

Padrões binários locais na classificação de imagens de sensoriamento remoto

Marcelo Musci¹
Raul Queiroz Feitosa¹
Maria Luiza Fernandes Velloso²
Tessio Novack³

¹Pontifícia Universidade Católica do Rio de Janeiro – PUC-Rio
Caixa Postal 38097 - 22453-900 - Gávea - RJ, Brasil
{musci, raul}@ele.puc-rio.br

²Universidade Estadual do Rio de Janeiro – UERJ
Rua São Francisco Xavier, 524 – 5º andar - 20550-900 - Maracanã - RJ, Brasil
mlfv@centroin.com.br

³Instituto Nacional de Pesquisas Espaciais – INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
tessio@dsr.inpe.br

Abstract. This paper investigates the use of texture descriptors based on Local Binary Pattern (LBP) for applications of automatic interpretation of remotely sensed (RS) images. After describing the use of LBP for applications in RS, the paper reports experiments involving land use and land cover classification respectively on Quickbird-2 and IKONOS-2 imagery. Different configurations for each texture representation approach have been considered in the analysis. In all experiments the LBP features were consistently superior to the traditional Grey-Level Co-occurrence Matrix (GLCM) based texture descriptor in terms of classification accuracy.

Palavras-chave: Sensoriamento remoto, classificação, textura, *local binary pattern*, *urban land use*, *land cover*.

1. Introdução

Descritores de texturas têm sido amplamente utilizados na classificação de imagens, (Alata et al., 1998; Arof e Deravi, 1998; Coburn e Roberts, 2004). Um método para descrição de textura baseado em Padrões Binários Locais (do inglês - *Local Binary Pattern* - LBP), tem sido aplicado mais recentemente em grande sucesso em várias aplicações, tais como inspeção visual e reconhecimento facial, (Mäenpää et al., 2003). Contudo, trabalhos com imagens de sensoriamento remoto utilizando o LBP e suas variantes são pouco numerosos na literatura.

Lucieer e Stein (2005) utilizaram LBP para segmentação de uma área costeira inglesa em imagens multiespectrais e um modelo de elevação. Orkhonselenge (2004) fez uso de imageamento de média resolução para realizar um mapeamento geológico, modelando textura multiespectral, através do LBP em uma única resolução. Song et al. (2010) testaram o LBP em um mosaico sintético de imagens de sensoriamento remoto, em experimentos de classificação que combinavam o descritor de textura e informação espectral.

O objetivo deste trabalho é avaliar o desempenho do LBP como descritor de textura em condições mais representativas de aplicações reais de classificação de imagens de sensoriamento de alta resolução espacial, seguindo uma abordagem baseada em objeto. Em particular avaliam-se neste estudo diversas configurações do LBP multiescala para esta classe de aplicações.

A avaliação é conduzida com base em dois experimentos. O primeiro baseia-se numa imagem Quickbird-2 e explora a classificação de tipos de assentamentos urbanos, como favelas e áreas urbanas de alta/baixa renda. O segundo experimento utiliza uma imagem IKONOS-2 para identificar classes de cobertura do solo.

Nestes experimentos o LBP é comparado com um método tradicional para caracterização de texturas, os descritores baseados em matrizes de co-ocorrência (*Gray Level Co-occurrence Matrix – GLCM*), (Haralick, 1973).

Uma breve descrição do LBP e suas variantes é apresentada na Seção 2. A Seção 3 descreve os experimentos realizados e apresenta e discute os resultados obtidos. Um resumo das principais conclusões e direções futuras são apresentados na Seção 4.

2 – LBP

O LBP associado a um pixel é calculado a partir de um conjunto de P amostras igualmente espaçadas e distribuídas sobre uma circunferência de raio R com centro sobre o pixel. A partir das intensidades g_p de cada uma destas amostras, onde $0 \leq p < P$, e da intensidade do próprio pixel g_c , obtém-se uma seqüência de P valores binários $T_P = \{S(g_0 - g_c), S(g_1 - g_c), \dots, S(g_{P-1} - g_c)\}$, onde $S(x) = 1$ se x for não negativo, e 0 caso contrário.

