

Compressão de Imagens de Cintilografia Miocárdia Atráves do Algoritmo Hebbiano Generalizado *

Robinson Pizzio
rpizzio@ee.pucrs.br

José Nelson Amaral
amaral@ee.pucrs.br

Paulo Roberto G. Franco
pfranco@ee.pucrs.br

Programa de Pós-Graduação em Engenharia Elétrica
Pontifícia Universidade Católica do Rio Grande do Sul
<http://www.ee.pucrs.br>
90619-900 - Porto Alegre - RS - Brasil

Resumo

Este trabalho investiga a capacidade de generalização de uma Rede Neural Artificial treinada pelo algoritmo Hebbiano generalizado para compressão de imagens de cintilografia miocárdia. Nossos resultados indicam que a nova abordagem proposta neste artigo produz uma economia considerável de espaço para armazenamento das imagens sem comprometer o seu uso para diagnose médica.

Abstract

This paper studies the capacity of generalization of a Artificial Neural Network trained with the Generalized Hebbian Algorithm. The ANN is applied to compress cintilography myocardial images. Our results indicate that this new approach yields a significant reduction in the storage requirements for images without compromising its use for medical diagnosis.

1 Introdução

Um grande número de exames de imagens de cintilografia miocárdia é realizado diariamente em nossos hospitais. Estas imagens são usualmente arquivadas por um determinado período e posteriormente destruídas. Tanto para referências futuras no tratamento dos pacientes quanto para estudos da população acometida por patologias miocárdicas, seria desejável armazenar digitalmente estas imagens de forma que as mesmas pudessem ser facilmente recuperadas quando necessário. Uma dificuldade para a preservação destas imagens em meio magnético é o volume de armazenamento de dados que estas imagens formariam. Uma segunda importante motivação para o desenvolvimento de novos métodos de compressão de imagens médicas é o crescente interesse em telemedicina [7].

Neste artigo nós apresentamos um método de compressão de imagens que pode reduzir significativamente a área de armazenamento necessária para imagens com características similares, como é o caso de imagens oriundas de um mesmo tipo de exame médico aplicado em diferentes pacientes. Este método é uma extensão ao trabalho desenvolvido por De Castro *et al.* [2]. De Castro desenvolveu um novo método para compressão de imagens utilizando uma formulação complexa para o Algoritmo Hebbiano Generaliza-

*Este trabalho foi financiado em parte pela Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela Fundação de Apoio à Pesquisa do Estado do Rio Grande do Sul (FAPERGS) e pela Pontifícia Universidade Católica do Rio

No método de De Castro é necessário armazenar os auto-vetores de cada uma das imagens juntamente com os valores de entrada e saída da Rede Neural Artificial (RNA). Neste artigo nós propomos que é possível armazenar apenas um conjunto de auto-vetores e utilizar este conjunto para codificar e decodificar um grupo de imagens. A aplicação desta extensão do método está restrita a conjuntos de imagens similares, como é o caso de exames de imagens da medicina, tal como as imagens cintilográficas do Miocárdio.

Uma das razões que levaram De Castro *et al.* a optar por uma compressão no domínio espectral com dados complexos é o fato de que imagens com variações abruptas de tons apresentam uma representação mais suave no domínio espectral do que no domínio espacial [4]. No caso das imagens de cintilografia miocárdia as imagens já são suficientemente suaves no domínio espacial. Portanto não há necessidade de trabalhar com CGHA. Nós utilizamos o novo método de janelamento proposto por De Castro para treinar a RNA com o GHA [2]. A vantagem de trabalhar no domínio espacial é uma redução significativa na complexidade computacional do método uma vez que não precisamos executar a Transformada Discreta de Fourier e sua inversa para transformar as imagens para o domínio espectral e posteriormente retorná-las ao domínio espacial.

Nossos experimentos indicam que a grande vantagem desta proposta é uma alta taxa de compressão das imagens sem que a habilidade de realizar diagnósticos a partir destas imagens seja comprometida. As imagens resultantes processadas por este método foram analisadas tanto em termos da relação sinal ruído de pico (PSNR), como por experientes especialistas médicos e sua qualidade foi julgada completamente aceitável para fins de diagnóstico.

2 O GHA para Compressão de Imagens

A literatura sobre Redes Neurais Artificiais (RNA) usando o algoritmo Hebbiano generalizado apresenta um número variado de aplicações [5, 6]. Nos últimos anos a utilização do GHA para compressão de imagens tem recebido atenção especial [1, 2].

