

Compressão Auto-Adaptativa de Imagens Multiespectrais

Gustavo Fontoura de Souza^{1,2}
José Alfredo Ferreira Costa²
Flavius da Luz Gorgônio²
Allan de Medeiros Martins²

¹ Centro Federal de Educação Tecnológica do RN – UNED/ZN - CEFET/RN
Rua Brusque, 2926, 59.112-450 Conj. Santa Catarina, Natal-RN, Brasil
gustavo@cefetrn.br

² Universidade Federal do Rio Grande do Norte - UFRN
Caixa Postal 1524 - Campus Universitário Lagoa Nova
CEP 59072-970 Natal - RN - Brasil
alfredo@dee.ufrn.br, flavius@dca.ufrn.br, allan@dee.ufrn.br

Abstract. Compression is a very important process for large amounts of data such as in the case of multispectral image data. There is a diversity of methods for compressing images, e.g. using vector quantization, image transforms, coding, fractals, etc. JPEG compression method has been widely accepted and used both for grey scale and color image. It uses Discrete Cosine Transform (DCT), quantization and a coding algorithm derived from Huffman code. This paper proposes a compression method called Auto-Adaptative Compression (AAC) for multispectral image data based on Principal Component Analysis (PCA) and Discrete Cosine Transform. The advantages of the method include: a) no need about previously assumptions from data; b) no need from user intervention; and c) each band is compressed by a different rates, according to amount of information derived from PCA phase. Although we present results obtained with software simulations, using real images, this process can be embedded in hardware boards to improve its performance. ACC was applied in some images and compared using mean squared error (MSE) and compression rate with a compression method that use discrete cosine transform and use a predefined threshold discard any coefficients to compress the image. In some cases AAC had better MSE results, in others same results, but less compression rate.

Palavras-chave: Discrete Cosine Transform; Principal Component Analysis; Image compression; Multispectral Image processing.

1. Introdução

Dos cinco sentidos humanos, a visão é o mais importante. Há várias razões que comprovam essa afirmativa, uma delas é que, sem dúvida, a quantidade de informações recebidas pelo ser humano é maior pela visão que pelos outros sentidos. Outra importante razão está associada à sensibilidade humana ao sentido da visão. Ou seja, normalmente somos mais sensibilizados quando vemos algo do que quando ouvimos, por exemplo.

Com a evolução constante dos computadores, dos sistemas de captura de imagens e principalmente dos meios de comunicação, em particular da internet, nossos olhos passam a ser sobrecarregados com mais e mais informações visuais. Para que essa facilidade de utilização, armazenamento e principalmente transferência de imagens pudesse ocorrer, as técnicas de compressão de dados precisaram evoluir muito. Desde as primeiras transmissões de imagens, ainda preto-e-branco e utilizando técnicas analógicas, até as velozes transmissões digitais via satélite, diversos trabalhos surgiram e mudaram os princípios e conceitos básicos acerca do tratamento e da transmissão de imagens (Gonzalez e Woods,1992).

As técnicas de compressão de imagens tornam-se fundamentais quando a quantidade de dados é muito grande, uma vez que o armazenamento e a transmissão são ainda mais dispendiosos. Quando falamos em imagens multiespectrais, fica evidente a necessidade de se realizar tal compressão. Existem diversos métodos de compressão que são ou podem ser utilizados para comprimir tais imagens.

Uma das falhas mais comuns dos processos de compressão de imagens multiespectrais é o fato de que os métodos não utilizam a informação multibanda, isto é, a informação que está contida entre as bandas da imagem, mas considera cada banda como decorrelacionada, que na verdade não é. O trabalho aqui apresentado consiste em uma continuação dos trabalhos de Souza (2005) e Costa *et al.* (2005), que aplicam a técnica de compressão auto-adaptativa a imagens coloridas, conseguindo bons resultados.

2. Análise de Componentes Principais (ACP)

Análise de Componentes Principais (PCA) é um dos métodos estatísticos de multivariáveis mais simples e bastante utilizados para compressão de imagens (Oliveira, 1997). Também chamada de Transformada Karhunen-Loève (KLT) ou ainda Transformada Hotelling, a PCA é considerada uma transformação linear ótima, dentre as transformadas de imagens, porém um contraponto para sua utilização é o alto esforço computacional envolvido.

