

Algoritmo do Vagalume Aplicado ao Projeto de Dicionários do COVQ

Herbert A. de Sá Leitão
Programa de Pós-Graduação
em Engenharia de Sistemas
POLI, UPE
Recife, PE, 50720-001
Email: halberico@pe.senai.br

Waslon T. A. Lopes
UFCG
Departamento de Engenharia Elétrica
Campina Grande, PB, 58109-970
Email: waslon@ieee.org

F. Madeiro
Programa de Pós-Graduação
em Engenharia de Sistemas
POLI, UPE
Recife, PE, 50720-001
Email: madeiro@poli.br

Resumo—Este artigo apresenta um método de aplicação do algoritmo do vagalume à etapa de projeto de dicionários do quantizador vetorial otimizado para canal, projetando dicionários para a quantização vetorial de imagens com transmissão por canal binário simétrico. O método, chamado de FA-COVQ (Firefly Algorithm – Channel Optimized Vector Quantization), buscou otimizar o valor de distorção média gerado no projeto de dicionários do quantizador vetorial otimizado para canal e, com isso, produzir dicionários mais robustos aos erros de canal, obtendo imagens reconstruídas de melhor qualidade. Os resultados mostram que o FA-COVQ reduziu em 93,61% dos casos a distorção média final dos dicionários projetados, quando comparado ao quantizador vetorial otimizado para canal. Este método também conseguiu melhorar o valor de relação sinal-ruído de pico das imagens reconstruídas: 91,66% dos conjuntos de dicionários do FA-COVQ avaliados no estudo apresentaram imagens reconstruídas com valor de relação sinal-ruído de pico maiores que as imagens reconstruídas pelos conjuntos de dicionários do quantizador vetorial otimizado para canal, sendo que este número sobe para 100,00% dos casos, quando o canal binário simétrico apresenta probabilidade de erro de bit de 0,005, de 0,010 e de 0,050.

I. INTRODUÇÃO

A quantização vetorial é uma técnica que pode ser utilizada na compressão de imagens [1], obtendo significativas taxas de compressão, podendo também ser utilizada em outras finalidades, como, por exemplo, marca d'água digital [2] e esteganografia [3]. No processo de compressão, o quantizador vetorial manipula a imagem tentando obter a menor perda possível na qualidade visual. Entretanto, a quantização vetorial é sensível a ruídos de transmissão. A quantização vetorial otimizada para canal é uma técnica de quantização que minimiza essa sensibilidade utilizando no projeto do dicionário informações da fonte e do canal de transmissão. A partir dessas informações o quantizador vetorial otimizado para canal (COVQ - *Channel Optimized Vector Quantizer*) consegue gerar um dicionário mais robusto a esse tipo de erro [4]. A melhoria na robustez dos dicionários contribui para a melhoria da qualidade final das imagens reconstruídas, aspecto importante que vem sendo objeto de estudo do aprimoramento e do desenvolvimento das técnicas de quantização vetorial.

A computação bioinspirada é uma área de estudos computacionais onde se desenvolvem algoritmos baseados em processos naturais ou em comportamentos sociais [5]. Em

problemas de otimização, como é o caso da etapa de projeto de dicionários da quantização vetorial, o uso de técnicas bioinspiradas vem contribuindo para melhorar o processo. A aplicação de técnicas de inteligência computacional ao COVQ, como, por exemplo, lógica nebulosa [6] e algoritmos genéticos [7], otimiza o projeto de dicionários do quantizador vetorial. Na quantização vetorial robusta, abordagem de quantização vetorial em que a atribuição dos índices aos vetores-códigos do dicionário projetado passa por um processo de organização, melhorando a qualidade do sinal reconstruído, o uso da técnica de resfriamento simulado (SA, *Simulated Annealing*), apresenta melhoria nos valores da relação sinal-ruído de pico (PSNR, *Peak Signal-to-Noise Ratio*) das imagens reconstruídas [8], [9]. Recentemente, algoritmos evolucionários [10]–[13], [19] passaram a ser utilizados na otimização do projeto de dicionários do algoritmo LBG (Linde-Buzo-Gray) introduzido em [14], com o intuito de melhorar a qualidade final das imagens reconstruídas, observada pelo aumento do valor de PSNR. Rajpoot *et al.*, em [15], apresentam a aplicação do algoritmo do sistema de colônia de formigas (ACS, *Ant Colony System*) ao projeto de dicionários do algoritmo LBG. Outra melhoria aplicada ao projeto de dicionários foi apresentada em [16], por Chen, Yang e Gou, utilizando a técnica de otimização por enxame de partículas (PSO, *Particle Swarm Optimization*). Em [17], Horng e Jiang desenvolveram um novo método de projeto de dicionários utilizando o algoritmo de otimização por acasalamento de abelhas (HBMO, *Honey-Bee Mating Optimization*); e Horng, em [18], mostra o desenvolvimento de um método utilizando o algoritmo do vagalume (FA - *Firefly Algorithm*).