Um único neurônio linear submetido à regra Hebbiana de aprendizado auto-organizado tende a extrair a primeira componente principal de um vetor de dados de entrada [1, 3, 6]. Esta componente corresponde ao maior auto-valor da matriz covariância dos dados de entrada.

A Figura 1 apresenta a estrutura da

RNA progressiva com uma única camada de neurônios lineares, a ser treinada pelo Aprendizado Hebbiano Generalizado.




Figura 1: RNA progressiva com uma única camada de neurônios lineares, a ser treinada pelo Aprendizado Hebbiano Generalizado.

A saída $y_j(n)$ produzida pelo neurônio j no tempo n em resposta ao conjunto de entradas $x_i(n)$ é dada pela equação 1.

$$y_j(n) = \sum_{i=0}^{p-1} w_{ji}(n)x_i(n), \quad j = 0, 1, \dots, m-1 \quad (1)$$

A adaptação dos pesos sinápticos se dá pela equação 2.

$$\Delta w_{ji}(n) = \eta y_j(n) [x_i(n) - \sum_{k=0}^j w_{ki}(n)y_k(n)] \quad (2)$$

onde $\Delta w_{ji}(n)$ é a variação aplicada ao peso sináptico $w_{ji}(n)$ no tempo n e η é a taxa de aprendizado, $j = 0, 1, \dots, m-1$ e $i = 0, 1, \dots, p-1$.

As componentes principais de um conjunto de dados são ordenadas de acordo com a ordem decrescente dos auto-valores da matriz de correlação do conjunto [1, 6].

Os únicos dados necessários para reconstruir uma imagem são as componentes principais (pesos sinápticos da RNA) e os dados de saída da RNA. A partir destes dados, a reconstrução da imagem se dá pela equação 3.

$$\hat{x}_i(n) = \sum_{j=0}^{m-1} y_{ji}(n)w_{ji} \quad (3)$$

Para comprimir uma imagem somente as primeiras m componentes principais são preservadas.

3 Aplicação do GHA a Imagens Cintilográficas

As imagens utilizadas estão quantizadas em 256 níveis de cinza. Os dados são apresentados à RNA sob a forma de vetores unidimensionais de p elementos. Cada um destes vetores é obtido através do particionamento da imagem em submatrizes de dimensões $l \times l$, onde $l = 2^n$ elementos. Portanto, o número de elementos do vetor unidimensional é $p = l^2$. As imagens utilizadas neste trabalho possuem 128×128 elementos.

Para imagens com variações suaves de tons no domínio espaço, pixels em uma mesma vizinhança são correlacionados. As submatrizes utilizadas para formar o conjunto de treino devem ser grandes o suficiente para captar esta correlação, mas não devem ser tão grandes a ponto de elevar significativamente o custo computacional de treino da RNA. De Castro determinou experimentalmente que uma matriz de 8×8 provê bons resultados para imagens de 128×128 pixels [1].

Para análise da qualidade da imagem reconstruída pelo algoritmo foi adotada a relação sinal-ruído de pico (PSNR).

Neste trabalho foram utilizadas imagens de 128×128 pixels e submatrizes de 8×8 elementos. O que corresponde a um vetor de 64 elementos. Para a reconstrução das imagens adotou-se 16 componentes principais. Assim a RNA possui 64 nós de entrada e 16 neurônios de saída.

4 Resultados Experimentais

Através de vários experimentos foi possível constatar que com imagens de Cintilografia Miocárdia obtém-se um resultado muito bom na reconstrução das imagens com apenas 16 componentes principais. A Figura 2 apresenta a imagem original do exame de um paciente. Esta imagem foi processada pela RNA e reconstruída com 16 componentes principais. A Figura 3 mostra a imagem reconstruída, cuja relação sinal ruído de pico (PSNR) é de 40,43dB. Para fins de comparação é interessante notar que De Castro reporta uma PSNR de 37dB para imagens reconstruídas com 32 componentes principais no domínio complexo [2].

Nos resultados de experimentos mostrados nas Figuras 4 e 5, nós investigamos a ca-




Figura 2: Imagem do Miocárdio do paciente A.




Figura 3: Imagem da Figura 2 reconstruída com apenas 16 componentes principais.

imagens com características similares. A Figura 4 apresenta a imagem original do exame de um paciente. A imagem da Figura 5 apresenta a reconstrução desta imagem utilizando as componentes principais obtidas da imagem do mesmo exame *de outro paciente*. A PSNR para a imagem reconstruída por este método é de 37,08 dB, ou seja apenas 3 dBs abaixo da PSNR obtida com as componentes principais da mesma imagem.