A PCA também é muito utilizada em algoritmos de compressão de imagens, de acordo com Queiroz (2002), Tran e Lenz (2001) e Bao e Hung (1999). Todos esses trabalhos utilizam as características básicas da PCA, que é a redução do espaço necessário para a representação da imagem, já que a PCA promove uma compactação da energia. Alguns trabalhos comparam as técnicas de compressão de imagens por transformadas, analisando os efeitos causados por cada uma das transformadas, Martinelli *et al.*, (1993), Anthony e Barham, (1990), Oliveira e Romero, (1997) e Oliveira *et al.*, (2000).

Tanto os trabalhos que utilizam PCA, como os trabalhos envolvendo Discrete Cosine Transform (DCT) levam sempre em conta a imagem como uma única “entidade”, isto é, mesmo os trabalhos que tratam a imagem como sendo composta por planos individuais e realizam transformadas separadamente, não tratam os planos de forma realmente separados, mas como uma simples repetição da técnica em cada um deles.

Singh *et al.*, (1997) realiza uma compressão com o uso de mais de uma transformada, neste caso, a wavelet e a DCT, com resultados bastante expressivos. O trabalho utiliza basicamente a seqüência de passo para a compressão utilizada no padrão JPEG, com algumas adaptações para o método desenvolvido.

Mesmo os trabalhos envolvendo mais de uma transformada não se preocupam com o tratamento diferenciado que pode ser dado às bandas, principalmente com a utilização da PCA, que permite agrupar ou compactar a energia.

A PCA consiste basicamente em promover uma transformação linear nos dados de modo que os dados resultantes desta transformação tenham suas componentes mais relevantes nas primeiras dimensões, em eixos denominados eixos principais (Duda e Hart, 1998). A figura 2.1 ilustra um conjunto bi-dimensional e o mesmo conjunto após a aplicação da PCA.

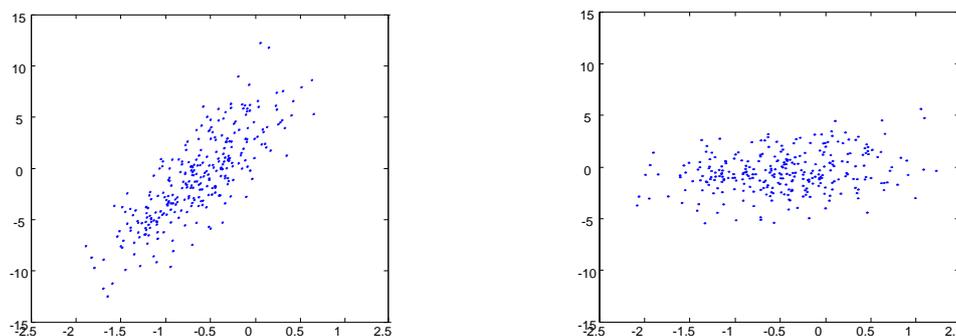


Figura 2.1 – Conjunto de dados antes e após a transformação linear aplicada.

3. Metodologia da Compressão

A técnica desenvolvida nesse trabalho, denominada Compressão Auto Adaptativa (CAA), é descrita pelo diagrama de blocos apresentado na figura 3.1.

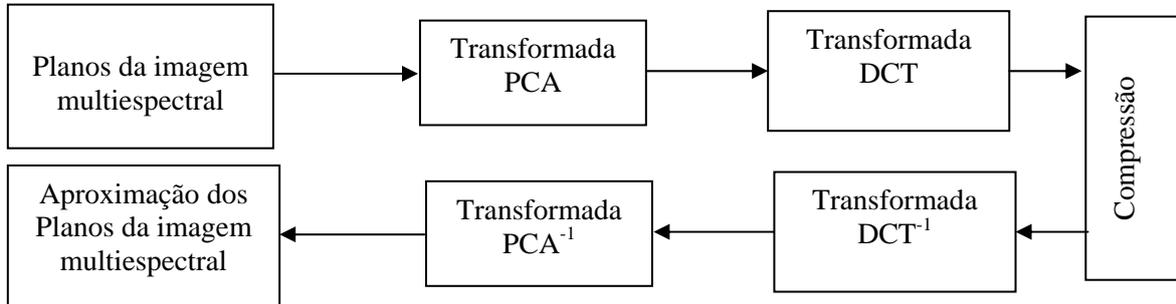


Figura 3.1 – Fluxograma do processo global da compressão da imagem.