O FA é uma forma de computação bioinspirada baseada na abordagem de enxame para otimização [19]. O FA é inspirado no comportamento social dos vagalumes e no fenômeno da bioluminescência. Baseado no fato de o FA ser uma metaheurística que obteve bons resultados quando aplicado ao algoritmo LBG, como é mostrado em [18], este artigo apresenta um método de aplicação do FA a um outro modelo de quantizador vetorial, o COVQ, pertencente a uma outra classe de quantização vetorial, a quantização vetorial otimizada para canal. O método é chamado de FA-COVQ. O artigo avalia a utilização do FA-COVQ no processo de quantização vetorial de imagens para transmissão em canal binário simétrico, procurando reduzir os valores de distorção média dos dicionários gerados. O estudo tem como objetivo

a melhoria na qualidade das imagens reconstruídas, e utiliza como métrica de avaliação os valores de PSNR obtidos.

O restante deste artigo encontra-se organizado da seguinte forma: a Seção II aborda o processo de quantização vetorial realizado pelo COVQ, a Seção III apresenta a metaheurística do algoritmo do vagalume, a seção IV descreve o funcionamento do FA-COVQ, os resultados obtidos no estudo são apresentados na Seção V e as conclusões na Seção VI.

II. COVQ

O COVQ é um modelo de quantização vetorial utilizado em aplicações que envolvem transmissão de sinais por canais com ruídos. A Figura 1 apresenta um diagrama de blocos que ilustra um sistema de transmissão utilizando o processo de quantização vetorial.

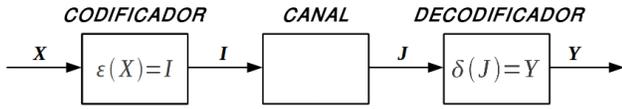


Figura 1. Sistema de transmissão utilizando quantização vetorial.

O codificador, $\varepsilon(\cdot)$, transforma um vetor X da imagem fonte, $X \in \mathbb{Z}^K$, em um índice $I = \varepsilon(X)$, $I \in \{0, 1, \dots, N-1\}$. Em que N é a quantidade de índices pertencentes ao conjunto. A operação do codificador está relacionada a um conjunto de particionamento de \mathbb{Z}^K , $P = \{S_0, S_1, \dots, S_{N-1}\}$, tal que $\varepsilon(X) = I \Leftrightarrow X \in S_i$. O decodificador, $\delta(\cdot)$, realiza o mapeamento do índice J , $J \in \{0, 1, \dots, N-1\}$, recebido após a transmissão, em um vetor-código (centróide) Y , $Y = \delta(J)$, $Y \in \mathbb{Z}^K$. O vetor-código Y faz parte de um conjunto denominado dicionário $\Phi = \{y_0, y_1, \dots, y_{N-1}\}$.

