

Nome: Érika Akemi Saito

Resumo do artigo: F. Pacifici et al. / Remote Sensing of Environment 113 (2009) 1276–1292

A NEURAL NETWORK APPROACH USING MULTI-SCALE TEXTURAL METRICS FROM VERY HIGH-RESOLUTION PANCHROMATIC IMAGERY FOR URBAN LAND-USE CLASSIFICATION

Fabio Pacifici, Marco Chini, William J. Emery

Este estudo utilizou imagens pancromáticas de alta resolução espacial do QuickBird e WorldView-1 para classificar acuradamente o uso do solo de quatro diferentes ambientes urbanos: Las Vegas, Roma, Washington e São Francisco. O método proposto se baseia na análise da primeira e segunda ordem multi-escala textural das feições extraídas de um dado pancromático. Para este propósito, parâmetros texturais foram sistematicamente investigados computacionalmente a partir de cinco diferentes tamanhos de janelas, três diferentes direções e duas diferentes células de mudança para um total de 191 feições de entrada.

Textura é um termo usado para caracterizar a tonalidade ou as variações no nível de cinza em uma imagem. O tamanho da janela usada para computar a textura tem um papel importante na extração da textura: tamanhos grandes de janela são mais apropriadas para resoluções finas que uma resolução grossa (Shaban & Dikshit, 2001). A inclusão de uma simples característica de textura no dado espacial de entrada aparece para melhorar significativamente a acurácia global da classificação (Shaban & Dikshit, 2002).

Foram investigadas seis diferentes características texturais de segunda-ordem (homogeneidade, contraste, dissimilaridade, entropia, segundo momento e correlação) derivadas do GLCM (Gray-level co-occurrence matrix) e duas características texturais de primeira-ordem.

A **homogeneidade** é o parâmetro mais sensível para a presença de elementos próximos a diagonal no GLCM. O **contraste** leva em conta a frequência espacial, que é a diferença na amplitude entre o maior e o menor valor de um conjunto contínuo de pixels. A **dissimilaridade** mede qual a diferença na co-ocorrência dos elementos da matriz em relação a cada outro e é alto quando o local da região tem um alto contraste. A **entropia** mede a desordem na imagem, quando a imagem é uniforme a entropia é alta. O **segundo momento** mede a uniformidade textural, por exemplo, pares de pixels repetidos. A **correlação** é expressa pelo coeficiente de correlação entre dois ranges de variáveis.

As estatísticas de primeira ordem podem ser computadas pelo histograma de intensidades dos pixels da imagem. Este depende unicamente do valor individual do pixel e não da interação ou co-ocorrência dos valores dos pixels vizinhos. Os parâmetros de primeira-ordem usados nesse paper são a média e a variância. As informações texturais são valores para discriminar a diferença das classes que possuem similaridade da resposta espectral. Ao mesmo tempo, é necessário explorar a multi-escala para aproximar melhor com objetos que tem diferenças espaciais na cobertura da área. Para este propósito, oito características foram definidas e computadas em cinco diferentes tamanhos de janelas 3x3, 7x7, 15x15, 31x31, 51x51 pixels (sobre 1,5-1,8 m, 3,5-4,2 m, 7,5-9,0 m, 15,5-18,6 m e 25,5-30,6 m, com o WorldView-1 e Quickbird, respectivamente), três diferentes direções 0°, 45° e 90° e dois diferentes tamanhos de

células com valores de 15 e 30 pixels para um total de 191 características texturais, que estão na tabela 5.

Table 5

Input space resulting from panchromatic band, first- and second- order textural features.