Um procedimento simples mapeia a seqüência de bits T_P para um valor inteiro. Determinou-se empiricamente que entre as possíveis seqüências T_P , aquelas em que ocorrem no máximo duas transições de 0 para 1 e de 1 para 0 são as mais significativas. Com base nisso, define-se um código $LBP_{P,R}^{riu2}$ invariante a rotação, como sendo o número de 1's da seqüência. Cria-se adicionalmente um código especial para as seqüências em que ocorrem mais do que 2 transições de 1 para 0 ou de 0 para 1, (Ojala et al., 2002). Formalmente

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} S(g_p - g_c) & \text{se \#de transições} \leq 2 \\ P+1 & \text{caso contrário} \end{cases} \quad (1)$$

O LBP uniforme invariante a rotação é igualmente invariante contra transformações monotônicas da escala de cinza, sendo uma boa representação do arranjo espacial dos tons de cinza, e, portanto, da textura, na vizinhança de cada pixel. Esta representação não captura, contudo, a informação de contraste. Uma medida $VAR_{P,R}$ do contraste local, também invariante quanto à rotação, pode ser obtida de modo similar, como mostra a Equação 2.

$$VAR_{P,R} = \frac{1}{P} \sum_{p=0}^{P-1} (g_p - \mu)^2, \text{ onde } \mu = \frac{1}{P} \sum_{p=0}^{P-1} g_p \quad (2)$$

Uma vez definidos os valores de P e R têm-se, desta forma, para cada pixel da imagem dois códigos representando textura e contraste na vizinhança em torno do pixel.

A distribuição conjunta $LBP_{P,R}^{riu2}/VAR_{P,R}$ no interior de um segmento da imagem pode ser aproximada por um histograma discreto bidimensional contendo $((P+2) \times b)$ bins, onde b é o número de bins para $VAR_{P,R}$. Ojala et al. (2002) apresentam evidências empíricas de que esta é uma poderosa ferramenta invariante a rotação para a classificação de texturas.

Na etapa de classificação aplica-se o teste estatístico conhecido como estatística G , (Sokal e Rohlf, 1987) que mede a similaridade entre dois histogramas, como definido na Equação 3

$$G(f_1, f_2) = 2 \left(\frac{\sum_{i=1}^B f_1(i) \log f_1(i) + \sum_{i=1}^B f_2(i) \log f_2(i) - \left(\sum_{i=1}^B f_1(i) \right) \log \left(\sum_{i=1}^B f_1(i) \right) - \left(\sum_{i=1}^B f_2(i) \right) \log \left(\sum_{i=1}^B f_2(i) \right)}{-\sum_{i=1}^B (f_1(i) + f_2(i)) \log (f_1(i) + f_2(i)) + \left(\sum_{i=1}^B f_1(i) + \sum_{i=1}^B f_2(i) \right) \log \left(\sum_{i=1}^B f_1(i) + \sum_{i=1}^B f_2(i) \right)} \right) \quad (3)$$

onde f_1 e f_2 são os histogramas da amostra e do modelo respectivamente e B é o número total de bins. É fácil verificar que quanto mais parecidos forem os histogramas, menor será o valor de G .

Alterando-se os valores de P e R é possível representar a textura em diferentes escalas. Neste caso, a similaridade entre as texturas é dada pela soma das similaridades dos histogramas em escalas correspondentes, ou seja.

$$G_{multi} = \sum_{P,R} G({}^{P,R}f_1, {}^{P,R}f_2) \quad (4)$$

onde ${}^{P,R}f_1$ e ${}^{P,R}f_2$ correspondem aos histogramas da amostra e do modelo respectivamente, obtidos com os parâmetros P e R .

3 – Avaliação Experimental

3.1 Procedimento Geral

As duas próximas seções apresentam os resultados de dois experimentos realizados com o propósito de avaliar os descritores de textura baseados em LBP. Trata-se no primeiro experimento de uma classificação de uso do solo e, no segundo experimento, de cobertura do solo.