Seja $P_{y|x}(j|i)$ a probabilidade de transmitir i ($i \in \varepsilon$) e receber j ($j \in \delta$), devido ao erro do canal. Considere também que a medida de distorção $d(x, y)$ associada ao mapeamento de um vetor de entrada, x , em um vetor de saída, y , é dada pela distância euclidiana quadrática,

$$d(x, y) = \|x - y\|^2. \quad (1)$$

Para um modelo de canal binário simétrico, as regiões do conjunto de particionamento P são definidas por [4]

$$S_i = \left\{ x : \sum_{j=0}^{N-1} P_{y|x}(j|i) \|x - y_j\|^2 \leq \sum_{j=0}^{N-1} P_{y|x}(j|i') \|x - y_j\|^2, \quad \forall i' \neq i \right\}. \quad (2)$$

O vetor-código da j -ésima região do conjunto de particionamento P é dado por

$$y_j = \frac{\sum_{i=0}^{N-1} P_{y|x}(j|i) \sum_{S_i} x}{\sum_{i=0}^{N-1} P_{y|x}(j|i) |S_i|}, \quad (3)$$

em que $|S_i|$ é o número de vetores de treino pertencentes à região S_i .

III. ALGORITMO DO VAGALUME

O Algoritmo do Vagalume foi desenvolvido por Yang em 2008 na Universidade de Cambridge. O funcionamento do algoritmo é delineado por três regras simplificadas: (a) Os vagalumes não possuem sexo, portanto qualquer vagalume pode atrair ou ser atraído. (b) A atratividade é proporcional ao brilho emitido, assim um vagalume de menor brilho move-se em direção a um vagalume de maior brilho. No caso particular de um vagalume não possuir um outro vagalume de maior brilho a seguir, este move-se aleatoriamente. A atratividade β entre os vagalumes deve ser uma função monotonicamente decrescente em relação a distância $d(y_i, y_j)$ entre eles,

$$d(y_i, y_j) = |y_i - y_j|^2, \quad (4)$$

$$\beta = \beta_0 e^{-\gamma d(y_i, y_j)}, \quad \gamma > 0, \quad (5)$$

em que β_0 é a atratividade quando $d(y_i, y_j) = 0$ e γ é o coeficiente de absorção da luz.

O movimento de um vagalume i atraído por um vagalume j é dado por

$$y_i^t = (1 - \beta)y_i^{t-1} + \beta y_j^{t-1} + \alpha \left(\text{rand} - \frac{1}{2} \right), \quad (6)$$

em que t representa o instante de tempo, α é um parâmetro de regulação da aleatoriedade no percurso do vagalume, e rand é um número aleatório entre 0 e 1.

(c) O brilho emitido por um vagalume é determinado por sua avaliação frente à função objetivo (função de otimização); quanto melhor avaliado, mais brilhante é o vagalume.

IV. FA-COVQ

O funcionamento do FA-COVQ é apresentado nesta seção. As etapas que detalham o projeto de dicionários por este modelo de quantizador podem ser descritas da seguinte forma: (a) Inicialmente são gerados aleatoriamente C_p dicionários iniciais de tamanho N . Cada dicionário inicial será representado no FA-COVQ por um dos vagalumes. (b) Em seguida a imagem de treino é particionada em M vetores, formando o conjunto de treino $\Gamma = \{x_0, x_1, \dots, x_{M-1}\}$. (c) É realizado, para cada vagalume, o mapeamento dos M vetores de treino nas N regiões do conjunto de particionamento P . (d) Calcula-se para cada vagalume a distorção média \bar{D}_n ,

$$\bar{D}_n = \frac{1}{KM} \sum_{m=0}^{M-1} \sum_{j=0}^{N-1} P_{y|x}(j|\varepsilon(x_m)) d(x_m, y_j). \quad (7)$$

A intensidade do brilho do vagalume é o inverso da distorção média. Quanto menor for a distorção média (função de otimização) maior é o brilho do vagalume. (e) Com o resultado da distorção média, define-se a melhor solução momentânea,

o vagalume com maior brilho. (f) Na sequência, os vagalumes passam a ser atraídos por outros vagalumes de maior brilho, conforme é apresentado na Equação 6. (g) Com a atualização do posicionamento dos vagalumes, que representam os dicionários, torna-se necessário a realização de um novo mapeamento dos M vetores de treino nas N regiões do conjunto de particionamento P . (h) Tem-se então o início de uma nova iteração, onde se realiza um novo mapeamento dos vetores de treino nas regiões do conjunto de particionamento, conforme descrito na Equação 2. (i) Calcula-se o vetor-código para cada região do conjunto de particionamento P , conforme a Equação 3. (j) Calcula-se novamente, para cada vagalume, a distorção média \bar{D}_n , apresentada na Equação 7. (k) Realiza-se o teste de convergência, que consiste em verificar se

$$\frac{\bar{D}_{n-1} - \bar{D}_n}{\bar{D}_{n-1}} \leq \nu. \quad (8)$$

A condição de parada da etapa de projeto de dicionário do COVQ depende do limiar de distorção ν estabelecido. Caso o critério de parada não tenha sido alcançado, o quantizador retorna a ação descrita na etapa (e).