	Input features	Cell Size (pixel)	Step (pixel)	Direction (°)	# Inputs
First-order	Panchromatic				1
	Mean	3×3			10
	Variance	7×7			
		15×15			
		31×31			
	51×51				
Second-order	Homogeneity	3×3	15	0	180
	Contrast	7×7	30	45	
	Dissimilarity	15×15		90	
	Entropy	31×31			
	Second Moment	51×51			
	Correlation				
Total input features					191

A dimensão da janela e os valores de mudança foram baseados na análise prévia do trabalho de Small (2003) que estimou a característica do comprimento da escala em 6357 cidades em 14 áreas urbanas em torno do mundo, mostrando quais as maiores cidades tem características no comprimento de escala entre 8.0 e 24.0 m. A Figura 5 apresenta a contribuição relativa de cada característica de entrada, que não estão eliminadas pela extensão *pruning*.

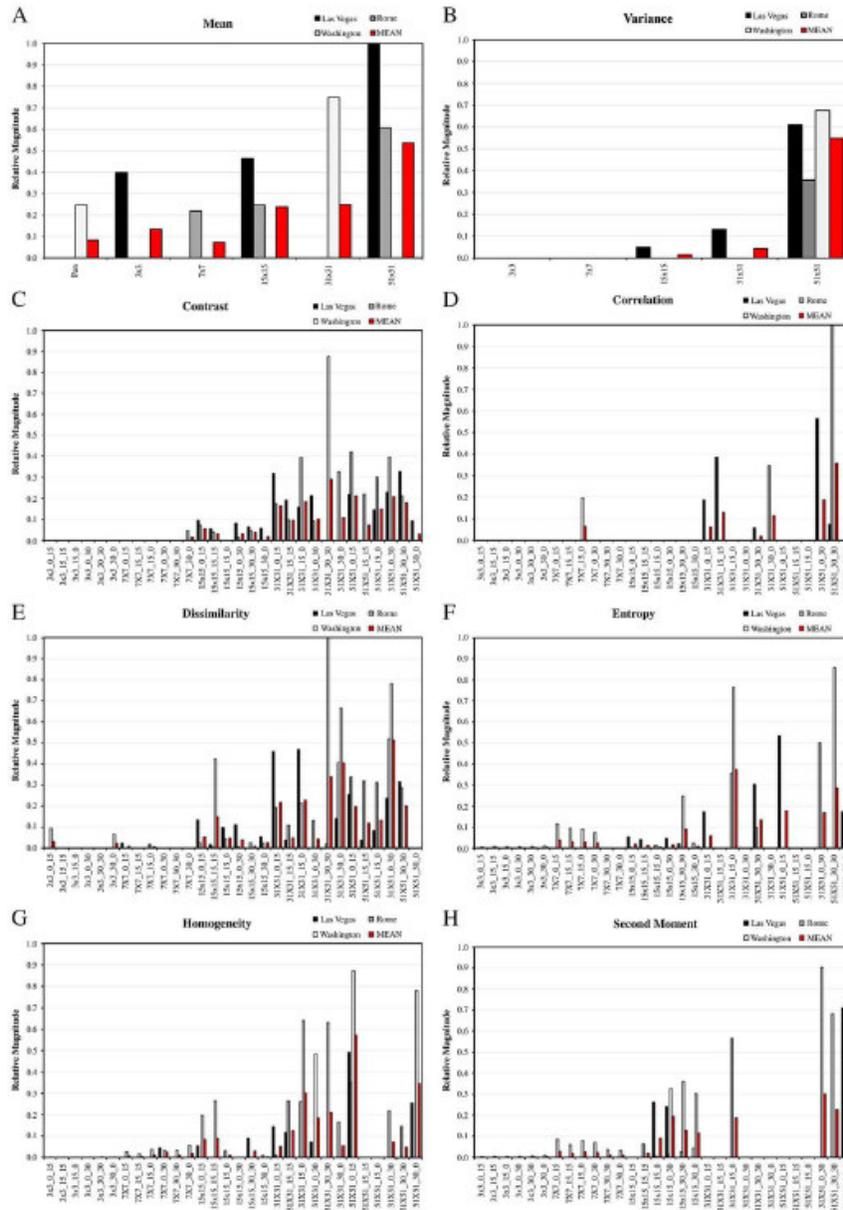


Fig. 5. Relative feature contribution of the input features not eliminated by the extended pruning of (A) Panchromatic and Mean, (B) Variance, (C) Contrast, (D) Correlation, (E) Dissimilarity, (F) Entropy, (G) Homogeneity and (H) Second Moment computed over all window size, directions and shifts. The mean values of these contributions, shown in red, highlights that many of the remaining inputs have a smaller influence on the classification process compared to other features. (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)

