; CHOI; WILLIAMS, 1989), métodos que exploram representações em múltiplas resoluções, em especial, decomposições realizadas por filtros de Gabor e transformadas wavelets (ACHARYYA; DE; KUNDU, 2003; ANTONINI et al., 1992; CHANG; KUO, 1992; DAUBECHIES, 1990; FUKUDA; HIROSAWA, 1999; WU; ZHANG; LIN, 1999).

Cada uma das texturas presentes em uma imagem pode ser representada a partir de medidas extraídas sobre as sub-bandas de coeficientes da transformada wavelet. Tais coeficientes evidenciam os padrões texturais presentes na imagem. Regiões com texturas suaves possuem principalmente coeficientes baixos. Nas regiões com transições, os coeficientes tendem a ser maiores, enfatizando as mudanças.

Uma característica bastante utilizada para a caracterização de texturas é a energia. A energia calculada para uma sub-banda Sb , adquirida por meio da transformada wavelet e composta por N coeficientes, é descrita como

$$\text{Energia}_{Sb} = \sqrt{\frac{1}{N} \sum_{x,y} (Sb(x,y))^2} \quad (1)$$

em que $Sb(x,y)$ representa o coeficiente da sub-banda Sb na coordenada (x,y) .

O desvio médio é uma alternativa à energia, sendo formado pela média dos valores absolutos dos coeficientes em Sb . O desvio médio é uma medida semelhante à energia mas que evita o cálculo de potências, definido como

$$\text{Desvio Médio}_{Sb} = \frac{1}{N} \sum_{x,y} |Sb(x,y)| \quad (2)$$

Pela variância pode-se construir mais uma medida, chamada de suavidade. Essa medida tem valor igual a zero para regiões com coeficientes constantes e cresce tendendo a 1 à medida que a variância cresce. A suavidade é definida como

$$\text{Suavidade}_{Sb} = 1 - \frac{1}{1 + \sigma^2} \quad (3)$$

sendo σ^2 a variância dos coeficientes da sub-banda Sb .

Mais uma medida que pode ser encontrada para caracterização de texturas é o resíduo médio (MUNEESWARAN et al., 2005), definida como

$$\text{Resíduo Médio}_{Sb} = \sum_{x,y} (Sb(x,y) - \mu)^2 \quad (4)$$

sendo μ a média amostral dos coeficientes da sub-banda Sb .

3. Metodologia Desenvolvida

Esta seção apresenta o método de avaliação de wavelets quanto à invariância à rotação. As características (descritores) são extraídas dos coeficientes de transformadas wavelets. O cálculo das características deve ser efetuado tomando-se imagens de uma textura com diferentes rotações, a fim de avaliar a dispersão dos valores segundo as diferentes orientações. Um exemplo de imagem com diferentes rotações é mostrado na figura 1.



Figura 1: Diferentes rotações de uma imagem.

Dada uma imagem de $N \times N$ pixels, uma transformada wavelet específica de l níveis é aplicada sobre a imagem. Características são extraídas sobre as sub-bandas da decomposição, formando o vetor de características que descreve a imagem.

Posteriormente, é necessário que a imagem sofra uma rotação de α graus, com α entre 0° e 360° . Para diferentes valores de α , o processo de decomposição e extração das características é realizado. Ao final, haverá um vetor de características para cada rotação da imagem. A sensibilidade à rotação é avaliada por meio de uma medida estatística de dispersão. O coeficiente de variação é definido como

$$CV = \frac{\sigma}{\mu} \quad (5)$$

ou seja, a razão entre o desvio padrão σ e a média μ para um conjunto de valores. Tal medida é apropriada pois permite a comparação direta entre diferentes conjuntos de dados, o que não é possível por meio da variação ou do desvio padrão.

O processo pode ser descrito pelo seguinte algoritmo:

para cada α de 0° a 360° com incremento β **faça**
 aplicar rotação de α graus na imagem de textura original;
 aplicar a transformada wavelet sobre a imagem de textura após rotação;
 calcular as características para as sub-bandas;
 armazenar o vetor de características;
fim
calcular a média dos coeficientes de variação dos vetores de características;

4. Resultados Experimentais

Nesta seção são apresentados e discutidos os resultados obtidos com a metodologia proposta, considerando a adaptação de bases wavelets em imagens com diferentes orientações. Os algoritmos foram implementados com o pacote MATLAB (MATHWORKS, 2008) versão 7.0.1.24704 e a biblioteca de funções para wavelets não-separáveis LISQ (LISQ, 2008), no sistema operacional Linux.