V. RESULTADOS

Esta seção apresenta os resultados obtidos utilizando as imagens apresentadas nas Figuras 2(a), 2(b) e 2(c), de 256×256 pixels, e com 256 níveis de cinza. As imagens foram utilizadas como conjunto de treino e como imagem fonte para o processo de quantização vetorial. Fazendo uso de dicionários iniciais aleatórios, foram projetados dicionários para o FA-COVQ, onde, para cada projeto de dicionário do FA-COVQ, o dicionário escolhido na primeira iteração, representando o vagalume de maior brilho, foi utilizado como dicionário inicial para o projeto de dicionários do COVQ. Foram avaliados dicionários de tamanho $N = 32$, 64 e 128 vetores-códigos, com dimensão $K = 16$ (blocos de 4×4 pixels), e com limiar de distorção $\nu = 0,001$, modelados para a decodificação das imagens transmitidas por canal binário simétrico com probabilidade de erro de bit (ϱ) de 0,005; 0,010; 0,050 e 0,100.

Os valores dos parâmetros aplicados ao FA-COVQ na etapa de projeto de dicionários são mostrados nas Tabelas I, II e III. O valor utilizado para o coeficiente de absorção de luz (γ) regula o valor resultante da exponencial da Equação 5, fazendo com que a multiplicação por β_0 resulte num valor de atratividade β no intervalo entre 0 e 1. Os valores de atratividade (β_0) utilizados foram obtidos a partir de uma análise prévia, onde foram observados valores de β_0 no intervalo entre 0 e 1, sendo escolhidos os valores de atratividade que geraram dicionários mais robustos aos erros de canal. A medida de robustez dos dicionários está relacionada a qualidade das imagens reconstruídas correspondentes. Quanto melhor a qualidade das imagens, mais robusto é o dicionário. A PSNR foi utilizada na avaliação da qualidade das imagens reconstruídas.

No estudo, para cada N , foram gerados 4 conjuntos de 20 dicionários, sendo um conjunto para cada canal binário simétrico com probabilidade de erro de bit (ϱ). Para esses conjuntos de dicionários, tem-se \overline{PSNR} como o valor

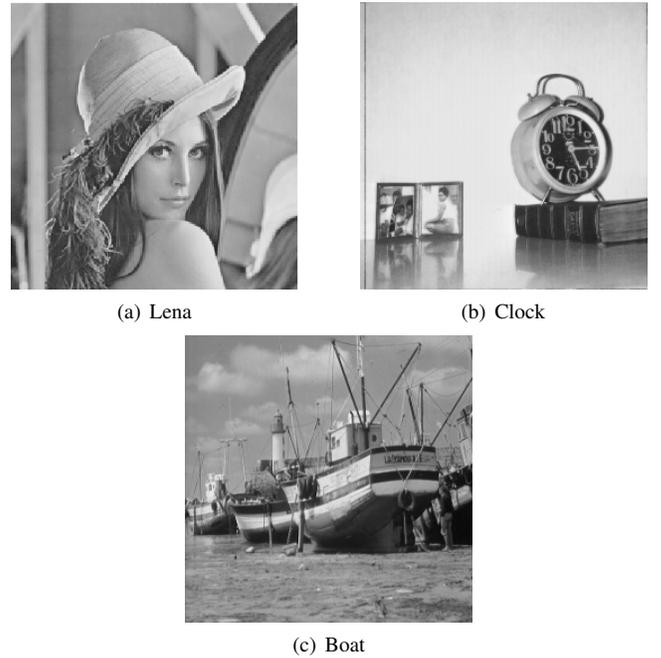


Figura 2. Imagens utilizadas de 256×256 pixels e com 256 níveis de cinza.

