

AVALIAÇÃO DE MÉTODOS DE ANÁLISE DE TEXTURAS APLICADAS EM IMAGENS DIGITAIS DE TERRENOS

Schwartz, William R. e Pedrini, Hélio

Departamento de Informática, Universidade Federal do Paraná, Curitiba-PR, {william, helio}@inf.ufpr.br

RESUMO: Devido ao aumento na quantidade de dados obtidos a partir de dispositivos de captura em alta resolução, a utilização de processos manuais para interpretação de imagens torna-se uma tarefa praticamente inviável. Dessa maneira, métodos automáticos de segmentação e classificação passam a apresentar fundamental importância no processo de análise de imagens. Para que resultados precisos sejam obtidos, torna-se necessária a definição de um conjunto de características capazes de descrever de maneira efetiva as regiões contidas em uma imagem. Embora existam diversos métodos que utilizam a análise de texturas para efetuar a referida descrição, não há um conjunto de medidas que descreva adequadamente imagens em domínios distintos de aplicações. Dessa maneira, tem-se a necessidade de se avaliar os métodos existentes com o propósito de determinar aqueles que melhor se adaptam a determinadas áreas de aplicações. Devido à existência de um número reduzido de trabalhos que visam à comparação dos métodos de análise de imagens por meio de características de texturas para a área de sensoriamento remoto e à importância de que seja efetuada uma descrição precisa das regiões contidas em uma imagem, este trabalho avalia as principais metodologias de análise de texturas com aplicação em amostras de terrenos.

ABSTRACT: Due to the increase in the amount of data obtained from acquisition devices in high resolution, the use of manual processes for interpretation of images becomes a practically impracticable task. In this way, automatic methods of segmentation and classification have a fundamental importance in the process of image analysis. In order to produce precise results, it is crucial the definition of a feature set capable of efficiently describing the regions contained in an image. Although several methods exist that use the analysis of textures to perform the mentioned task, there is no general set of measures that adequately describes images in distinct application domains. Therefore, it is relevant to evaluate the existing methods with the intention to determine those that better adapt to certain application areas. Due to the existence of a reduced number of works whose purpose is to compare image analysis methods by means of texture features for remote sensing area, associated to the importance of that a necessary description of the regions contained in an image, this paper evaluates the main methodologies of texture analysis applied to terrain data samples.

PALAVRAS-CHAVE: Análise de texturas, segmentação, classificação, imagens digitais de terreno

1 INTRODUÇÃO

Com o aumento no volume de dados obtidos a partir de dispositivos de captura em alta resolução, a utilização de processos manuais para interpretação de imagens apresenta-se como uma tarefa árdua e muitas vezes impraticável. Dessa maneira, as etapas de segmentação e classificação, as quais produzem estruturas de alto nível que viabilizam o processo de interpretação, passam a ser fundamentais no processo de análise de imagens.

Por serem extremamente dependentes da correta extração de características das regiões presentes na imagem, essas etapas apresentam-se como um grande desafio para a comunidade científica. Embora essa extração possa

ser efetuada diretamente a partir da intensidade dos pixels, métodos que utilizam a propriedade de textura têm proporcionado resultados mais acurados.

Diversos métodos para análise de texturas têm sido propostos na literatura (Tuceryan e Jain 1998), entretanto, não existe um único conjunto de medidas capaz de descrever de maneira eficiente imagens em domínios distintos de aplicações. Adicionalmente, são escassos os trabalhos que avaliam tais métodos, determinando aqueles que melhor se adaptam a áreas de aplicações específicas.

As abordagens presentes nos trabalhos elaborados para avaliação dos métodos de análise de texturas se restringem a um número reduzido de metodologias ou à comparação de imagens que não compõem uma área de

aplicação específica. Dentre os trabalhos existentes estão os propostos por Connors e Harlow (1980), Ohanian e Dubes (1992), Randen e Husoy (1999), Singh e Singh (2002) e Weszka et al. (1976).

