

Utilização de um Novo Modelo para Representação de Sinais, como Extrator de Características, na Recuperação de Imagens Médicas por Conteúdo

João L. Fernandes, Cristina N. Vasconcelos, Giovanni C. Carelli

Departamento de Ciência da Computação – Universidade Federal Fluminense (UFF)
Rua Passo da Pátria, 156 – 24210-240 – Niterói – RJ – Brasil

{ccmjlf,crisnv}@ic.uff.br, giovannicarelli@hotmail.com

Abstract. *The recovery of similar items from medical images databases can promote the acquisition of important knowledge to aid the diagnosis. The recovery of images by similarity involves the extraction of representative features of the images, which is not a trivial task, since there is usually a large number of factors that must be considered to simulate the human perception. Such techniques are known in literature as CBIR (Content-based Image Retrieval). In this paper, we propose studying a new model for signal representation, as features extractor, aiming at developing metrics of similarity between medical images.*

Resumo. *A recuperação de itens semelhantes, em bancos de dados de imagens médicas, pode ser um auxílio eficiente à elaboração de diagnósticos. Recuperar imagens por similaridade envolve a extração de características representativas dos exemplares, o que não é uma tarefa trivial, já que, normalmente, há um grande número de fatores que devem ser considerados, na tentativa de simular a percepção humana. Tais técnicas são conhecidas na literatura como CBIR (Content-based Image Retrieval). Neste trabalho, propomos o estudo de um novo modelo para representação de sinais, como extrator de características, visando ao desenvolvimento de métricas de semelhança entre imagens médicas.*

1. Introdução

É inegável a importância das imagens médicas como potenciais fontes de informação, onde diversos profissionais podem adquirir conhecimentos que, de forma geral, contribuam para o avanço das pesquisas em Saúde. Entretanto, considerando que tais fontes exigem, na maioria das vezes, complexos tratamentos para extração e análise dos dados relevantes a uma determinada aplicação, profissionais da área da Saúde ainda não obtêm todos os benefícios derivados desse valioso repositório [Silva, 2009].

Uma área de crescente interesse, envolvendo imagens médicas, é aquela relacionada à recuperação, em um banco de imagens, daquelas semelhantes a um exemplar de consulta. Recuperar uma imagem por similaridade envolve a extração de características representativas dos exemplares, o que não é uma tarefa trivial, já que, normalmente, há um grande número de fatores que devem ser levados em consideração, na tentativa de simular a percepção humana. As técnicas relacionadas a essa área, são

conhecidas como CBIR (*Content-based Image Retrieval*) e têm sido alvo de muitas pesquisas. Na literatura disponível, encontramos vários trabalhos que utilizam abordagens baseadas na análise multirresolução de *wavelets* para a produção de sistemas CBIR [Silva, 2009 e Castañon, 2003].

A produção de sistemas utilizando-se técnicas de CBIR inclui, de forma geral, o estabelecimento de vetores de características, que são descritores numéricos das imagens, incorporando, portanto, seus detalhes relevantes. Tais vetores são armazenados no banco de dados, de forma a facilitar a recuperação dos itens correlatos a um exemplar de consulta. Neste trabalho, propomos o estudo de um novo modelo para representação de sinais, como extrator de características, para o estabelecimento de vetores de semelhança entre imagens médicas, com vistas à sua utilização em sistemas CBIR.

2. Modelo proposto

Recentemente, no trabalho em [Fernandes, 2006], foi proposto o estudo de um novo modelo para a representação de sinais: partindo da Transformada de Fourier, desenvolveu-se uma representação conjunta espaço-frequência, baseada em funções de Gabor. Em [Torreão et al., 2009] demonstrou-se que tal modelo apresenta vantagens na representação de sinais a partir de poucas componentes de frequência, e possui características que parecem torná-lo adequado à modelagem de processos neurofisiológicos observados no córtex visual dos mamíferos. A seguir, uma breve descrição sobre a fundamentação teórica do processo.

