

Algoritmo Competitivo Sensível à Distorção Parcial Aplicado à Compressão de Imagens no Domínio de Wavelets

P. H. ESPÍRITO SANTO e F. MADEIRO

Resumo—Este artigo apresenta uma avaliação de desempenho de um algoritmo de aprendizagem Competitiva Sensível à Distorção Parcial aplicado ao projeto de dicionários para Quantização Vetorial de imagens. É apresentada uma comparação de desempenho com o algoritmo LBG (Linde-Buzo-Gray), nos domínios espacial e da transformada *wavelet*. É avaliada a proposta de introdução de “consciência” no processo de aprendizado.

Palavras-Chave— Quantização Vetorial, Algoritmo Competitivo, Wavelets.

Abstract—This paper presents a performance evaluation of a Partial Distortion Sensitive Competitive Learning algorithm applied to image vector quantization codebook design. A performance comparison with the LBG (Linde-Buzo-Gray) algorithm is carried out, in spacial and *wavelet* domains. The introduction of “conscience” into the learning process of PDSCL is evaluated.

Keywords— Vector Quantization, Competitive Algorithm, Wavelets.

I. INTRODUÇÃO

O objetivo fundamental da compressão de imagens é representar uma imagem de tal maneira que o número de *bits* utilizados na representação seja minimizado para uma distorção aceitável. Uma poderosa técnica para compressão é a quantização vetorial (QV), que pode ser vista como uma extensão da quantização escalar (QE). A QV opera em blocos de *pixels* em vez de *pixels* isolados.

A qualidade obtida com a QV depende muito do dicionário empregado no processo de codificação. O algoritmo LBG [1] é a mais conhecida técnica para se projetar dicionários para QV. Há diversas outras técnicas para se obter quantizadores vetoriais, dentre as quais podem ser citadas redes neurais artificiais (aprendizagem competitiva). Um problema encontrado com o uso de algoritmos competitivos está associado ao fato de que alguns vetores-código participam pouco do processo de treinamento da rede (sub-treinamento). Para sanar o problema de sub-treinamento, Grossberg [2] propôs introduzir “consciência” ao treinamento. A abordagem pode ser aplicada ao projeto de dicionário para QV [3][4]. O presente trabalho apresenta um sistema de compressão de imagens no domínio *wavelet* utilizando um algoritmo competitivo sensível à distorção parcial (*Partial Distortion Sensitive Competitive Learning* - PDSCL) para o projeto de dicionários para QV.

II. ALGORITMO PDSCL

Uma rede neural competitiva é aquela em que apenas um neurônio (vetor-código), o vencedor da competição, é treinado

Núcleo de Pesquisa em Telecomunicações, POLI, Universidade de Pernambuco (UPE), Recife-PE, Brasil, E-mails: paulohugos@gmail.com, franciscomadeiro@yahoo.com.br.

a cada apresentação de um vetor (padrão) de entrada. Para um algoritmo competitivo [3], será declarado vencedor e terá suas componentes atualizadas o vetor-código que apresentar o menor valor de distância euclidiana quadrática (DEQ) em relação ao vetor de entrada apresentado no momento. No algoritmo PDSCL [4] é usada uma distância modificada, \hat{d} , sensível à distorção introduzida a cada apresentação de um vetor de entrada. O algoritmo PDSCL busca introduzir maior “consciência” ao treinamento através da sensibilidade à distorção parcial introduzida.

Seja n_{PDSCL} o número total de iterações do algoritmo PDSCL, M a quantidade de vetores de treino, $X(m)$ o m -ésimo vetor de treino, $d[X(m) - Y_i(n, m)]$ a DEQ entre $X(m)$ e $Y_i(n, m)$, sendo este o i -ésimo vetor código quando da apresentação de $X(m)$ na n -ésima iteração. $Y_{i^*}(m)$ denota o vencedor. A função $f(pd_i(m), m)$ é aplicada à distorção acumulada $pd_i(m)$. A seguir, é apresentado o algoritmo PDSCL.