Para analisar a importância dos parâmetros de textura a respeito da escolha do tamanho das células e direções os autores computaram para cada um deles, a contribuição de cada característica na soma sob diferentes tamanhos de células e direções (Fig. 6). A Fig. 6A mostra que a banda pancromática, não contém nenhuma informação no tamanho da célula e direções, tendo assim pouca contribuição.

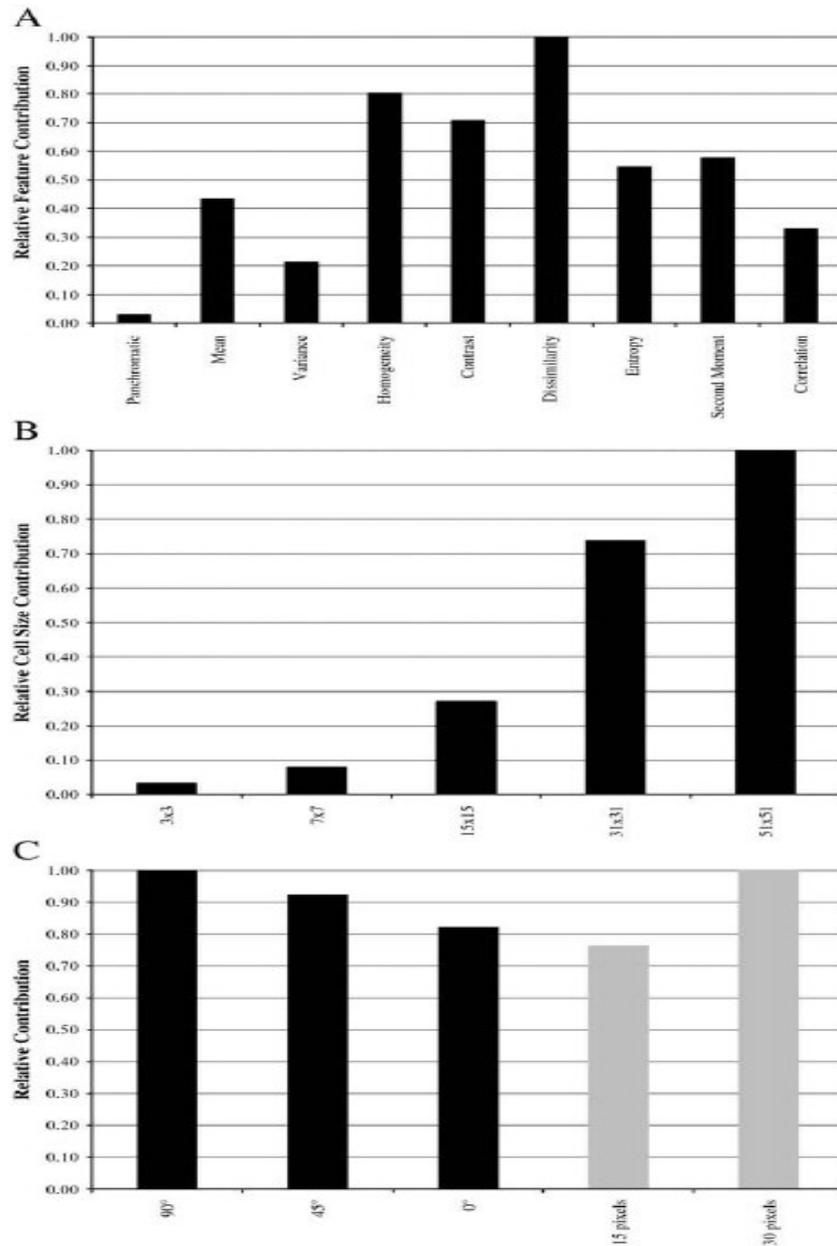


Fig. 6. Feature contributions with respect to textural parameters, window sizes and directions. In (A) is shown the contributions of textural parameters regardless of the choice of cell sizes and directions. Dissimilarity appears to be the most informative texture parameter. In (B) is shown the importance of the cell sizes, regardless of the choice of textural parameters and directions. In (C), the three directions (in black) and the two-step size (in gray) show high and relatively similar contributions, meaning that both directions and step sizes are relevant for the classification phase.

As características texturais de primeira-ordem, que não contem nenhuma informação ou direção, tem menor contribuição que as características de segunda-ordem. A dissimilaridade aparece como o parâmetro de textura mais informativo, ainda se é similar ao Contraste. Este pode relatar a linearidade do peso da tonalidade do nível de cinza na cena. Desse mesmo modo foram analisadas a importância do tamanho das células com respeito a seleção dos parâmetros de textura e direções.

Na Fig 6B estão ilustradas onde as células grandes de 31x31 e 51x51 apresentam alta contribuição. Na Fig 6C, as três direções (em preto) e o tamanho dos dois passos (em

cinza) tem alta e contribuição similar, significa que o corpo de direção e o tamanho do passo são relevantes para a fase de classificação.

Para uma investigação adicional da contribuição das características, a frequência da característica de entrada e sua contribuição estão apresentadas na Fig. 7, cujo ponto mais alto que o menor mostra uma contribuição relativa maior que 0.30.

Table 7