No processo apresentado da figura 3.1, a imagem multiespectral é processada através da transformada PCA (Principal Component Analysis), produzindo novos planos de imagens com a mesma quantidade de dados, porém em planos descorrelacionados. A partir desse ponto o processamento será individualizado em cada uma das bandas. Para cada banda aplicaremos a transformada do Cosseno (DCT) que produzirá a compactação da energia no canto superior esquerdo da imagem, possibilitando assim a compressão. Na fase da compressão alguns coeficientes são descartados, gerando assim algumas perdas inerentes ao processo de compressão. No processo de reconstrução da imagem, as transformadas são efetuadas em ordem inversa.

A grande vantagem da aplicação do processo descrito é o alto poder de agrupamento da informação que a aplicação das técnicas de PCA e DCT promovem. A maioria dos processos e técnicas de compressão apresenta algoritmos que impõem certas considerações que nem sempre são necessárias. O método proposto não impõe nenhuma condição, uma vez que todos os dados necessários para realização da compressão provêm da própria massa de dados (imagem).

3.1 – Determinação dos Limiares de compressão

A compressão acontece pelo simples descarte de alguns coeficientes das bandas no espaço gerado pela aplicação da DCT. A figura 3.2 mostra esse processo.

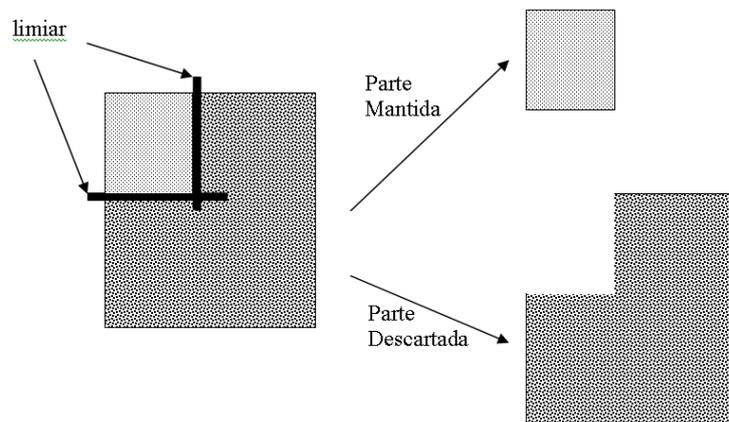


Figura 3.2 – Compressão por limiar, aplicado a DCT da imagem.

A principal contribuição deste artigo é a introdução de limiares diferentes para cada uma das bandas, de modo a proporcionar uma maior compressão na banda com menor quantidade de informação e compressão mais amena nas bandas com maior quantidade de informação. A medição dessa quantidade de informação é feita através dos autovalores associados a cada uma das bandas geradas pela PCA.

Durante a pesquisa realizada, foi desenvolvida uma métrica que permite calcular esse limiar de forma automática, sem a intervenção do usuário. Essa medida é calculada através da equação 3.1.

$$Th_k = round \left(\frac{x \cdot \sqrt{\lambda_k}}{\sum_{i=1}^N \sqrt{\lambda_i}} \right) \quad (3.1)$$

onde x é o tamanho da imagem, λ_k é o autovalor associado a banda k e N é o número de bandas da imagem.

4. Resultados

Aplicou-se a técnica a 3 imagens multiespectrais obtidas no banco de imagens da DGI/INPE (<http://www.dgi.inpe.br/CDSR/>). As imagens baixadas são da costa do Rio Grande do Norte e as imagens foram subdivididas em 16 imagens menores (1000 x 1000) denominadas de imagem_01 a imagem_16, visando apenas agilizar o processamento.