Tabela I. PARÂMETROS DO FA-COVQ PARA $N = 32$.

ϱ	γ	β_0		
		Lena	Clock	Boat
0,005	0,001	0,5	0,5	0,5
0,010	0,001	0,6	0,6	0,6
0,050	0,001	0,7	0,7	0,7
0,100	0,001	0,9	0,9	0,9

Tabela II. PARÂMETROS DO FA-COVQ PARA $N = 64$.

ϱ	γ	β_0		
		Lena	Clock	Boat
0,005	0,001	0,5	0,5	0,5
0,010	0,001	0,6	0,6	0,6
0,050	0,001	0,4	0,3	0,3
0,100	0,001	0,4	0,4	0,3

Tabela III. PARÂMETROS DO FA-COVQ PARA $N = 128$.

ϱ	γ	β_0		
		Lena	Clock	Boat
0,005	0,001	0,5	0,5	0,5
0,010	0,001	0,6	0,6	0,6
0,050	0,001	0,7	0,7	0,7
0,100	0,001	0,5	0,5	0,5

médio de relação sinal-ruído de pico das imagens reconstruídas por dicionário, considerando 50 transmissões. E tem-se \overline{PSNR}_{FINAL} como o valor médio de relação sinal-ruído de pico final para cada N e ϱ . A Tabela IV apresenta os valores de \overline{PSNR}_{FINAL} obtidos para as três imagens. Pode-se observar que 91,66% dos valores de \overline{PSNR}_{FINAL} obtidos pelo

Tabela IV. RESULTADOS DE \overline{PSNR}_{FINAL} OBTIDOS.

ϱ	Imagem	QV	$N = 32$	$N = 64$	$N = 128$
0,005	Lena	COVQ	25,14	25,86	26,33
		FA-COVQ	25,40	26,27	26,90
	Clock	COVQ	24,82	25,35	25,50
		FA-COVQ	25,23	25,73	26,16
	Boat	COVQ	23,88	24,49	25,06
		FA-COVQ	24,01	24,78	25,45
0,010	Lena	COVQ	24,50	24,78	24,71
		FA-COVQ	24,84	25,05	25,12
	Clock	COVQ	23,93	23,96	24,30
		FA-COVQ	24,19	24,31	24,86
	Boat	COVQ	23,32	23,65	23,69
		FA-COVQ	23,55	23,82	24,12
0,050	Lena	COVQ	20,65	20,91	21,04
		FA-COVQ	20,83	21,35	21,21
	Clock	COVQ	20,14	20,14	19,89
		FA-COVQ	20,38	20,22	20,37
	Boat	COVQ	20,08	20,49	20,62
		FA-COVQ	20,22	20,91	20,79
0,100	Lena	COVQ	19,02	19,08	18,73
		FA-COVQ	19,18	18,87	18,98
	Clock	COVQ	18,14	18,20	18,24
		FA-COVQ	18,12	18,26	18,27
	Boat	COVQ	18,71	18,72	18,05
		FA-COVQ	18,92	18,72	18,27

FA-COVQ foram maiores que os valores de \overline{PSNR}_{FINAL} do COVQ, subindo para 100,00% nos casos de canal binário simétrico com $\varrho = 0,005$, $\varrho = 0,010$ e $\varrho = 0,050$. Os melhores resultados de ganho em decibéis, do FA-COVQ em relação ao COVQ, foram obtidos com os dicionários de tamanho $N = 128$, modelados para canal binário simétrico com $\varrho = 0,005$, para as imagens Lena e Clock, 0,57 dB e 0,66 dB respectivamente.