Considerando a importância de uma eficiente extração de características para as etapas de segmentação e classificação de imagens, bem como o número reduzido de trabalhos que avaliam os métodos de análise de texturas, particularmente aplicados a imagens de sensoriamento remoto, este trabalho propõe uma série de experimentos visando comparar o desempenho obtido por esses métodos quando aplicados a imagens de terrenos.

Este trabalho está dividido como segue. A seção 2 descreve os métodos de análise de texturas a serem avaliados. A metodologia a ser empregada para a avaliação é apresentada na seção 3, enquanto na seção 4 os resultados são expostos e analisados. Finalmente, a seção 5 descreve as conclusões obtidas com a elaboração deste trabalho.

2 MÉTODOS DE ANÁLISE DE TEXTURAS

Devido ao fato da textura conter informações sobre a distribuição espacial e a variação de luminosidade, além de descrever o arranjo estrutural das superfícies e relações entre regiões vizinhas, informações texturais são de grande valia para compor um conjunto de medidas capaz de efetuar uma representação efetiva das propriedades apresentadas pelas regiões de uma imagem.

Normalmente, a descrição de regiões texturizadas é efetuada por meio de métodos de extração de características, os quais visam obter uma representação significativa de cada região. Tais métodos, descritos nas próximas seções, dividem-se, segundo a classificação proposta por Tuceryan e Jain (1998), entre as abordagens *estatística*, *baseada em processamento de sinais*, *geométrica* e *baseada em modelos*. Não é a intenção deste trabalho descrever detalhadamente cada uma dessas abordagens e sim apontar os principais aspectos de cada uma.

2.1 Abordagem Estatística

Os métodos que utilizam a abordagem estatística não buscam compreender explicitamente a estrutura hierárquica da textura, mas sim tentam representar a textura indiretamente por propriedades não determinísticas que definem distribuições e relacionamentos entre os níveis de cinza dos pixels de uma imagem.

O histograma dos níveis de cinza provê informações estatísticas de primeira ordem, pois cada pixel é considerado de maneira individual durante a determinação da distribuição dos níveis de cinza. Embora as estatísticas de primeira ordem apresentem algumas desvantagens (Tuceryan e Jain 1998), o custo computacional apresentado na

determinação das características é baixo.

Métodos baseados em estatísticas de segunda ordem têm demonstrado alto poder discriminativo em uma grande variedade de imagens. Uma das abordagens utilizadas para adquirir informações sobre transições de níveis de cinza entre dois pixels é aquela obtida através da construção da matriz de co-ocorrência (Haralick et al. 1973), baseada na ocorrência repetida da configuração de alguns níveis de cinza na textura.

A amostragem de regiões colineares que compõem uma imagem permite que sejam encontradas corridas de cinza, compostas por pixels consecutivos que apresentam os mesmos valores de nível de cinza. Com o objetivo de sintetizar as informações obtidas a partir dessas corridas, Galloway (1975) propõe a criação das matrizes de comprimento de corridas de cinza, cujos elementos contêm o número de corridas com um dado tamanho para um determinado nível de cinza, provendo desta maneira, estatísticas de ordem superior a serem utilizadas na análise de texturas.

Uma maneira de diferenciar texturas ásperas de texturas finas baseia-se na detecção da frequência espacial, determinada pela ocorrência de variações de nível de cinza em uma região específica. Texturas finas são compostas por primitivas com tamanho pequeno e apresentam frequência espacial alta, enquanto as texturas ásperas, compostas por primitivas maiores, são caracterizadas por possuírem frequência espacial baixa. Para determinar a frequência espacial contida em uma textura utiliza-se a função de autocorrelação (Haralick 1979).

2.2 Abordagem Baseada em Processamento de Sinais

Os métodos de análise de texturas baseados em processamento de sinais possuem a característica de extrair descritores a partir da representação obtida após a execução de transformações na imagem de entrada.

O espectro resultante da transformada bidimensional de Fourier apresenta grande concentração de energia no centro do plano de frequências para texturas ásperas, enquanto que, para texturas finas, a energia do espectro encontra-se espalhada pelo plano. Desse modo, a partir do espectro de Fourier pode-se avaliar a aspereza de texturas. Como características utiliza-se funções obtidas a partir do espectro (Nadler e Smith 1993).