Algoritmo PDSCL:

Para $1 \leq n \leq n_{PDSCL}$

Para $1 \leq m \leq M$

Y_{i^*} é o vencedor se tiver a menor \hat{d} , em que

$$\hat{d} = f(pd_i(m), m) + d[X(m) - Y_i(n, m)]$$

enquanto, $f(pd_i(m), m) = e^{-m/T} pd_i(m) e^{-m/T}$

$$\text{e } pd_i(m + 1) = pd_i(m) + d[X(m) - Y_i(n, m)] .$$

Atualize o vencedor

$$Y_{i^*}(m + 1) = Y_{i^*}(m) + \alpha(m)[X(m) - Y_i(m)] \quad (1)$$

em que $\alpha(m) = 1/m$

No cálculo da função $f(pd_i(m), m)$, T é uma constante (250 nas simulações). Na atualização do vencedor, equação (1), $\alpha(m)$ é a taxa de aprendizado na m -ésima apresentação de um vetor de entrada, em que α varia de 1 até $1/M$.

III. TRANSFORMADA WAVELET DISCRETA (TWD)

A transformada *wavelet* discreta pode ser descrita como uma aplicação de bancos de filtros às direções horizontal e vertical da imagem. No processo de decomposição *wavelet*, *pixels* de uma direção da imagem sofrem um processo de convolução com filtros *wavelet* e, em seguida, passam por um processo de sub-amostragem de ordem 2, então se obtêm sub-bandas (conjuntos de coeficientes *wavelet*) de aproximação e de detalhe. Em se tratando de uma decomposição *wavelet* multiresolucional, são aplicados sucessivamente (3 níveis foram usados nas simulações) bancos de filtros aos conjuntos de coeficientes de detalhe anteriormente obtidos. Na Figura 1 é possível se verificar uma decomposição *wavelet* até o 3º nível de uma imagem de 256x256 *pixels*, resultando na sub-banda

CA 3ª R = 8,0	CDh 3ª R = 2,0	Detalhe horizontal 2ª nível 64 x 64 pixels R = 1,5	Coeficientes de Detalhe horizontal 1ª nível 128x128 pixels R = 0,0
CDv 3ª R = 2,0	CDd 3ª R = 2,0	Detalhe vertical 2ª nível 64 x 64 pixels R = 1,5	
		Detalhe diagonal 2ª nível 64 x 64 pixels R = 1,5	Coeficientes de Detalhe diagonal 1ª nível 128x128 pixels R = 0,0
Coeficientes de Detalhe vertical 1ª nível 128x128 pixels R = 0,0			

Fig. 1. Disposição das sub-bandas obtidas com a aplicação da TWD, até o 3º nível de decomposição. Taxa de codificação, R, bpp por sub-banda.

de aproximação no 3º nível (CA) e nas sub-bandas de detalhe horizontal (CDh), vertical (CDv) e diagonal (CDd) dos 1º, 2º e 3º níveis de decomposição.

Na reconstrução, as sub-bandas sofrem um processo de super-amostragem de ordem 2 e, em seguida, é novamente aplicado um processo de convolução com filtros *wavelet*. O processo é realizado para as duas direções da imagem. Fatores como o tipo de *wavelet* mãe (família de filtros), número de níveis de decomposição, estratégia de alocação de bits para cada sub-banda, influenciam o desempenho de sistemas de codificação *wavelets*. A qualidade do sistema de codificação baseado em QV sofre pouca influência das sub-bandas do 1º nível de decomposição e grande influência das sub-bandas do 3º nível de decomposição. Uma estratégia de alocação de bits que explore a influência das sub-bandas, como a apresentada na Figura 1 exclui as sub-bandas do 1º nível de decomposição (contém 75% dos coeficientes) e atribui mais bits às sub-bandas do 3º nível de decomposição (contém 6,25% dos coeficientes).