A Tabela 4.1 apresenta resultados obtidos nos diversos testes realizados, para cada um deles calculou-se o erro médio quadrático (EMQ) e a taxa de compressão (TXC), obtidos com as equações 4.1 e 4.2, respectivamente.

$$EMQ = \frac{\sum_{i=1}^N (img - img')}{NP} \quad (4.1)$$

$$TXC = \frac{\text{Bytes da Imagem Comprimida}}{\text{Bytes da Imagem Original}} \times 100 \quad (4.2)$$

onde img é a imagem original, img' é a imagem reconstruída, NP é o número de pixels das imagens e N é o número de bandas da imagem.

Tabela 4.1 – Resultados observados nas imagens processadas

Imagem	Tamanho	EMQ	TXC	Limiares					
				14	29	45	154	187	571
Imagem_01	1000x1000	98,11	6,46	14	29	45	154	187	571
Imagem_02	1000x1000	43,21	7,79	23	33	46	82	159	657
Imagem_03	1000x1000	24,69	10,73	12	14	24	70	87	794
Imagem_04	1000x1000	163,84	9,55	8	15	25	85	126	741
Imagem_05	1000x1000	206,08	6,07	15	29	75	157	175	550
Imagem_06	1000x1000	171,35	7,42	16	22	61	87	181	633
Imagem_07	1000x1000	5,82	8,63	38	43	52	70	92	706
Imagem_08	1000x1000	104,30	9,60	8	13	25	88	124	743
Imagem_09	1000x1000	70,86	6,31	20	40	49	142	183	566
Imagem_10	1000x1000	61,55	6,20	19	43	50	129	201	557
Imagem_11	1000x1000	57,26	7,45	21	45	62	87	144	642
Imagem_12	1000x1000	57,92	7,47	19	38	54	108	140	642
Imagem_13	1000x1000	85,52	8,05	19	32	39	109	130	672
Imagem_14	1000x1000	77,03	6,90	20	43	52	123	152	609
Imagem_15	1000x1000	70,36	6,81	22	48	61	109	155	605
Imagem_16	1000x1000	52,66	7,37	19	41	51	118	134	637

As figuras 4.1 e 4.2 mostram o comparativo entre as imagens 01 e 05 e suas respectivas reconstruções após o processo de compressão. As imagens mostradas nas figuras consistem na combinação dos planos 3, 2 e 1 como o RGB, respectivamente.