Esta seção descreve os procedimentos comuns a ambos os casos. As seções seguintes esclarecem as particularidades de cada experimento.

O objetivo primordial desta avaliação não foi maximizar a acurácia da classificação, mas tão somente comparar os descritores baseados em LBP com os descritores de Haralick, largamente utilizado nas aplicações de sensoriamento remoto. Assim, segmentos da imagem de entrada foram classificados exclusivamente utilizando atributos de textura, muito embora a inclusão de atributos espectrais ou de forma provavelmente levasse a valores de acurácia mais elevados.

Neste trabalho foram utilizadas várias combinações dos descritores $LBP_{P,R}^{riu2}/VAR_{P,R}$ definidas por pares distintos de valores dos parâmetros P e R . Em todos os casos adotaram-se 8 níveis de cinza para o cálculo de $VAR_{P,R}$.

Foram testadas configurações diferentes dos parâmetros do GLCM, especificamente, o número de níveis de cinza ($N_g \in \{128, 64, 32, 16\}$) da imagem, a distância ($d \in \{1, 2, 3\}$) entre os *pixels* e a orientação ($\theta \in \{0^\circ, 45^\circ, 90, 135^\circ\}$). Das matrizes de co-ocorrência extraíram-se os atributos energia, entropia, homogeneidade, contraste, variância e correlação.

Adotou-se como classificador para ambos os grupos de descritores o k -NN, onde o valor de k foi determinado empiricamente em cada caso e para cada conjunto de dados. Em face da relativa escassez de segmentos, optou-se pela estratégia *leave-one-out* para ambos os experimentos. As implementações dos classificadores diferiram apenas na métrica utilizada no cálculo da distância das amostras aos seus vizinhos mais próximos. Nos testes com texturas descritas por LBP foi utilizada a estatística G (Equação 4) como medida de dissimilaridade. Já nos testes com descritores de textura baseados na GLCM foi utilizada a distância euclidiana, depois de normalizarem-se os atributos de modo a terem média nula e desvio padrão unitário.

3.2 Experimento #1 – Classificação de Uso do Solo

Dados

Neste primeiro experimento utilizou-se uma imagem do sensor Quickbird-2 com resolução de 0,6m na banda pancromática e dimensão de 4000×4000 pixels capturada em 31 de março de 2002, que cobre uma área da cidade de São Paulo (coordenadas Norte/Leste 322464/7389053 Sul/Oeste 324872/7386671, projeção UTM-SAD69).

Trata-se nesta aplicação de classificar quanto ao tipo predominante do uso do solo quadras cujos limites constam de um arquivo vetorial fornecido pela Secretaria Municipal

de Planejamento Urbano de São Paulo, (PMSP, 2009). A Figura 1A mostra uma composição RGB da imagem utilizada.

A aplicação previa inicialmente cinco classes de uso do solo: *Urbana de alta renda*, *Urbana de baixa renda*, *Urbana vertical*, *Favela* e *Terreno desocupado*. Em nossos experimentos a classe *Urbana vertical*, devido as suas características peculiares, foi agrupada à classe *Urbana de alta renda*, gerando assim uma única classe denominada *Urbana alta/vertical*.

A Figura 1B mostra a classificação também fornecida pela prefeitura e utilizada como verdade de campo nos experimentos. A Tabela 1 apresenta o número de quadras pertencentes a cada classe do problema.