Técnicas que aplicam multi-resolução em imagens, tais como *wavelets*, objetivam alterar a representação de modo que tanto informações sobre frequência quanto informações espaciais estejam presentes. O uso da transformada *wavelet* foi proposta inicialmente para análise de texturas no trabalho de Mallat (1989). A energia de cada sub-imagem (de Wouwer et al. 1999) encontra-se como uma das características extraídas a partir dos coeficientes da transformada *wavelet*.




Figura 1. Imagens utilizadas para avaliação dos métodos de análise de texturas, obtidas no repositório *Earth Sciences and Image Analysis, NASA-Johnson Space Center*. O conjunto é composto por imagens aéreas representando mar, deserto, dunas, floresta, geleira, montanhas, nuvens, rio, região urbana e vegetação rasteira.

2.3 Abordagem Geométrica

Na abordagem geométrica, uma textura é definida como sendo composta por primitivas que, após serem identificadas, permitem a extração de medidas capazes de descrever a textura.

He e Wang (1990) propõem um método baseado na idéia de que uma imagem texturizada pode ser considerada como um conjunto de pequenas unidades essenciais, denominada unidade de textura, as quais caracterizam a informação local de um dado pixel em relação aos seus vizinhos. Medidas extraídas a partir de todas as unidades presentes na imagem revelam o aspecto global da textura.

Hornig et al. (2002) propõem o método denominado codificação de características de texturas, utilizando medidas para descrição das características. Altera-se o conceito de unidade de textura definido por He e Wang (1990), considerando apenas a sua conectividade.

2.4 Abordagem Baseada em Modelos

Nesta abordagem, cada textura é considerada como uma amostra extraída de um processo estocástico definido por um conjunto de parâmetros que, servindo como modelo para textura, resumem suas características. Nesta abordagem encontram-se os métodos baseados em campos aleatórios e fractais.

A análise de texturas baseada em campos aleatórios de Markov (MRF) utiliza os parâmetros obtidos a partir da distribuição de probabilidade das características locais. A distribuição do MRF que segue o modelo generalizado de Ising (Rosholm 1997) pode ser utilizada para modelagem de texturas.

3 METODOLOGIA DE AVALIAÇÃO

Assim como na maioria dos trabalhos, a abordagem desenvolvida para avaliação dos métodos de análise de texturas descritos na seção 2 baseia-se na classificação de amostras de texturas apresentando tamanhos distintos.

Os resultados apresentados nos gráficos da seção 4 são obtidos a partir do processo de classificação efetuado sobre o conjunto de terrenos mostrado na figura 1. Para se obter valores estáveis, cada experimento é executado cinco vezes e utiliza-se o valor médio dos resultados obtidos.

No conjunto da figura 1, cada imagem é composta por 512×512 pixels e 256 tons de cinza, exceto no experimento 2(g) onde se considera variações no número de tons de cinza das texturas. A partir de cada uma são obtidas 150 amostras escolhidas aleatoriamente, dentre as quais 100 são utilizadas para obtenção do conjunto de treinamento e 50 são posteriormente classificadas.

Para cada região amostrada, características de texturas são extraídas, de modo que cada medida retornada seja acrescentada em um vetor de características, utilizado na descrição da região. Uma desvantagem em utilizar diretamente o vetor de características se deve às diferenças de escalas encontradas nas medidas, ocasionando ponderações indevidas. Para minimizar este problema, efetua-se a padronização das medidas (Theodoridis e Koutroumbas 2003).

Uma vez estimados os parâmetros, a partir do conjunto de treinamento, para descrição das regiões de terrenos que compõem o conjunto mostrado na figura 1, utiliza-se o classificador quadrático para atribuir cada amostra a uma das possíveis classes.