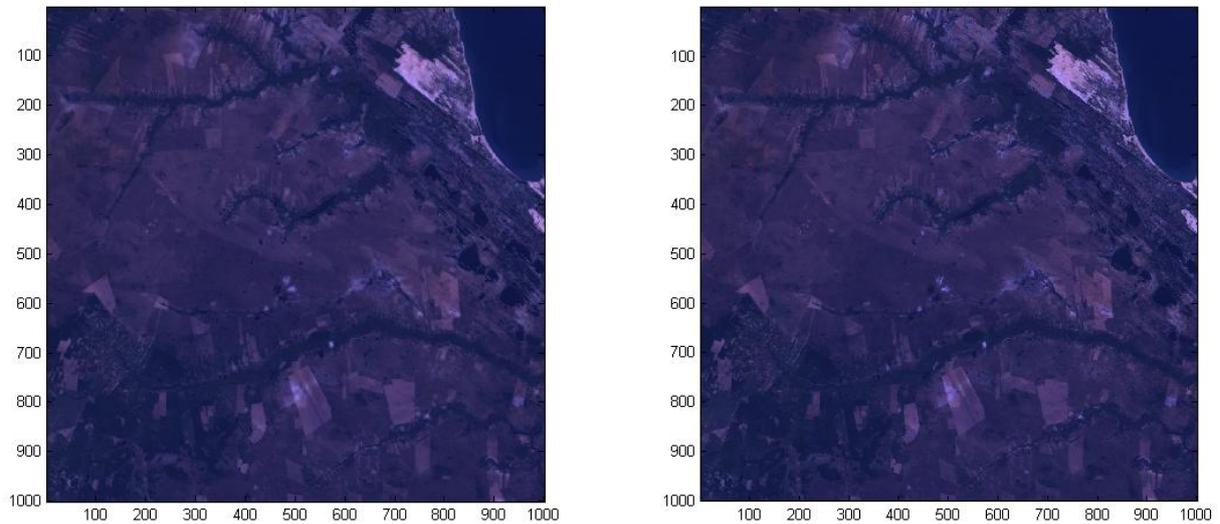


Figura 4.1 – Imagem_01 (a) reconstruída e (b) original

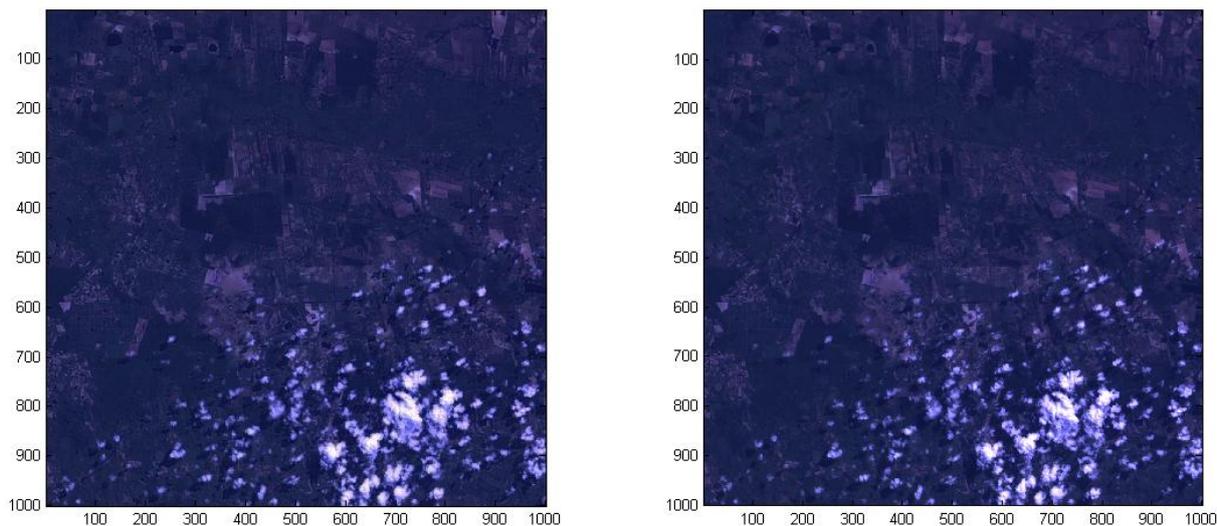


Figura 4.2 – Imagem_05 (a) reconstruída e (b) original

Tabela 4.2 – Compressão com transformada do Cosseno

Imagem	Tamanho	EMQ	TXC	Limiar
Imagem_01	1000x1000	144,37	9,99	316
Imagem_02	1000x1000	52,35	9,99	316
Imagem_03	1000x1000	47,17	9,99	316
Imagem_04	1000x1000	154,28	9,99	316
Imagem_05	1000x1000	190,21	9,99	316
Imagem_06	1000x1000	182,90	9,99	316
Imagem_07	1000x1000	9,579	9,99	316
Imagem_08	1000x1000	64,04	9,99	316
Imagem_09	1000x1000	113,10	9,99	316
Imagem_10	1000x1000	96,20	9,99	316
Imagem_11	1000x1000	103,36	9,99	316
Imagem_12	1000x1000	108,13	9,99	316
Imagem_13	1000x1000	147,82	9,99	316
Imagem_14	1000x1000	137,07	9,99	316
Imagem_15	1000x1000	126,26	9,99	316
Imagem_16	1000x1000	97,57	9,99	316

A figura 4.3 apresenta o resultado da compressão das mesmas imagens realizando apenas a transformada do cosseno, mantendo a matriz superior esquerda dos elementos 1 a 316 (limiar) e calcula-se a taxa de compressão que é de aproximadamente 10% e seus respectivos erros médios quadráticos.

O gráfico mostrado na figura 4.4 consiste em um comparativo entre os valores dos EMQ das duas compressões realizadas.