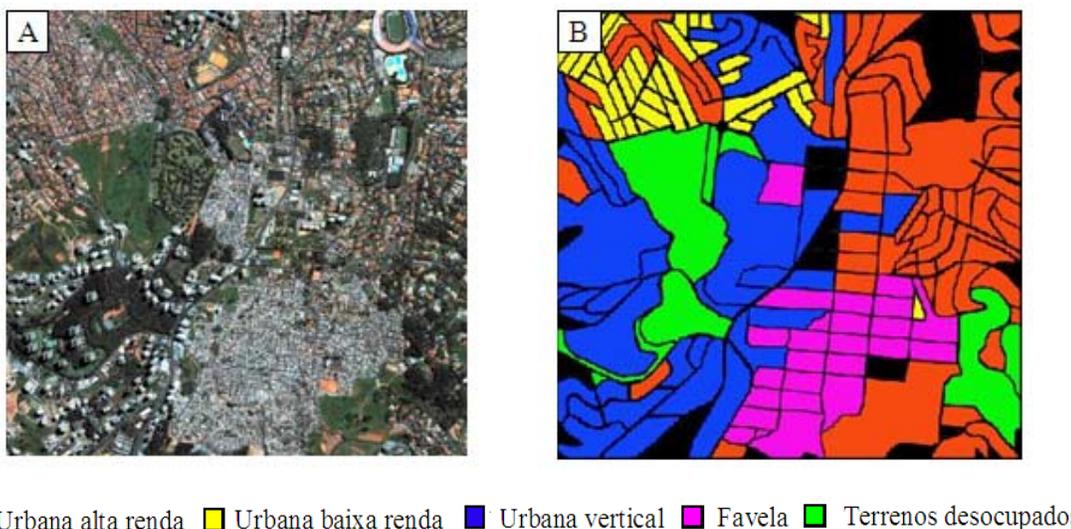


Figura 1 – Imagem Quickbird-2 utilizada no experimento de classificação de uso (A); mapa de uso do solo (B).

Tabela 1 – Distribuição de segmentos entre as classes de uso

Classe	Número de Segmentos
<i>Favela</i>	25
<i>Urbana alta/vertical</i>	101
<i>Terreno desocupado</i>	8
<i>Urbana de baixa renda</i>	42

Resultados

Nos testes realizados com os descritores $LBP_{P,R}^{riu2}/VAR_{P,R}$, o classificador k -NN com $k=9$, trouxe os melhores resultados, os quais podem ser vistos na Tabela 2. São apresentados resultados para diferentes combinações de valores de P e R , denotadas na coluna mais à esquerda pelos rótulos M1 a M6 aos quais se fará novamente referência mais adiante neste texto.

De forma similar, os experimentos com GLCM, foram realizados com diferentes configurações de seus parâmetros. Os melhores resultados neste caso foram obtidos pelo classificador k -NN operando com $k = 5$. Estes são mostrados no gráfico da Figura 2 que apresenta o índice $Kappa$ alcançado por ambos os tipos de descritores nas diversas configurações de parâmetros testadas.

Tabela 2 – Resultados da classificação de uso com descritores LBP

Rótulo	LBP Multiescala (P,R)	Kappa	Favela	Acurácia Média			Acurácia Global
				Urbana alta/vertical	Terreno desocupado	U. Baixa renda	
M1	8,2+16,3+24,5	0,81	0,92	0,95	0,50	0,81	0,89
M2	8,2+16,3	0,80	0,92	0,93	0,50	0,81	0,88
M3	8,2+8,3	0,83	0,92	0,94	0,50	0,84	0,90
M4	8,1+8,3	0,82	0,92	0,94	0,50	0,83	0,89
M5	8,1+16,2+24,3	0,81	0,92	0,94	0,50	0,81	0,89
M6	8,1+8,2+8,3	0,82	0,92	0,94	0,50	0,83	0,89