Best ten features and corresponding feature contribution averaged over three cities and several different land-uses classes.

Best 10 features	Relative input feature contribution
Mean 51 × 51	0.535
Variance 51 × 51	0.547
Homogeneity 51 × 51_0_15	0.572
Homogeneity 51 × 51_30_0	0.345
Dissimilarity 31 × 31_30_30	0.339
Dissimilarity 31 × 31_30_0	0.404
Dissimilarity 51 × 51_0_30	0.512
Entropy 31 × 31_15_0	0.374
Second Moment 51 × 51_0_30	0.301
Correlation 51 × 51_30_30	0.357

As características texturais de primeira-ordem, que não possuem nenhuma informação na direção tem baixa contribuição que as de segunda ordem. A Dissimilaridade aparece como o parâmetro de textura dominante. Para a resolução espacial nos testes dos casos estudados, as células grandes, com 31x31 e 51x51 pixels, mostraram alta contribuição que as células de tamanho pequeno (com respeito na escolha dos parâmetros de textura e direções), demonstrando que há necessidade de explorar melhor esta informação direcional. Entretanto, muitos dos dados de entrada sobraram, depois da fase de estendida pelo *pruning*, tendo uma pequena influência no processo de classificação comparado com outras características. Especificamente, muitos poucos dados de entrada mostraram uma contribuição relativamente maior que 0.30 como mostrou a tabela 7. Como esperado, a drástica redução da característica de entrada (sobre 60 para 10) diminuindo a acurácia da classificação da cena de Washington para 0.861 com relação a extensão do resultado do *pruning*.

Referências

- Shaban, M. A., & Dikshit, O. (2001). Improvement of classification in urban areas by the use of textural features: The case study of Lucknow city, Uttar Pradesh. *International Journal of Remote Sensing*, 22, 565–593.
- Shaban, M. A., & Dikshit, O. (2002). Evaluation of the merging of SPOT multispectral and panchromatic data for classification of an urban environment. *International Journal of Remote Sensing*, 23, 249–262.
- Small, C. (2003). High spatial resolution spectral mixture analysis of urban reflectance. *Remote Sensing of Environment*, 88, 170–186.