Os testes foram aplicados sobre um conjunto de imagens gerado a partir das imagens do Google Maps (Google Maps, 2008) mostradas na figura 2. Todas essas imagens foram obtidas considerando-se uma escala de 100 metros. A composição das imagens de teste foi realizada

aplicando-se rotações, sobre a imagem original, de 5 em 5 graus, e extraindo-se a parte central, composta por 64×64 pixels.

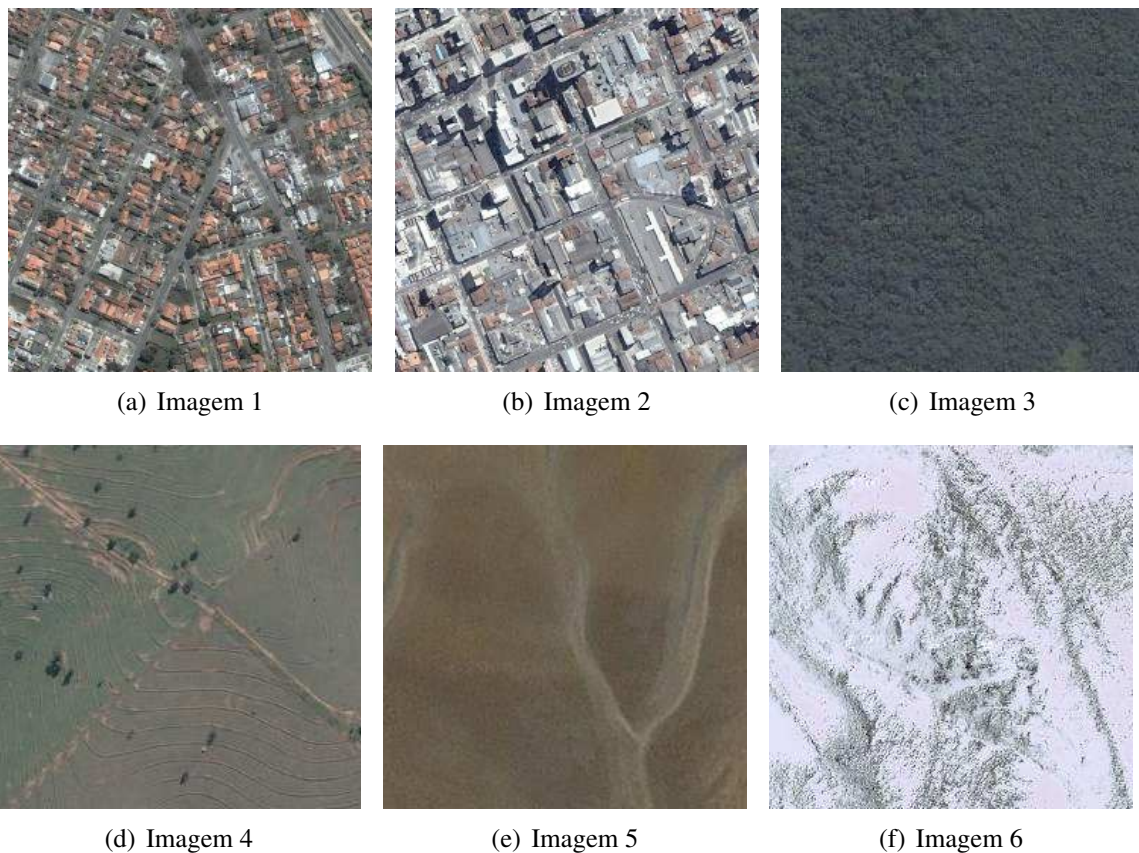


Figura 2: Imagens usadas para os teste de rotação.

Os testes foram realizados com as wavelets separáveis Biortogonal 3.3 (bior3.3), Coiflets 5 (coif5), Daubechies 2 (db2) e Symlets 5 (sym5). Os filtros de wavelets não-separáveis utilizados foram Neville 2 (N2), Neville 4 (N4) e MaxMax (MM). Para cada uma das transformações wavelets foram usados dois níveis de decomposição. Os vetores de características foram formados pelas medidas de energia, desvio médio, suavidade e resíduo médio, extraídas sobre todas as bandas da transformação wavelet.