IV. METODOLOGIA - SISTEMA TWD + QV

No processo de compressão no domínio *wavelet*, à imagem é aplicada a TWD bidimensional (filtros Biorotogonais) e obtidas as sub-bandas *wavelet*. São obtidos dicionários multiresolucionais para QV de cada sub-banda através dos algoritmos LBG e PDSCL. Para o projeto de dicionários é respeitada a estratégia definida na Figura 1, em que R denota a taxa de codificação. Nas simlações são usadas imagens 256x256 pixels em escala de cinza (8 bpp).

V. RESULTADOS

Foi feito um conjunto de simulações para avaliar o comportamento dos algoritmos LBG e PDSCL, que consistiu no uso de diferentes imagens e taxas de codificação. A Tabela I apresenta resultados obtidos com os algoritmos LBG e PDSCL em relação à relação sinal ruído de pico (PSNR, *peak signal to noise ratio*), obtida na reconstrução de imagens nos domínios espacial e *wavelet*, para uma taxa de codificação R= 0,5 bpp.

Observa-se que o algoritmo PDSCL apresenta um desempenho superior em termos do PSNR (dB) quando comparado com o LBG no domínio espacial. No domínio

TABELA I
PSNR (dB) para os algoritmos LBG e PDSCL nos domínios espacial e *wavelet*, com R= 0,5 bpp .

Imagem	LBG(esp)	PDSCL(esp)	LBG(wav)	PDSCL(wav)
Lena	30,04	30,55	30,31	31,21
Clock	29,68	30,20	29,04	29,33
Mandrill	25,24	25,29	24,37	24,44
Boat	27,96	28,43	27,56	27,24




Fig. 2. Imagens reconstruídas com o algoritmo PDSCL no (a) domínio espacial, (b) no domínio *wavelet*.

wavelet, a superioridade é observada para as imagens Clock e Mandrill.

A Figura 2 apresenta a imagem Boat codificada a 0,5 bpp (a) no domínio espacial, (b) no domínio *wavelet*. Um aspecto favorável ao uso de *wavelet* pode ser constatado ao se realizar uma inspeção visual nas imagens. A compressão no domínio *wavelet*, 2 (a), não apresenta o incomodo fenômeno de “bloqueamento” encontrado com a compressão no domínio espacial, 2 (b). A análise do processo de treinamento das redes neurais apontou que o algoritmo PDSCL tornou o treinamento mais uniforme quando comparado com o algoritmo competitivo padrão, minimizando o problema do sub-treinamento.

VI. CONCLUSÕES

O algoritmo PDSCL minimiza o problema do sub-treinamento encontrado em redes neurais competitivas, além de ter um melhor desempenho que o algoritmo LBG no domínio espacial, em termos de PSNR das imagens reconstruídas. A codificação no domínio *wavelet* não apresenta o incomodo fenômeno de “bloqueamento” encontrado no domínio espacial.

REFERÊNCIAS

- [1] LINDE, Y., BUZO, A., and GRAY, R. M. “An Algorithm for Vector Quantizer Design,” *IEEE Transactions on Communications*, vol. 28, No. 1, pp. 84-95, January 1980.
- [2] GROSSBERG, S. “Adaptive Pattern Classification and Universal Recording: I. Parallel Development and Coding of Neural Feature Detectors” *Biological Cybernetics*, Vol.23, pp.121-134, 1976.
- [3] ESPIRITO SANTO, P. H., MADEIRO, F., CUNHA, D. C., ALBUQUERQUE, R. C. “On Frequency Sensitive Competitive Learning for VQ Codebook Design,” *10th Brazilian Symposium on Neural Networks (SBRN)*, Salvador - BA, 2008.
- [4] ZHU, C. and PO, L.M. “Partial Distortion Sensitive Competitive Learning Algorithm for Optimal Codebook Design,” *Electronics Letters*, Vol. 32, No. 19, pp. 1757-1758, September 1996.