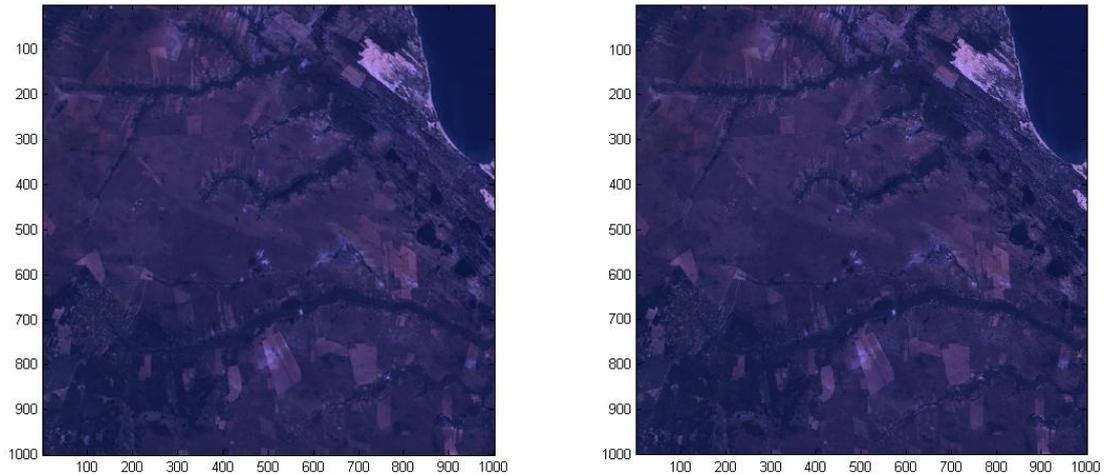


Figura 4.3 – Imagem_01 (a) reconstruída e (b) original utilizando apenas a DCT

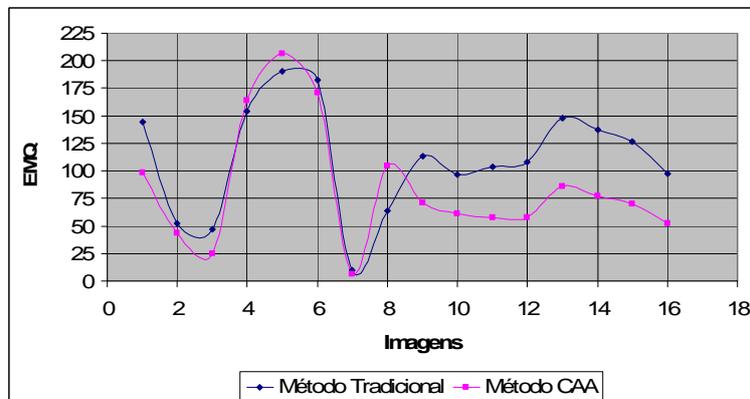


Figura 4.4 – Comparativo entre os dois processos para as 16 imagens utilizadas.

Na maioria das imagens o processo de compressão CAA conseguiu obter menor erro médio quadrático que o método tradicional utilizando apenas a transformada do cosseno, os poucos itens que não apresentou menor erro, apresentou maior taxa de compressão. Uma vez que a taxa de compressão do CAA não é conhecida *a priori*, as taxas de compressão dos métodos não são necessariamente iguais para cada imagem processada.

5. Conclusões

Este trabalho apresentou o processo de Compressão Auto-Adaptativa (CAA) aplicado a imagens de satélite multiespectrais. Como principais características desse método, destacam-se a diversidade de taxas de compressão que são aplicadas em cada um das bandas da imagem, além da não necessidade de intervenção do usuário, ou seja, o usuário não precisa especificar nenhum parâmetro e não há pré-definições ou considerações sobre os dados, uma vez que o processo é completamente orientado pelos próprios dados da imagem. Nos experimentos realizados foram utilizadas imagens multiespectrais da costa do Rio Grande do Norte, subdividida em imagens de tamanho 1000x1000 para agilizar o processo. Como parâmetros de comparação, foram calculados a taxa de compressão adaptativa de cada imagem, bem como o erro médio quadrático.