Os testes realizados comparam a variação dos vetores de características para cada uma das imagens em diferentes rotações, avaliando as wavelets mais apropriadas para obter descritores menos suscetíveis a esse tipo de transformação. Uma função wavelet é fixada e os vetores de características são extraídos para todas as rotações de uma imagem. Em seguida, os coeficientes de variação das medidas no vetor de características são calculados e a média extraída para medir a variação dos descritores de uma imagem quando ela sofre rotações. Os gráficos da figura 3 mostram o coeficiente de variação dos vetores de características para cada uma das bases wavelets testadas.

Como pode ser observado pelos gráficos, as wavelets não-separáveis apresentam variação bastante inferior àquela das wavelets separáveis. A partir desses resultados é possível perceber a superioridade de filtros não-separáveis para obter descritores invariantes à rotação.

5. Conclusões e Trabalhos Futuros

Devido à importância da utilização de descritores invariantes a certas famílias de transformações e as propriedades de análise em multirresolução apresentados pelas

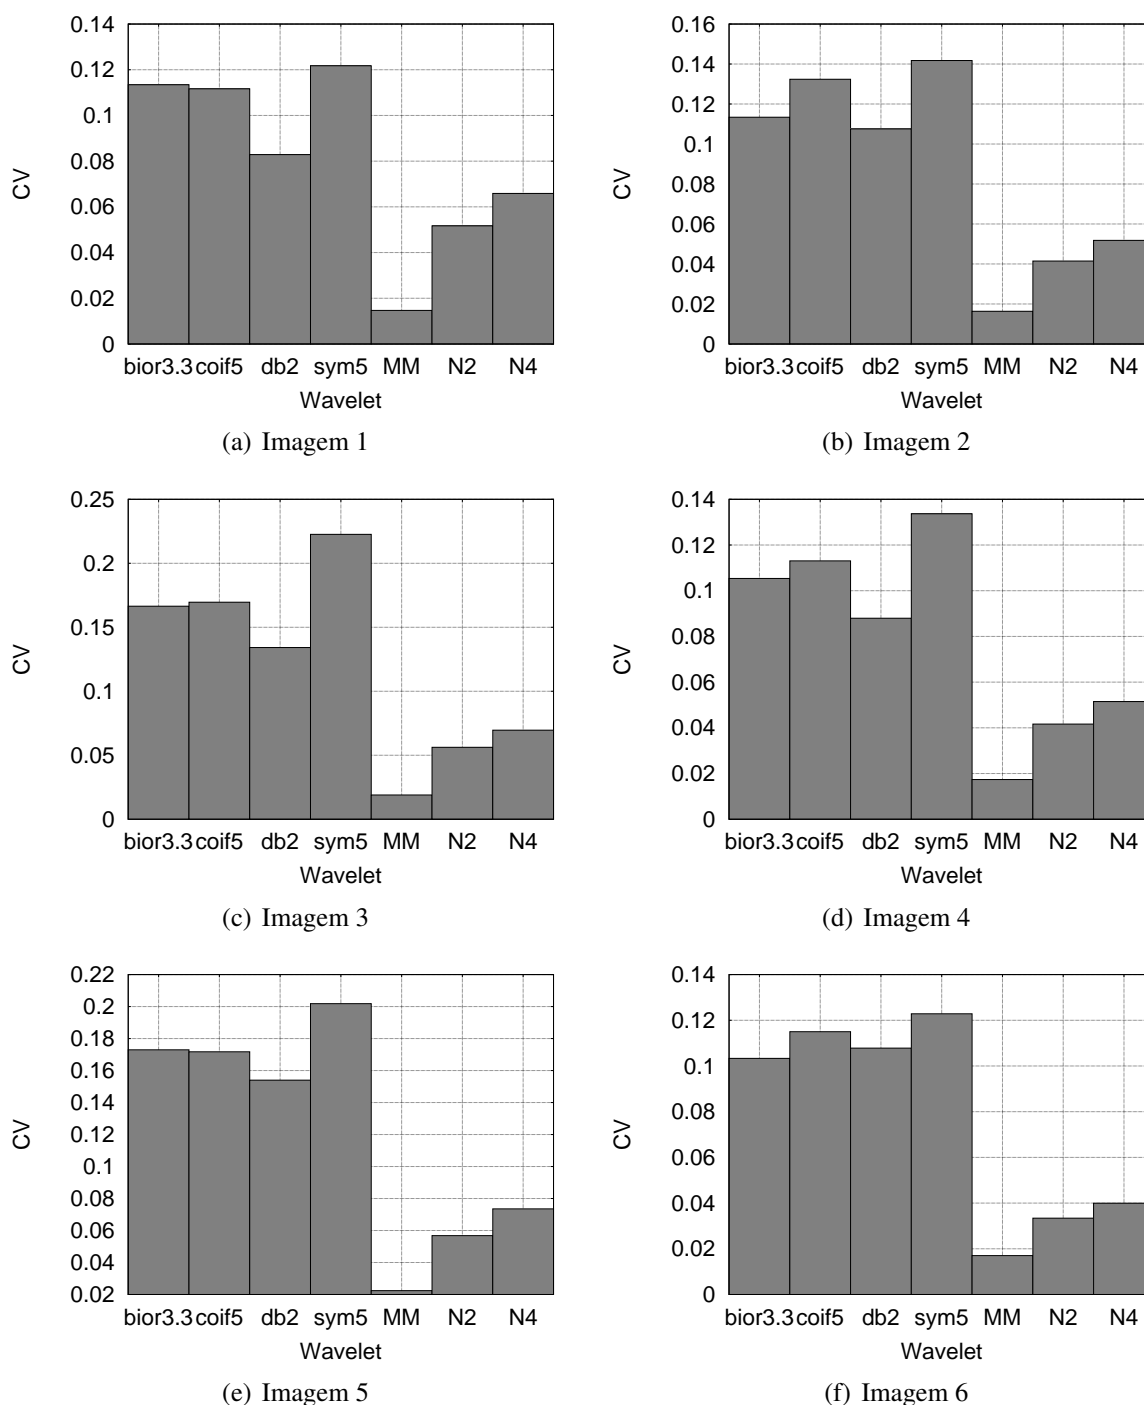


Figura 3: Variação de características para imagens com rotações.

transformadas wavelets, este trabalho avaliou a extração de descritores por meio de transformadas wavelets separáveis e não-separáveis com relação à invariância à rotação. Os resultados experimentais mostram que os filtros não-separáveis apresentam-se mais eficazes quanto à rotação, particularmente o filtro MaxMax.

Como diretiva para trabalhos futuros, pretende-se avaliar um conjunto mais amplo de descritores, de modo a combinar características específicas de cada filtro wavelet visando ao aumento de poder discriminatório no processo de segmentação aplicado a imagens de sensoriamento remoto.

6. Agradecimentos

William Robson Schwartz agradece à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES, processo BEX 1673/04-1).

Referências

- ACHARYYA, M.; DE, R. K.; KUNDU, M. K. Segmentation of remotely sensed images using wavelet features and their evaluation in soft computing framework. *IEEE Transactions on Geoscience and Remote Sensing*, v. 41, n. 12, p. 2900–2905, dez. 2003.
- ANTONINI, M. et al. Image coding using wavelet transform. *IEEE Transactions on Image Processing*, v. 1, n. 2, p. 205–220, abr. 1992.