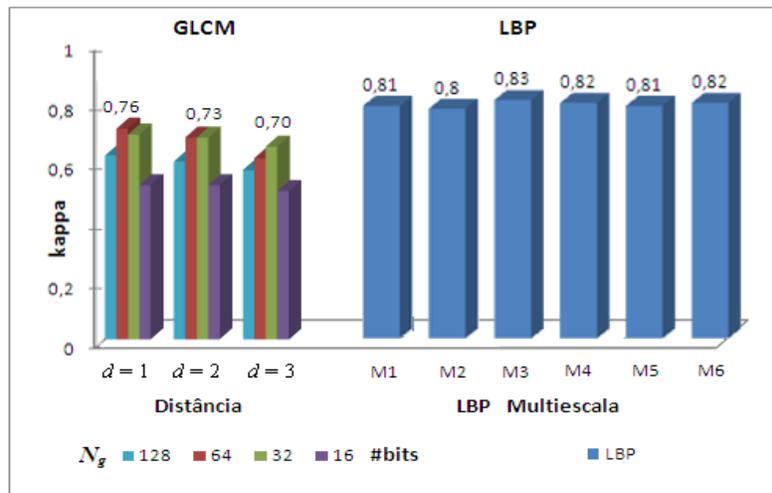


Figura 2 – Comparação de resultados da classificação de uso do solo para descritores LBP e GLCM. Os significados dos rótulos M1 a M6 estão descritos na Tabela 2

3.3 Experimento #2 – Classificação de Cobertura

Dados

Este experimento baseou-se em uma imagem IKONOS-2 pancromática do município do Rio de Janeiro com resolução de 1 m capturada em 30 de maio de 2010 (coordenadas Norte/Leste 7471911/669457 e Sul/Oeste 7453904/688804, UTM-SAD 69, WGS 1984), com dimensão 2800×2000 pixels.

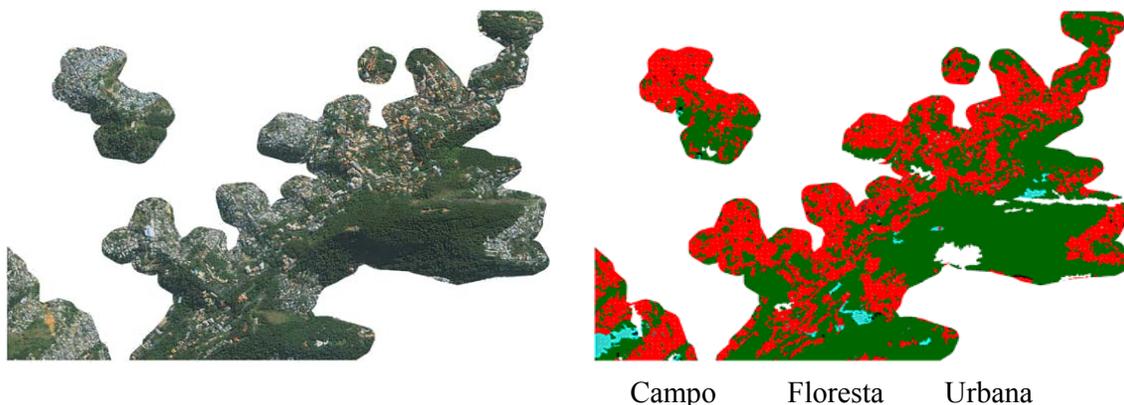


Figura 3 –Área da cidade do Rio de Janeiro, IKONOS-2, (A); mapa de uso do solo (B)

A Figura 3A mostra uma composição RGB da imagem fusionada com as bandas multiespectrais. Toda a área mostrada na Figura 3A foi segmentada utilizando um programa comercial, e os segmentos resultantes foram classificados visualmente, produzindo o mapa mostrado na Figura 3B que apresenta também as classes do problema, isto é, *Campo*, *Floresta*, e *Urbana*. A Tabela 3 traz informações adicionais sobre este mapa que foi usado como verdade de campo.

Tabela 3 – Distribuição de segmentos entre as classes de cobertura

Classe	Número de Segmentos
<i>Campo</i>	5
<i>Floresta</i>	57
<i>Urbana</i>	26

Resultados

A tabela 4 mostra índices de desempenho coletados em nossos experimentos para as mesmas configurações dos parâmetros P e R dos descritores de textura considerados no experimento anterior. Em todos os casos adotou-se $k=1$ para o classificador k -NN, com o que se obtiveram os melhores resultados.

Os valores do índice $Kappa$ são apresentados novamente na Figura 4 à direita. A mesma Figura mostra à esquerda os resultados alcançados utilizando GLCM, com o classificador k -NN, neste caso com $k = 5$, que gerou os melhores índices.