4 RESULTADOS EXPERIMENTAIS

Esta seção apresenta uma série de experimentos visando à avaliação dos métodos de análise de texturas, considerando os aspectos de qualidade e tempo de execução. Sem observar esse compromisso, a utilização das etapas de segmentação e classificação de imagens pode ser inviabilizada por apresentar resultados impróprios ou alto custo computacional.

4.1 Detalhes de Implementação

Todos os experimentos efetuados foram executados em microcomputador Pentium IV 1600 MHz com 256 Mbytes de memória RAM utilizando linguagem de programação C com o sistema operacional Linux. A seguir são descritos os detalhes de implementação para os métodos de análise de texturas.

Na implementação do modelo generalizado de Ising, considera-se as vizinhanças de primeira, segunda, terceira e quarta ordens, tendo número de parâmetros igual a 3, 5, 7 e 9, respectivamente (Rosholm 1997). A ordem da vizinhança que apresenta melhor resultado para classificação é avaliada experimentalmente.

Para o método de codificação de características de texturas são consideradas a aspereza, homogeneidade, convergência média, variância, entropia de código e a similaridade de código, conforme um parâmetro Δ (Horng et al. 2002). Esse parâmetro, que denota a tolerância para variação dos tons de cinza entre pixels vizinhos, é determinado experimentalmente.

A função de autocorrelação implementada possui dois parâmetros a serem ajustados, p e q , esses representando o deslocamento presente entre duas amostras da textura (Haralick 1979). Nos experimentos efetua-se variações nesses parâmetros, considerando que os valores de p e q são iguais, ambos estão diretamente relacionados ao número de medidas a serem acrescentadas no vetor de características.

Para o método baseado em unidade de textura são implementadas as medidas de simetria preto-branco, simetria geométrica e o grau de direção (He e Wang 1990).

A partir da matriz de co-ocorrência são extraídas as medidas de entropia, segundo momento angular, contraste, correlação, variância e homogeneidade, sendo que o vetor de características é composto pela média de cada medida para as orientações de 0° , 45° , 90° e 135° , as quais indicam como o relacionamento é considerado (Haralick et al. 1973). Para determinar o parâmetro d , que denota a distância entre os pixels relacionados, são testados valores entre 1 e 6.

No método baseado em matrizes de comprimento de corridas de cinza são implementadas as medidas origi-

nalmente propostas por Galloway (1975), ênfase em corridas curtas, ênfase em corridas longas, não uniformidade de tom de cinza, não uniformidade de tamanho de corrida e percentagem de corrida. Tais medidas são extraídas a partir das matrizes determinadas para corridas apresentando orientações de 0° e 90° .

Para o método baseado em transformada *wavelet*, considera-se a família de funções Daubechies 4, efetuando-se uma decomposição em dois níveis. Os coeficientes de energia são obtidos a partir das sub-imagens que apresentam frequências mais altas (de Wouwer et al. 1999).

Finalmente, os dois últimos métodos implementados baseiam-se em estatísticas de primeira ordem e no espectro de Fourier. Para o primeiro, calcula-se o desvio padrão, média, assimetria, curtose, energia e a entropia a partir do histograma de tons de cinza. Já no segundo, determina-se a variância e a média a partir da função $S(\theta)$, obtida a partir do espectro de Fourier (Nadler e Smith 1993).

4.2 Descrição dos Experimentos


Os tons de cinza que compõem cada amostra podem ser utilizados diretamente para sua descrição, entretanto, além de serem correlacionados, o espaço de características apresenta dimensionalidade muito elevada, o que acarreta resultados impróprios e alto custo computacional.

Com intuito de mostrar os efeitos da classificação efetuada a partir dos tons de cinza, os gráficos das figuras 2(a) e 2(b) apresentam o desempenho obtido na classificação e o tempo requerido por esta, onde o eixo das abscissas representa o tamanho da amostra e o eixo das ordenadas denota a classificação correta, normalizada entre 0 e 1, e o tempo mostrado em segundos, respectivamente.