- BECK, J.; SUTTER, A.; IVRY, R. Spatial frequency channels and perceptual grouping in texture segregation. *Computer Vision, Graphics and Image Processing*, Academic Press Professional, Inc., San Diego, CA, Estados Unidos, v. 37, n. 2, p. 299–325, 1987.
- CASTAÑÓN, C. A. B. *Recuperação de imagens por conteúdo através de análise multiresolução por wavelets*. Págs. 112. Dissertação (Mestrado) — Instituto de Ciências Matemáticas e de Computação, São Paulo, Brasil, 2003.
- CHANG, T.; KUO, C.-C. J. A wavelet transform approach to texture analysis. *IEEE International Conference on Acoustics, Speech, and Signal Processing*, v. 4, p. 661–664, mar. 1992.
- CHOI, H.-I.; WILLIAMS, W. J. Improved time-frequency representation of multicomponent signals using exponential kernels. *IEEE Transactions on Acoustics, Speech and Signal Processing*, v. 37, n. 6, p. 862–871, jun. 1989.
- COIFMAN, R. R. Wavelet analysis and signal processing. In: . Londres, Inglaterra: Springer-Verlag, 1990. p. 59–68. ISBN 0-387-97215-3.
- CUI, L.; LI, H.; ZHOU, Y. Theory of 2-D non-separable optimal M-band wavelets and its applications. In: *GMP '04: Proceedings of the Geometric Modeling and Processing 2004*. Washington, DC, Estados Unidos: IEEE Computer Society, 2004. p. 331–334.
- DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. *IEEE Transactions on Information Theory*, v. 36, p. 961–1005, set. 1990.
- DAUBECHIES, I. *Ten Lectures on Wavelets*. [S.l.]: SIAM, 1992. (CBMS-NSF Regional Conference Series in Applied Mathematics). Págs. 377.
- FUKUDA, S.; HIROSAWA, H. A wavelet-based texture feature set applied to classification of multifrequency polarimetric SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 37, n. 5, p. 2282–2286, set. 1999.
- GOMES, J.; VELHO, L. *From Fourier analysis to wavelets*. Orlando, Estados Unidos: SIGGRAPH'98 Course Notes, SIGGRAPH-ACM publication, 1998. Págs. 210. Disponível em: <<http://www.visgraf.impa.br/Publications/SigGraph98>>.
- Google Maps. 2008. <http://maps.google.com/>, acesso em Novembro de 2008.
- GRAPS, A. An introduction to wavelets. *IEEE Computational Science & Engineering*, IEEE Computer Society Press, Los Alamitos, CA, Estados Unidos, v. 2, n. 2, p. 50–61, 1995.
- GROSSMANN, A.; MORLET, J. Decomposition of hardy functions into square integrable wavelets of constant shape. *SIAM Journal on Mathematical Analysis*, v. 15, n. 4, p. 723–736, 1984.
- HAAR, A. Zur theorie der orthogonalen funktionensysteme. *Mathematische Annalen*, p. 331–371, 1910.