Tabela 4 Resultados da classificação de cobertura com descritores LBP

Rótulo	LBP Multiescala (P,R)	$Kappa$	Acurácia Média			Acurácia Global
			Campo	Floresta	Urbana	
M1	8,2+16,3+24,5	0,84	0,93	0,88	1,00	0,92
M2	8,2+16,3	0,88	0,98	0,85	1,00	0,94
M3	8,2+8,3	0,91	1,00	0,85	1,00	0,96
M4	8,1+8,3	0,88	1,00	0,81	1,00	0,94
M5	8,1+16,2+24,3	0,88	0,98	0,85	1,00	0,94
M6	8,1+8,2+8,3	0,91	1,00	0,85	1,00	0,96

3.4 – Discussões dos Resultados

Os resultados das classificações mostradas nas Figuras 2 e 4 indicam que a metodologia utilizando o LBP obteve os melhores resultados em ambos os testes, alcançando mesmo nos piores resultados um desempenho superior àqueles obtidos com o uso de GLCM. Para a imagem do sensor Quickbird-2 o desempenho do melhor caso, utilizando os descritores $LBP_{8,2}^{riu2}/VAR_{8,2} + LBP_{8,3}^{riu2}/VAR_{8,3}$ foi superior em 9% e na imagem do sensor IKONOS-2 em 12% com ambos os descritores $LBP_{8,2}^{riu2}/VAR_{8,2} + LBP_{8,3}^{riu2}/VAR_{8,3}$ e $LBP_{8,1}^{riu2}/VAR_{8,1} + LBP_{8,2}^{riu2}/VAR_{8,2} + LBP_{8,3}^{riu2}/VAR_{8,3}$.

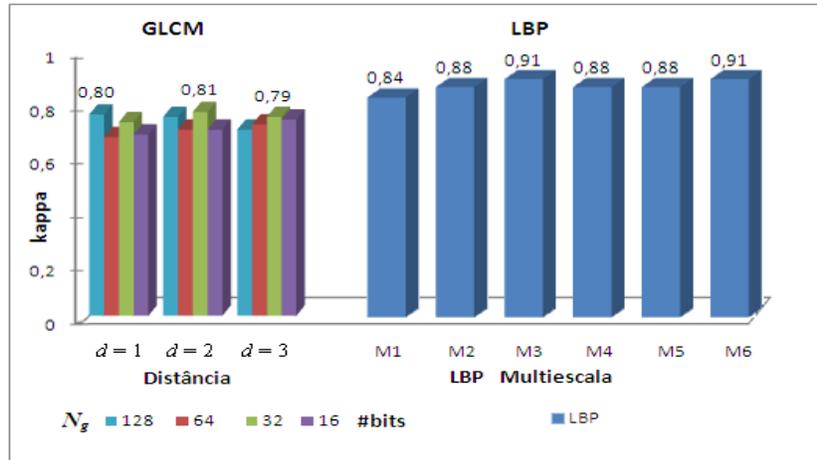


Figura 4 – Comparação de resultados da classificação de cobertura para descritores LBP e GLCM. Os significados dos rótulos M1 a M6 estão descritos na Tabela 4.

As Tabelas 2 e 4 indicam que o uso do LBP nas imagens analisadas, utilizando raios (parâmetro R) maiores do que 3 (M1) não produziram ganhos de desempenho em relação às outras configurações consideradas. Nota-se ainda que, a configuração M3 em que os valores 8,2 e 8,3 para P, R aparecem combinados produziu os melhores resultados em ambos os experimentos.

Cabe mencionar que no primeiro experimento algumas quadras se compõem de partes que muito claramente correspondem a mais de uma classe, o que provavelmente prejudicou os índices medidos para ambos os tipos de descritores, como ilustra a Figura 5.