Nas Figuras 3(a), 3(b), 3(c), 3(d), 3(e) e 3(f) são apresentadas as imagens Lena, Clock e Boat, reconstruídas após transmissão por canal binário simétrico com $\varrho = 0,005$, utilizando dicionários projetados pelo COVQ e pelo FA-COVQ de tamanho $N = 128$ vetores-código. Foram escolhidas imagens reconstruídas que apresentaram valores de PSNR próximos aos valores de \overline{PSNR}_{FINAL} apresentados na Tabela IV. Portanto, tem-se $PSNR = 26,32\text{ dB}$ para a imagem Lena reconstruída pelo COVQ, $PSNR = 26,91\text{ dB}$ para a imagem Lena reconstruída pelo FA-COVQ, $PSNR = 25,50\text{ dB}$ para a imagem Clock reconstruída pelo COVQ, $PSNR = 26,16\text{ dB}$ para a imagem Clock reconstruída pelo FA-COVQ, $PSNR = 25,06\text{ dB}$ para a imagem Boat reconstruída pelo COVQ e $PSNR = 25,49\text{ dB}$ para a imagem Boat reconstruída pelo FA-COVQ.

A Figura 4 mostra os resultados obtidos em um projeto de dicionários para a imagem Lena, sendo o tamanho do

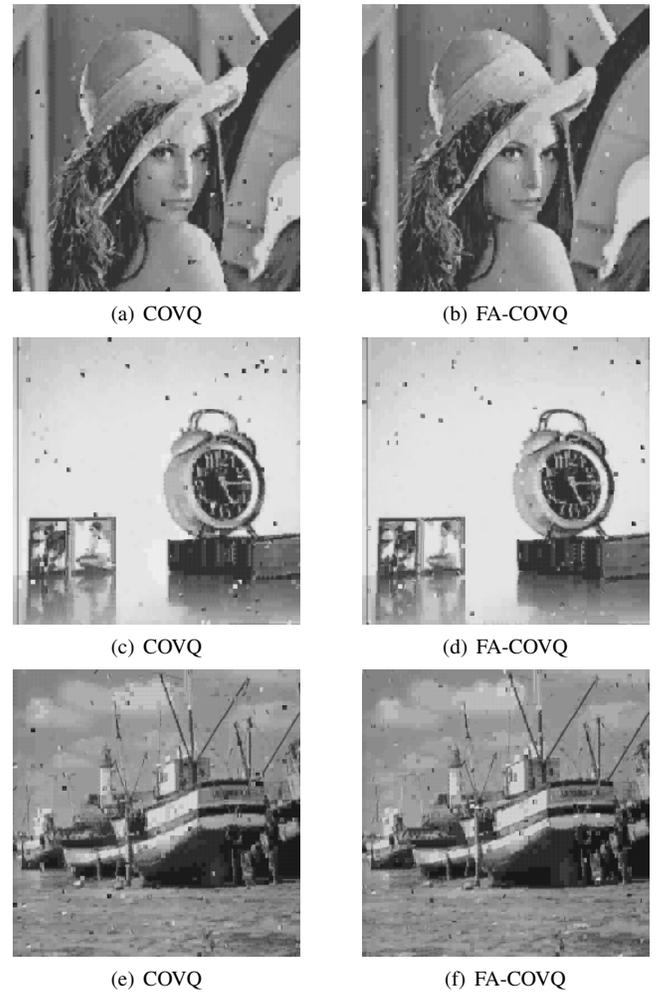


Figura 3. Resultados obtidos de imagens reconstruídas, após transmissão por canal binário simétrico com probabilidade de erro de bit $\varrho = 0,005$, utilizando dicionários projetados de tamanho $N = 128$ vetores-código.

dicionário $N = 128$ vetores-códigos e o canal com probabilidade de erro de bit $\varrho = 0,010$. São apresentadas na figura a distorção média a cada iteração (\overline{D}_n) para o COVQ e para o FA-COVQ. Os números mostrados junto a distorção média do FA-COVQ representam o vagalume que obteve o melhor resultado na iteração (salienta-se que este vagalume, por ser o de maior brilho, corresponde ao dicionário escolhido na iteração). Pode-se observar que na etapa de projeto de dicionários o FA-COVQ realizou 37 iterações, obtendo distorção média final $\overline{D} = 9,317 \cdot 10^6$. Nessas 37 iterações houve 35 trocas de vagalumes ao longo do processo, apresentando 21 vagalumes diferentes, o que mostra uma grande ação mútua entre os vagalumes. O COVQ realizou 30 iterações, obtendo distorção média final $\overline{D} = 9,796 \cdot 10^6$. A \overline{PSNR} das imagens reconstruídas pelo dicionário projetado pelo FA-COVQ foi de 25,01 dB, já as imagens reconstruídas pelo COVQ obtiveram \overline{PSNR} de 24,41 dB, o que representa, em média, uma melhoria de 0,60 dB na qualidade das imagens reconstruídas pelo FA-COVQ. Com relação à ação do FA-COVQ na otimização da distorção média final (\overline{D}) dos dicionários projetados, o resultado final do estudo mostrou que 93,61% dos dicionários projetados pelo FA-COVQ obtiveram valores de distorção média final menores quando comparados ao COVQ.