- HE, W.; LAI, M.-J. Examples of bivariate nonseparable compactly supported orthonormal continuous wavelets. *IEEE Transactions on Image Processing*, v. 9, n. 5, p. 949–953, 2000.
- KOVACEVIC, J.; VETTERLI, M. Nonseparable multidimensional perfect reconstruction filter banks and wavelet bases for \mathbb{R}^2 . *IEEE Transactions on Information Theory*, v. 38, n. 2, p. 533–555, 1992.
- LENDERS, P.; SJOSTROM, A. On the implementation of nonseparable two-dimensional Haar wavelet transforms. *IEEE Transactions on Signal Processing*, v. 47, n. 11, p. 3137–3139, nov. 1999.
- LINDEMANN, M. *Approximation properties of non-separable wavelet bases with isotropic scaling matrices – and their relation to Besov spaces*. Págs. 138. Tese (Doutorado) — Universidade de Bremen, Alemanha, 2005.
- LISQ. *A toolbox for the lifting scheme on 2D quincunx grids*. 2008. <http://www.mathworks.com/matlabcentral/fileexchange/13507>, acesso em Novembro de 2008.
- MALLAT, S. Multifrequency channel decompositions of images and wavelet models. *IEEE Transactions on Acoustics, Speech and Signal Processing*, v. 37, n. 12, p. 2091–2110, dez. 1989.
- MALLAT, S. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 11, n. 7, p. 674–693, jul. 1989.
- MATHWORKS, T. *MATLAB®- The Language of Technical Computing*. 2008. <http://www.mathworks.com/products/matlab/>, acesso em Novembro de 2008.
- MORLET, J. et al. Wave propagation and sampling theory. *SIAM Journal on Mathematical Analysis*, v. 15, n. 4, p. 723–736, 1984.
- MUNEESWARAN, K. et al. Texture classification with combined rotation and scale invariant wavelet features. *Pattern Recognition*, v. 38, n. 10, p. 1495–1506, 2005.
- SILVA, R. da et al. Satellite image segmentation using wavelet transforms based on color and texture features. In: *4th International Symposium on Visual Computing*. Las Vegas, NV, Estados Unidos: Springer-Verlag, 2008.
- WOUWER, G. V. de; SCHEUNDERS, P.; DYCK, D. V. Statistical texture characterization from discrete wavelet representations. *IEEE Transactions on Image Processing*, v. 8, n. 4, p. 592–598, abr. 1999.
- WU, G.; ZHANG, Y.; LIN, X. Wavelet transform-based texture classification with feature weighting. In: *IEEE International Conference on Image Processing*. Kobe, Japão: IEEE Computer Society, 1999. v. 4, p. 435–439.