Figura 5 – Exemplos de segmentos com sobreposição de classes da Imagem1

4. Conclusão

Neste trabalho, avaliaram-se técnicas baseadas em Padrões Binários Locais (*Local Binary Patterns - LBP*) para descrição de texturas em imagens de sensores remotos de alta resolução espacial. Em dois experimentos utilizando imagens Quickbird-2 e IKONOS-2 os atributos LBP alcançaram consistentemente melhores índices de acurácia do que os atributos de Haralick.

O presente estudo limitou-se a considerar o aspecto desempenho da classificação. Os atributos baseados em LBP têm ainda outras características potencialmente interessantes que merecem ser exploradas em um estudo subsequente. Há razões para acreditar que o número de segmentos necessários para caracterizar uma classe de textura através de um histograma seja substancialmente menor para o LBP do que para outros métodos, o que poderá simplificar o processo de coleta de amostras em aplicações que usam métodos supervisionados de classificação.

Por outro lado, os histogramas LBP/VAR ocupam muito espaço, o que restringe a escolha do classificador a ser utilizado. Outros descritores, como os de Haralick, por exemplo, tem dimensão comparativamente menor, o que facilita a implementação de soluções com classificadores mais sofisticados do que o k -NN.

Outro aspecto a ser investigado futuramente é a combinação destes descritores de textura com outros atributos espectrais e de forma.

Cabe por fim mencionar que trabalhos recentes introduziram formas de representação de textura similares ao LBP que apresentaram resultados superiores ao LBP em certas classes de aplicações. Os resultados apresentados neste trabalho encorajam a investigação destas técnicas para aplicações em sensoriamento remoto.

Referências Bibliográficas

Alata, O.; Cariou, C.; Ramananjara, C.; Najim, M. Classification of Rotated and Scaled Textures Using HMMV Spectrum Estimation and the Fourier-Mellin Transform. **Proceedings IEEE International Conf. on Image Processing**, v. 1, p. 53-56, 1998.

Arof, H.; Deravi, F. Circular Neighbourhood and 1-D DFT Features for Texture Classification and Segmentation. **Proceedings. IEE Vision Image, and Signal Processing**, v. 145, p. 167-172, 1998.

Coburn, C. A.; Roberts, A. C. B. A multiscale texture analysis procedure for improved forest stand classification, **International Journal of Remote Sensing**, v. 25(20), p.4287-4308, 2004.

Ella, A., P.; Bergh F., D.; Van Wyk, B.J.; Van Wyk, M. A. A comparison of texture feature algorithms for urban settlement classification. In: **IEEE International GeoSciences and Remote Sensing Symposium (IGARSS)**, Boston, MA, U.S.A., p. 1308-1311, 6-11 July 2008.

Haralick, R. M.; Dinstein, I.; Shanmugam, K. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 3, p. 610-621, 1973.

Lucieer, A.; Stein, A. Texture-based landform segmentation of LiDAR imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 6(3-4), p. 261-270, 2005.

Mäenpää, T.; Turtinen, M.; Pietikäinen, M. Real-time surface inspection by texture. **Real-Time Imaging**, v. 9, part 5, p. 289-296, 2003.

Ojala, T.; Pietikäinen, M. Multiresolution gray scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 7, p. 971-987, 2002.

Orkhonselenge, T. Texture based segmentation of remotely sensed imagery for identification of geological units. M.Sc. thesis, **International Institute for Geo-information Science and Earth Observation**, Enschede, 2004.

PREFEITURA MUNICIPAL DA CIDADE DE SAO PAULO (PMSP). **InfoLocal**, Disponível em: <http://infolocal.prefeitura.sp.gov.br/> Acesso em 19 abr. 2009.

Sokal, R. R.; Rohlf, F.J. **Introduction to Biostatistics**. 2nd. W.H. Freeman and Co, New York, 1987.

Song, C.; Fengjie Yang, F.; Li, P. Rotation Invariant Texture Measured by Local Binary Pattern for Remote Sensing Image Classification. In. **Education Technology and Computer Science (ETCS), Second International Workshop on**, Wuhan, p. 3-6, 6-7 March 2010, ISBN: 978-1-4244-6388-6.