



Exacta

ISSN: 1678-5428

exacta@uninove.br

Universidade Nove de Julho

Brasil

Alves de Araújo, Sidnei; Henriques Librantz, André Felipe; Alves, Wonder Alexandre Luz  
Ferramenta para indexação e recuperação automática de imagens médicas  
Exacta, vol. 4, núm. Esp, novembro-special, 2006, pp. 75-77  
Universidade Nove de Julho  
São Paulo, Brasil

Disponível em: <http://www.redalyc.org/articulo.oa?id=81009911>

- Como citar este artigo
- Número completo
- Mais artigos
- Home da revista no Redalyc

redalyc.org

Sistema de Informação Científica  
Rede de Revistas Científicas da América Latina, Caribe, Espanha e Portugal  
Projeto acadêmico sem fins lucrativos desenvolvido no âmbito da iniciativa Acesso Aberto

# Ferramenta para indexação e recuperação automática de imagens médicas

Sidnei Alves de Araújo, André Felipe Henriques Librantz, Wonder Alexandre Luz Alves

Uninove, Departamento de Ciências Exatas. São Paulo – SP [Brasil]  
saraujo@uninove.br

Neste trabalho, é apresentada uma ferramenta de indexação e recuperação automática de imagens baseada em redes neurais artificiais (RNAs). Para classificação das imagens, utilizaram-se atributos extraídos por meio de descritores estatísticos, conhecidos como descritores de Haralick. Uma rede neural híbrida foi utilizada como núcleo da aplicação para reconhecer os diferentes padrões de texturas dessas imagens.

Nas áreas de saúde, em especial na medicina, o conteúdo visual de uma imagem pode ser transformado em dados úteis para um posterior diagnóstico. Os avanços tecnológicos dos últimos anos e o rápido crescimento nas bases de imagens digitais têm motivado o estudo e o desenvolvimento de mecanismos automáticos de indexação e posterior recuperação de imagens. Em resposta a essa demanda, diversos métodos baseados em algum tipo de característica de imagens digitais (cor, forma, textura ou região de uma imagem) têm sido propostos (AKSOY; HARALICK, 1998), principalmente nos denominados *picture archiving and communication system* (Pacs), que permitem integrar informações textuais do paciente, além de informações gráficas provenientes de exames como raios X, tomografia e ultra-sonografia. Neste trabalho, aborda-se o desenvolvimento de uma ferramenta computacional para indexação e recuperação automática de imagens médicas, que tem como núcleo uma RNA híbrida composta por um modelo supervisionado (mapas auto-organizáveis ou, em

inglês, *self-organization map* [SOM]), acoplado a outro não supervisionado (quantização vetorial por aprendizagem ou, em inglês *learning vector quantization* [LVQ]). Para caracterização das imagens, utilizou-se uma abordagem estatística para extração dos atributos de textura por meio dos descritores de Haralick (HARALICK, 1979), obtidos a partir das matrizes de co-ocorrência que consistem numa contagem de quantas combinações diferentes de níveis de cinza ocorrem em uma imagem, em uma determinada direção. Para obtenção de tais matrizes, considera-se a variação da distância e direção ( $d$ ,  $\theta$ ) entre *pixels* vizinhos. A partir das matrizes de co-ocorrência, obtêm-se as medidas estatísticas. Foram utilizados, como atributos para descrever as texturas das imagens, oito descritores: segundo momento angular, contraste, entropia, momento da diferença inversa, correlação, variância, dissimilaridade e média. Essas oito estatísticas são as entradas da rede neural proposta e estão descritas nas equações 1 a 8.

$$SMA(d, \theta) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} [P(i, j)]^2 \quad (1)$$

$$Cont(d, \theta) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - j)^2 P(i, j) \quad (2)$$

$$ENT(d, \theta) = - \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - j) \log_2 [P(i, j)] \quad (3)$$



$$MDI(d, \theta) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{1}{1 + (i - j)^2} P(i, j) \quad (4)$$

$$COR(d, \theta) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{ijP(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (5)$$

$$VAR(d, \theta) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - j)^2 \cdot P(i, j) \quad (6)$$

$$DIS(d, \theta) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} |i - j| \cdot P(i, j) \quad (7)$$

$$MED(d, \theta) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} i \cdot P(i, j) \quad (8)$$

As RNAs consistem numa técnica de inteligência artificial e têm como inspiração a estrutura e o funcionamento do cérebro humano. Uma característica importante das redes neurais é a capacidade de auto-organização, ou por meio da qual a rede atribui um padrão de entrada a uma classe entre um conjunto de classes conhecidas (HAYKIN, 2001).

A idéia principal do modelo híbrido proposto é utilizar o SOM, que é um algoritmo não supervisionado para proporcionar um agrupamento inicial dos padrões de entrada e, como é comum haver problemas de classificação nas fronteiras da decisão entre as classes, utilizar a quantização vetorial por aprendizagem, de natureza supervisionada, para melhorar a divisão do espaço dos padrões previamente agrupados (HAYKIN, 2001). Como a utilização da ferramenta proposta só é possível após o treinamento da rede neural que compõe o seu núcleo, foi necessário o prévio treinamento. Para isso, foram criados dois conjuntos de padrões de imagens com base nos descritores de Haralick, um para o treinamento da rede, denotado por P, e outro para a fase de testes, indicado por

Q. Para compor cada um dos conjuntos, foram utilizadas 50 imagens de tecidos biológicos extraídas da Universidad Nacional del Sur (2005). Ressalta-se que as imagens do conjunto P eram diferentes das do conjunto Q. Tanto no conjunto de treinamento quanto no de teste, as imagens foram divididas em cinco classes, cada uma com dez imagens. O treinamento da rede neural híbrida inicia-se rotulando o conjunto por meio do algoritmo SOM, que proporciona um agrupamento inicial dos padrões de treinamento. Para a fase de rotulação dos padrões, foram propostos uma rede SOM com oito neurônios na camada de entrada (um para cada descritor) e um mapa de saída com 36 neurônios. Para este primeiro agrupamento dos padrões, o algoritmo SOM foi executado por 700 épocas, utilizando uma taxa de aprendizagem de 0,005. Após o treinamento com SOM, a aprendizagem por LVQ foi então utilizada para melhorar a divisão do espaço das classes. Depois da fase de treinamento do modelo híbrido, procedeu-se à de testes para verificar o desempenho desse modelo. Os resultados obtidos foram bastante satisfatórios, uma vez que a porcentagem de acertos chegou a 100%. Feita a aferição do modelo neural, este foi acoplado à ferramenta proposta que deve estar pronta para uso. A Ilustração 1 mostra uma situação na qual uma imagem qualquer é selecionada e, na seqüência, a aplicação apresenta imagens similares à imagem selecionada.

Os resultados obtidos na classificação de imagens, com a aplicação da RNA híbrida, sinalizam que o método proposto pode ser uma alternativa para aplicações que envolvam as tarefas de indexação e recuperação automática de imagens digitais, principalmente em bancos de imagens médicas.

Fonte: Os autores.

AKSOY, S.; HARALICK, R. M. Textural features for image database retrieval. In: IEEE WORKSHOP ON CONTENT-BASED ACCESS OF IMAGE AND VIDEO LIBRARIES. Washington. *Proceedings...* Washington: IEEE, 1998. p. 45-49.

HAYKIN, S. *Redes neurais princípio e prática*. 2. ed. Porto Alegre: Bookman, 2001.

### Para referenciar este texto

77