Seja $I(x,y)$ um sinal bidimensional de quadrado integrável sobre um domínio ilimitado, de tal modo que a sua transformada de Fourier exista. A seguinte identidade se verifica:

$$I(x,y) = \iint_{-\infty}^{\infty} d\omega_x d\omega_y \left\{ \exp[i\omega_x(x-a) + i\omega_y(y-b)] \exp\left[-\frac{(x-a)^2 + (y-b)^2}{2\sigma^2}\right] * \right. \\ \left. * \exp[i(\omega_x x + \omega_y y)] \right\} \quad (1)$$

onde a , b e σ são funções das frequências ω_x e ω_y , dadas por

$$\sigma(\omega_x, \omega_y) = \frac{1}{(2\pi)^{3/2}} \sqrt{|\tilde{I}(\omega_x, \omega_y)|} \quad (2)$$

e

$$\omega_x a(\omega_x, \omega_y) + \omega_y b(\omega_x, \omega_y) = -\varphi_{\tilde{I}}(\omega_x, \omega_y) \quad (3)$$

com $\tilde{I}(\omega_x, \omega_y)$ denotando a transformada de Fourier de $I(x,y)$ – cuja amplitude e fase são indicadas por $|\tilde{I}|$ e $\varphi_{\tilde{I}}$, respectivamente – e com o asterisco na Eq. (1) denotando a operação de convolução de uma função de Gabor (esquerda) por uma função exponencial complexa (direita).

Utilizando as definições acima, a identidade em (1) pode ser comprovada tomando-se a Transformada de Fourier de ambos os lados da equação, ou então, efetuando-se a convolução indicada sob a dupla integral. Em quaisquer dos casos, o resultado obtido para o lado direito de (1) será exatamente a definição de $I(x,y)$, pela Transformada de Fourier Inversa. A representação em (1), portanto, apenas reescreve a

fórmula tradicional da Transformada Inversa de Fourier, expressando o sinal $I(x,y)$ ainda em termos de uma expansão em funções de base exponenciais complexas. Obteve-se, portanto, a partir da transformada de Fourier tradicional, uma representação conjunta espaço-frequência, sob a forma de funções de Gabor.

Como descrito em [Torreão et al., 2009], essa representação permite uma caracterização completa do sinal. Neste trabalho, propomos utilizar as próprias Funções de Gabor de Representação para fornecer subsídios para caracterização de uma imagem e elaboração de vetores de semelhança.

3. Metodologia

Para composição dos vetores de características, dividimos a imagem de teste em janelas de tamanho 5×5 pixels e calculamos o valor da função de representação:

$$g_a(x, y) = \exp[i\omega_x(x-a) + i\omega_y(y-b)] \exp\left[-\frac{(x-a)^2 + (y-b)^2}{2\sigma^2}\right] \quad (4)$$

para cada *pixel* (x,y) da janela. Os elementos da função em (4) são exatamente os mesmos descritos em (1), (2) e (3). Os valores deduzidos, em módulo, são consolidados em um somatório por janela e por frequência. O vetor final, portanto, é a média entre os valores das janelas, ao longo da imagem, por par de frequência (ω_x, ω_y) considerado. Cada vetor de característica deduzido possui 16 valores, correspondentes às 16 frequências mais baixas. Para cálculo do índice de semelhança (D) entre imagens, estamos utilizando, entre os vetores, a distância de Minkowsky [Castañon, 2003], com $r=3$.

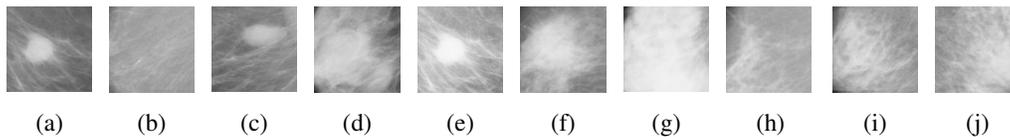


Figura 1: (a) Exemplar de consulta, (b) a (j) Imagens utilizadas para pesquisa por similaridade, em relação à imagem em (a).