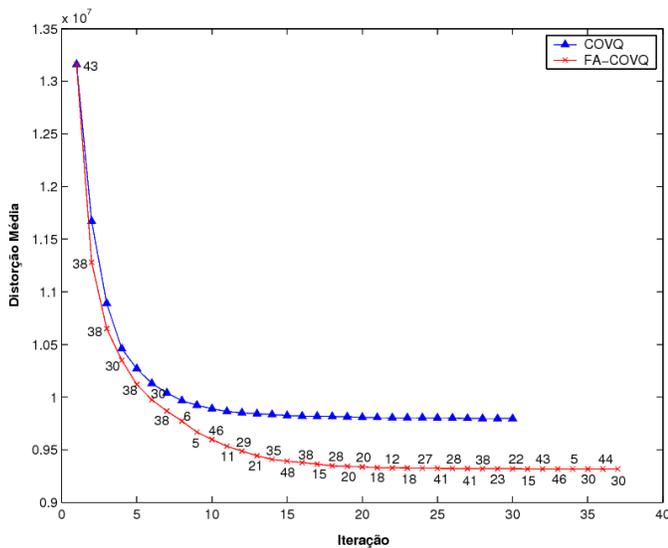


Figura 4. Resultados de minimização da distorção média \bar{D}_n em projeto de dicionário do FA-COVQ e do COVQ com a imagem Lena, utilizando dicionários de tamanho $N = 128$ vetores-código e com probabilidade de erro de bit $\rho = 0,010$.

VI. CONCLUSÕES

Este artigo apresentou um método de aplicação do algoritmo do vagalume à etapa de projeto de dicionários do quantizador vetorial otimizado para canal. O método, chamado de FA-COVQ, utilizou o algoritmo do vagalume para projetar dicionários com menor de distorção média final, tendo como objetivo a obtenção de imagens reconstruídas de melhor qualidade.

Os resultados finais do FA-COVQ apresentaram redução na distorção média final em 93,61% dos dicionários projetados, em comparação com os resultados obtidos pelo método COVQ convencional. O método também conseguiu melhorar o valor médio de relação sinal-ruído de pico final em 91,66% dos conjuntos de dicionários avaliados no estudo, sendo que este número sobe para 100,00% dos casos, quando o canal binário simétrico apresenta probabilidade de erro de bit de 0,005, 0,010 e 0,050. Foram obtidos com os dicionários de tamanho $N = 128$, modelados para canal binário simétrico com probabilidade de erro de bit $\rho = 0,005$, ganhos médios acima 0,57 dB, para as imagens Lena e Clock, o que em pesquisas envolvendo o quantizador vetorial otimizado para canal chega a representar um ganho expressivo. Além disso, nos casos de probabilidade de erro de bit mais baixas do estudo ($\rho = 0,005$ e $\rho = 0,010$), os parâmetros aplicados ao FA-COVQ são os mesmos para todas as imagens, o que generaliza a aplicação do método para essas faixas de probabilidade de erro de bit.

Como trabalho futuro será avaliado o impacto causado pelo aumento no número de vagalumes utilizados no projeto de dicionários, além da aplicação de outros algoritmos bioinspirados ao projeto de dicionários do quantizador vetorial otimizado para canal, como o algoritmo do sistema de colônia de formigas [10], o algoritmo de otimização por enxame de partículas [11], o algoritmo de otimização por acasalamento de abelhas [17], entre outros.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro do CNPq e do SENAI-PE.