Alguns dos métodos de análise de texturas apresentam parâmetros que, conforme os valores assumidos proporcionam resultados distintos na classificação. Dentre esses métodos estão a estimação dos parâmetros pelo modelo generalizado de Ising (figura 2(c)), método de codificação de características de texturas (figura 2(d)) e o método de autocorrelação (figura 2(e)). Nesses experimentos, o eixo das abscissas e ordenadas indicam, respectivamente, o tamanho da amostra e a classificação obtida.

Para o método baseado em matrizes de co-ocorrência, efetua-se alterações no parâmetro d e no número de tons de cinza que compõem a textura, conforme mostrado nas figuras 2(f) e 2(g). As alterações efetuadas no número de níveis de cinza estão diretamente relacionadas ao tempo requerido para a extração das características.


Utilizando os parâmetros que proporcionam melhor desempenho nos experimentos mostrados nas figuras 2(c) a 2(g), cria-se os gráficos mostrados nas figuras 2(h) e 2(i), onde são comparados o tempo requerido e o resultado ob-




(a) Classificação utilizando os próprios tons de cinza como característica de texturas.




(b) Tempo de execução conforme o tamanho da janela, utilizando os próprios tons de cinza como característica de texturas.




(c) Classificação efetuada com alterações na ordem da vizinhança do método baseado no modelo generalizado de Ising.




(d) Classificação efetuada com alterações no parâmetro Δ do método de codificação de características de texturas.




(e) Classificação efetuada com alterações nos parâmetros p e q da função de autocorrelação.




(f) Classificação obtida alterando o parâmetro d do método baseado em matrizes de co-ocorrência.



(g) Classificação obtida com a variação no número de tons de cinza da imagem.



(h) Tempo requerido para classificação.



(i) Classificação obtida.

Figura 2. Experimentos efetuados utilizando-se os métodos de autocorrelação (Au), transformada *wavelet* (Da), estatísticas de primeira ordem (Fi), espectro de Fourier (Fo), matrizes de comprimento de corridas de cinza (Ga), unidade de textura (He), codificação de características de texturas (Ho), matrizes de co-ocorrência (Ha) e modelo generalizado de Ising (Is). Na legenda das figuras 2(a) e 2(b), Vap e Van denotam, respectivamente, variáveis com e sem padronização.

tido na classificação, respectivamente. O tempo para o modelo generalizado de Ising é mostrado no gráfico pois apresenta ordem de grandeza muito maior que os demais.

4.3 Análise dos Resultados Obtidos

A figura 2(a) mostra que a classificação correta alcançada com níveis de cinza é baixa, mesmo quando se utiliza variáveis padronizadas. Dessa maneira, torna-se interessante a aplicação de métodos capazes de resumir as propriedades apresentadas pelas regiões da imagem e

que possibilitem a redução na dimensionalidade dos dados, esta justificada diretamente pelo gráfico da figura 2(b) que, mesmo para amostras de tamanho pequeno, a aplicação dos tons de cinza apresenta alto custo computacional.

Para o modelo generalizado de Ising, em geral, os melhores resultados são obtidos quando se considera vizinhança de quarta ordem para o campo aleatório de Markov. Embora a vizinhança de segunda ordem apresente bom desempenho quando são analisadas amostras compostas de 8×8 pixels, para amostras maiores, quanto maior a ordem da vizinhança melhores são os resultados obtidos.

Os experimentos efetuados para determinar os melhores valores para o parâmetro Δ do método de codificação de características mostram que, para amostras com 8×8 e 16×16 pixels, $\Delta = 6$ e $\Delta = 9$ proporcionam os melhores resultados, porém, para as outras configurações, $\Delta = 0$ é aquele que resulta na melhor classificação. Esse último valor é considerado durante a comparação entre os métodos.

A utilização da função de autocorrelação com os parâmetros p e q iguais a 7 proporciona os melhores resultados para classificação, embora obtenha desempenho inferior para amostras compostas de 8×8 pixels. Valores maiores de p e q não foram avaliados devido ao rápido aumento na dimensionalidade do espaço de características.