Tabela 1: Índices de similaridade D , calculados para as imagens da Figura 1.

Imagem de Pesquisa	D	Imagem de Pesquisa	D	Imagem de Pesquisa	D
(b)	4.995277	(e)	0.365419	(h)	20.685948
(c)	2.079339	(f)	3.271543	(i)	3.205847
(d)	18.664704	(g)	8.205047	(j)	3.358907

4. Experimentos

Nos testes que realizamos, o limiar para detecção de uma imagem similar a um exemplar de consulta foi avaliado, empiricamente, em $D = 2.5$. Assim, ao compararmos duas imagens, elas foram consideradas similares quando o cálculo da distância D , entre os respectivos vetores de características, resultou um valor abaixo desse limite.

A título de exemplo, vamos mostrar o comportamento do algoritmo para um pequeno subconjunto das imagens de teste. As imagens na Figura 1 mostram recortes de tecido mamário, obtidos através de imagens oriundas de exames mamográficos, disponibilizadas em [Suckling, 2010]. Consideramos a imagem em (a) como um exemplar de consulta; conforme disposto em [Suckling, 2010], ela apresenta uma região com massa circunscrita e bem definida. A Tabela 1 mostra valores para o índice D , comparando-se a imagem em (a) com aquelas de (b) a (j). Como podemos perceber através das linhas sombreadas na tabela, as imagens em (c) e (e) foram aquelas detectadas como similares ao exemplar em (a) e tal semelhança pode ser comprovada por simples inspeção visual. Deve-se destacar que a imagem em (e) é o mesmo exemplar em (a) utilizado para a consulta, mas em condições bem diferentes de brilho e contraste – mesmo assim, o algoritmo foi robusto o suficiente para detectar a semelhança.

5. Conclusão

Os resultados iniciais obtidos demonstram que o nosso processo possui excelentes condições de aplicação. Ainda há muitos testes a serem realizados, estudando-se o comportamento dos parâmetros envolvidos no processo, bem como experimentando outras metodologias de aplicação. Já está em curso uma mudança na estrutura do algoritmo, na qual consideraremos uma “pirâmide” de imagens de resoluções crescentes e a consequente obtenção de um conjunto de vetores de características, um para cada nível de imagem – esperamos aumentar a precisão do método a partir dessa mudança.

Na próxima fase do trabalho, testaremos nossa aplicação em um conjunto diferente de imagens (e não somente provenientes de exames mamográficos), propiciando gráficos de precisão e revocação [Castañon, 2003]; além disso, vamos propor o estudo da Transformada Sintonizada de Gabor [Torreão e Victer, 2010], como extratora de características das imagens. Da mesma forma, esperamos obter bons resultados com essa abordagem inovadora.

Referências

- Castañon, C. A. B. (2003) “Recuperação de imagens por conteúdo através de análise multirresolução por Wavelets”, Dissertação de Mestrado, ICMC-USP, São Carlos.
- Fernandes, J. L. (2006) “Shape from shading: Novas abordagens a partir de movimento e de foco”, Tese de Doutorado, Universidade Federal Fluminense, Niterói.
- Silva, L. A. (2009) “Categorização de Imagens Médicas baseada em Transformada Wavelet e Mapas Auto-Organizáveis”, Tese de Doutorado, USP, São Paulo.
- Suckling, J. (Organiser) (2010) *site* “The mini-MIAS database of mammograms” [<http://peipa.essex.ac.uk/info/mias.html>], Último acesso: Agosto/2010.
- Torreão, J. R. A. e Victer, S. M. C. (2010) “A Transformada de Gabor Sintonizada”, Relatório técnico apresentado ao Instituto de Matemática Pura e Aplicada (IMPA), Rio de Janeiro.
- Torreão, J. R. A., Fernandes, J. L. and Victer, S. M. C. C. (2009) “A Model for Neuronal Signal Representation by Stimulus-Dependent Receptive Fields” In: 19th International Conference on Artificial Neural Networks (ICANN 2009), Limassol.