Vários experimentos deste tipo foram realizados e as imagens resultantes foram submetidas à apreciação de especialistas da área médica. Em muitos casos os especialistas não conseguiam distinguir entre a imagem original e a imagem reconstruída. Nos casos em que haviam diferenças visíveis, os especialistas afirmaram que estas diferenças não comprometiam a atividade

Quando um exame de imagem cintilográfica do miocárdio é realizado, é necessário colocar placas de chumbo sobre o paciente para protegê-lo de exposição excessível à radiação gama. Nas imagens apresentadas nas Figuras 2 à 5, a *sombra* destas placas aparece no canto inferior esquerdo e na parte inferior da imagem. Apesar das placas serem posicionadas aproximadamente na mesma posição esta *sombra* varia de posição de uma imagem para outra. Como as placas causam uma variação brusca no tom da imagem, estas bordas podem provocar um efeito significativo nas componentes principais da imagem, resultando na diferença de 3 dBs observada no experimento descrito anteriormente. Uma solução para este problema seria um pré-processamento das imagens de forma a eliminar estas bordas ou obtê-las na mesma posição. Pesquisa futura que contemple esta abordagem deverá consultar com especialistas médicos para não comprometer a qualidade diagnóstica da imagem recuperada.



Figura 4: Imagem do exame de um paciente A.

Considerando que o espaço necessário para armazenar cada peso sináptico e o valor de cada saída é idêntico ao espaço necessário para armazenar um pixel (8 bits), utilizando-se a RNA com a estrutura mostrada na Figura 1, com $p = 64$ e $m = 16$, são necessários $64 \times 16 = 1024$ bytes para armazenar as componentes principais (PCs) de uma imagem. Portanto são necessários $256 \times 16 = 4096$ bytes para armazenar os valores da saída para cada imagem. Com a nova abordagem proposta neste artigo, não é necessário armazenar as PCs de cada imagem, resultando numa redução de 20% no espaço necessário para armazenar um




Figura 5: Imagem da Figura 4 reconstruída com as componentes principais da imagem de um outro paciente.

5 Conclusão

Tendo em vista os resultados obtidos com este trabalho, pode-se observar a grande utilidade desta ferramenta para aplicações à compressão de imagens. Ao invés de armazenar-mos as componentes principais de diversas imagens, podemos armazenar apenas as PCs de uma imagem. A partir destes dados podemos reconstruir outras imagens obtendo perdas não muito significativas para o diagnóstico médico.

Uma palavra de cautela é necessária em relação à utilização deste método de compressão. Ele produz excelentes resultados para imagens que são suaves e para cujo uso uma alta definição não é requerida, como é o caso das imagens produzidas em medicina nuclear. Estudos futuros deverão avaliar a aplicação do método para outras imagens médicas, tais como ultrasonografia e imagens geradas por ressonância magnética (MRI).

6 Agradecimentos

Gostaríamos de fazer um agradecimento especial à Maria C. F. de Castro por todo o auxílio durante nossa pesquisa e principalmente por nos ter cedido o uso do programa para treinamento da RNA com o algoritmo Hebbiano generalizado.

Referências

- [1] M. C. F. De Castro. Algoritmo hebbiano gene-

cupais de um conjunto de dados no domínio complexo. Master's thesis, PUCRS, 1996.

- [2] M. C. F. De Castro, F. C. C. De Castro, J. N. Amaral, and P. R. G. Franco. Uma formulação complexa para o algoritmo hebbiano generalizado aplicada à compressão de imagens. *III Simpósio Brasileiro de Redes Neurais*, Novembro 1996.
- [3] L. H. Chen and S. Chang. An adaptive learning algorithm for principal component analysis. *IEEE Trans. on Neural Networks*, 6(5), 1995.
- [4] R. Gonzalez and R. E. Woods. *Digital Image Processing*. Addison Wesley, 1993.
- [5] M. H. Hassoun. *Fundamentals of Artificial Neural Networks*. MIT Press, 1995.
- [6] S. Haykin. *Neural Networks: A Comprehensive Foundation*. Macmillian Publishing Company, 1994.
- [7] J. A. Schnepf, D. H. C. Du, R. Rite-nour, and A. J. Fahrman. Building future medical education environments over ATM networks. *Communications of the ACM*, 38(2):54–, 1995.