Os resultados obtidos com a aplicação da técnica proposta, foram melhores que os obtidos com a transformada do cosseno, que é utilizada na tradicional compressão do JPEG. Vale a pena lembrar que não foi considerada a compressão utilizada para comparar os resultados da CAA como o processo JPEG, pois o processo JPEG é destinado a imagens coloridas, não se

aplicando de forma direta a imagens multiespectrais. Diversos trabalhos futuros podem ser visualizados, como a investigação sobre como intervir na taxa de compressão, como incorporar bandas de resoluções diferentes, ou mesmo, como aplicar essa técnica em blocos menores visando um estudo de redução do custo computacional.

6. Referencias Bibliográficas

Anthony D. e Barham, J. "A comparison of image compression by a Neural Network and Principle Component Analysis". Proc. International Joint Conference on Neural Networks (IJCNN'90), pp. 339-344. IEEE, 1990. Disponível em <<http://ieeexplore.ieee.org/Xplore/login.jsp?url=/iel2/148/3745/00137591.pdf?arnumber=137591>> Acesso em 15 Ago 2004.

Bao, P.; Hung, H.; PCA neural network for JPEG image enhancement. Signals, Systems, and Computers, 1999. Conference Record of the Thirty-Third Asilomar Conference on. pp. 976-980 vol.2. Disponível em <<http://ieeexplore.ieee.org/Xplore/login.jsp?url=/iel5/6676/17893/00831855.pdf?temp=x>> Acessado em 20 Fev 2003.

Costa, José Alfredo Ferreira. Dória Neto, Adrião Duarte. Souza, Gustavo F. Compressão auto-adaptativa de imagens coloridas. XXVIII Congresso Nacional de Matemática Aplicada e Computacional. Santo Amaro, 2005. Disponível em <http://www.sbmac.org.br/eventos/cnmac/cd_xxviii_cnmac/> Acessado em 30 Mar 2008.

Duda, R. O., Hart, P. E. Pattern Classification. John Wiley & sons, 1998.

Gonzalez, R. C., Woods, R. E., Digital Image Processing, Addison-Wesley Publishing Company, 1992.

Martinelli, G.; Ricotti, L.P.; Marcone, G.; Neural clustering for optimal KLT image compression. Signal Processing, IEEE Transactions on. pp. 1737-1739.

Oliveira, P.R.; Romero, R.F.; Nonato, L.G.; Mazucheli, J.; Techniques for image compression a comparative analysis. Neural Networks, 2000. Proceedings. Sixth Brazilian Symposium on. pp. 249-254. Disponível em <<http://portal.acm.org/citation.cfm?id=827249.827519>>. Acessado em 15 Ago 2004.

Oliveira, P.R.; Romero, R.F. A comparison between PCA neural networks and the JPEG standard for performing image compression. In: Cybernetic Vision, 1996. Proceedings., Second Workshop on. pp. 112-116. Disponível em: <<http://ieeexplore.ieee.org/Xplore/login.jsp?url=/iel3/4969/13661/00629449.pdf?arnumber=629449>> Acesso em 10 Ago 2006.

Queiroz, R.L. de., Improved transforms for the compression of color and multispectral images.; Image Processing. 2002. Proceedings. 2002 International Conference on. pp. II-381- II-384 vol.2. Disponível em: <http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?isNumber=22295&prod=CNF&arnumber=1039967&arSt=+381&ared=+384&arNumber=1039967> Acessado em 22 Nov 2006.

Singh, I.; Agathoklis, P.; Antoniou, A., Compression of color images using mixed transform techniques. Communications, Computers and Signal Processing, 1997. '10 Years PACRIM 1987-1997 - Networking the Pacific Rim'. 1997 IEEE Pacific Rim Conference on. pp. 334-337 vol.1 Disponível em <<http://ieeexplore.ieee.org/Xplore/login.jsp?url=/iel3/4892/13485/00619967.pdf?arnumber=619967>> Acessado em 25 Jan 2004.

Souza, Gustavo F. Compressão auto-adaptativa de imagens coloridas. 2005. 58 p. (RN/UF/BCZM CDU 621.397/043.3). Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Norte, Natal - RN. 2005.

Tran, L.V.; Lenz, R.; PCA-based representation of color distributions for color-based image retrieval. Image Processing, 2001. Proceedings. 2001 International Conference on. pp. 697-700. Disponível em: <http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=958589> Acessado em 10 Nov 2005.