Os gráficos das figuras 2(f) e 2(g) mostram que a melhor classificação efetuada pelo método baseado em matrizes de co-ocorrência é obtida com $d = 1$ e utilizando-se imagens de terrenos compostas por 64 tons de cinza. Embora essa configuração requeira um tempo intermediário (figura 2(h)), torna-se inviável para aplicações de tempo real.

Como resultado final da avaliação das características de texturas, apresenta-se os gráficos das figuras 2(h) e 2(i), os quais representam, respectivamente, a avaliação do tempo e da qualidade de classificação. Observando-se apenas a qualidade obtida na classificação, os métodos baseados em matriz de co-ocorrência, codificação de características de texturas, matrizes de comprimento de corridas de cinza e a transformada *wavelet* apresentam os melhores resultados.

Pela figura 2(h) percebe-se que o método baseado em matrizes de co-ocorrência apresenta custo computacional elevado. Desse modo, considerando o compromisso entre qualidade e tempo requerido, os métodos que apresentam melhor desempenho são a codificação de características de texturas e os baseados em transformada *wavelet* e em matrizes de comprimento de corridas de cinza.

5 CONCLUSÕES

Uma tarefa que apresenta alta complexidade está relacionada à definição de um conjunto de características capazes de descrever de maneira efetiva cada região contida em uma imagem, normalmente efetuada utilizando-se medidas obtidas a partir de métodos de análise de texturas. Este trabalho apresentou uma avaliação desses métodos aplicados a imagens digitais de terrenos.

REFERÊNCIAS

- Connors, R. W. e Harlow, C. A. A Theoretical Comparison of Texture Algorithms. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 2(3):204–221, 1980.
- de Wouwer, G. V., Scheunders, P. e D. Van Dyck, D. Statistical Texture Characterization from Discrete Wavelet Representations. **IEEE Transactions on Image Processing**, 8(4):592–598, 1999.
- Galloway, M. M. Texture Analysis Using Gray Level Run Lengths. **Computer Graphics and Image Processing**, 4:172–179, 1975.
- Haralick, R., Shanmugam, K. e Dinstein, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man and Cybernetics**, 3(6):610–621, 1973.
- Haralick, R. M. Statistical and Structural Approaches to Texture. **Proceedings of the IEEE**, 67(5):786–804, 1979.
- He, D. C. e Wang, L. Texture Unit, Texture Spectrum, and Texture Analysis. **IEEE Transactions on Geoscience and Remote Sensing**, 28(4):509–512, 1990.
- Hornig, M.-H., Sunb, Y.-N. e Lin, X.-Z. Texture Feature Coding Method for Classification of Liver Sonography. **Computerized Medical Imaging and Graphics**, 26(1):33–42, 2002.
- Mallat, S. G. A Theory for Multiresolution Signal Decomposition: the Wavelet Representation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 11(7):674–693, 1989.
- Nadler, M. e Smith, E. P. **Pattern Recognition Engineering**. John Wiley & Sons, 1993.
- Ohanian, P. P. e Dubes, R. C. Performance Evaluation for Four Classes of Textural Features. **Pattern Recognition**, 25(8):819–833, 1992.
- Randen, T. e Husoy, J. H. Filtering for Texture Classification: A Comparative Study. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 21(4):291–310, 1999.
- Rosholm, A., 1997. **Statistical Methods for Segmentation and Classification of Images**. Tese de doutorado, Danmarks Tekniske Universitet.
- Singh, M. e Singh, S. Spatial Texture Analysis: A Comparative Study. In: **International Conference on Pattern Recognition**, vol. 1, pp. 676–679, 2002.
- Theodoridis, S. e Koutroumbas, K. **Pattern Recognition**. Elsevier Academic Press, 2ª edição, 2003.
- Tuceryan, M. e Jain, A. K. Texture Analysis. In: **The Handbook of Pattern Recognition and Computer Vision**, pp. 207–248. World Scientific Publishing, 1998.
- Weszka, J., Dyer, C. e Rosenfeld, A. A Comparative Study of Texture Measures for Terrain Classification. **IEEE Transactions on System, Man, and Cybernetics**, SMC-6(4):269–285, 1976.