REFERÊNCIAS

- [1] A. Gersho e R. M. Gray, *Vector Quantization and Signal Compression*, Massachusetts, USA: Kluwer Academic Publishers, 1992.
- [2] J. Shen e J. Ren, "A Robust Associative Watermarking Technique Based on Vector Quantization," *Digital Signal Processing*, vol. 20, pp. 1408–1423, Set. 2010.
- [3] C. Yang e Y. Lin, "Reversible Data Hiding of a VQ Index Table Based on Referred Counts," *Journal of Visual Communication and Image Representation*, vol. 20, pp. 399–407, Ago. 2009.
- [4] N. Favardin e V. Vaishapayan, "On the Performance and Complexity of Channel-Optimized Vector Quantizers," *IEEE Transactions on Information Theory*, vol. 37, pp. 155–160, Jan. 1991.
- [5] X. Yang, *Nature-Inspired Metaheuristic Algorithms*, 2^a ed. University of Cambridge, United Kingdom: Luniver Press, 2010.
- [6] W. Hwang, F. Lin e C. Lin, "Fuzzy Channel-Optimized Vector Quantization," *IEEE Communications Letters*, vol. 4, pp. 408–410, Dez. 2000.
- [7] W. Hwang, C. Ou e C. Yeh, "Genetic Channel-Optimized Vector Quantizer Design for Burst Error Channels," *New Aspects in Neurocomputing: 11th European Symposium on Artificial Neural Networks*, vol. 63, pp. 345–357, Jan. 2005.
- [8] A. R. S. Barreto, E. A. Lima e F. Madeiro, "Sobre o Índice de Desordem Como Figura de Mérito em Quantização Vetorial Robusta," em *Congresso de Matemática Aplicada e Computacional - Nordeste (CMAC-NE)*. Natal-RN, Brasil: Nov. 2012.
- [9] W. T. A. Lopes, F. Madeiro, M. S. Alencar e B. G. Aguiar Neto, "Quantização Vetorial Robusta Utilizando Simulated Annealing," em *Anais do V Congresso Brasileiro de Redes Neurais (CBRN'2001)*. Rio de Janeiro-RJ, Brasil: Abr. 2001.
- [10] M. Dorigo e C. Blum, "Ant Colony Optimization Theory: A Survey," *Theoretical Computer Science*, vol. 344, pp. 243–278, Nov. 2005.
- [11] J. Kennedy e R. Eberhart, "Particle Swarm Optimization," *Proceedings of IEEE International Conference on Neural Networks*, vol. 4, pp. 1942–1948, Nov/Dec. 1995.
- [12] S. Yang, M. Wang e L. Jiao, "A Quantum Particle Swarm Optimization," *Congress on Evolutionary Computation*, vol. 1, pp. 320–324, Jun. 2004.
- [13] T. E. Rinderer e A. M. Collins, *Bee Genetics and Breeding*, T. E. Rinderer ed. Academic Press, 1986.
- [14] Y. Linde, A. Buzo e R. Gray, "An Algorithm for Vector Quantizer Design," *IEEE Transactions on Communications*, vol. 28, pp. 84–95, Jan. 1980.
- [15] N. Rajpoot, A. Hussain, O. Ali e M. Qureshi, "A Novel Image Coding Algorithm Using Ant Colony System Vector Quantization," em *International Workshop on Systems, Signal and Image Processing (IWSSIP)*. Poznan, Polônia: Set. 2004.
- [16] Q. Chen, J. Yang e J. Gou, "Image Compression Method Using Improved PSO Vector Quantization," em *First International Conference on Neural Computation (ICNC 2005)*. Changsha, China: Ago. 2005.
- [17] M. Horng e T. Jiang, "Image Vector Quantization Algorithm via Honey Bee Mating Optimization," *Expert Systems with Applications*, vol. 38, pp. 1382–1392, Mar. 2011.
- [18] M. Horng, "Vector Quantization Using The Firefly Algorithm for Image Compression," *Expert Systems with Applications*, vol. 39, pp. 1078–1091, Jan. 2012.
- [19] X. Yang, "Firefly Algorithms for Multimodal Optimization," *Stochastic Algorithms: Foundation and Applications, SAGA 2009, Lecture Notes in Computer Sciences*, vol. 5792, pp. 169–1178, Out. 2009.