

SOBRE O PROJETO DE DICIONÁRIOS DE COVQ EM CONDIÇÕES MAIS SEVERAS QUE AS DO CANAL DE TRANSMISSÃO

FELIPE A. B. S. FERREIRA*, FRANCISCO MADEIRO†

**Centro de Tecnologia e Geociências (CTG)*
Universidade Federal de Pernambuco (UFPE)
Recife, PE, Brasil

†*Escola Politécnica de Pernambuco (POLI)*
Universidade de Pernambuco (UPE)
Recife, PE, Brasil

Emails: felipe.bsferreira@ufpe.br, madeiro@poli.br

Abstract— Vector Quantization is a lossy compression technique that allows high compression rates, which play a fundamental role in storage and transmission applications across a variety of multimedia systems. Despite its compression capabilities, Vector Quantization is highly sensitive to transmission noise, compromising the final quality of the transmitted signals. In this scenario, Channel-Optimized Vector Quantization (COVQ) is used because it considers characteristics of the transmission channel itself to design codebooks more robust to channel errors. The objective of this work is to design the codebooks under more severe conditions, in terms of bit error probability (BEP), than those of the transmission channel itself. Computer simulations were performed considering a Binary Symmetric Channel (BSC) and it was observed that it is possible to reduce the impact of transmission errors in the reconstructed images if codebooks are designed considering a BEP greater than that of the channel.

Keywords— Image compression, Channel-optimized vector quantization, Binary symmetric channel.

Resumo— Quantização Vetorial é uma técnica de compressão com perdas que permite altas taxas de compressão, o que é fundamental para aplicações de armazenamento e transmissão em diversos sistemas multimídia. Apesar de sua capacidade de compressão, a Quantização Vetorial é muito sensível aos ruídos de transmissão, comprometendo a qualidade final dos sinais transmitidos. Neste cenário vem sendo utilizada a Quantização Vetorial Otimizada para Canal (COVQ, *Channel-Optimized Vector Quantization*), que utiliza características do próprio canal de transmissão para projetar dicionários mais robustos aos erros de canal. O objetivo deste trabalho é projetar dicionários sob condições mais severas, quanto à probabilidade de erro de bit (BEP, *Bit Error Probability*), que as do próprio canal de transmissão. Foram realizadas simulações computacionais considerando um Canal Binário Simétrico (BSC, *Binary Symmetric Channel*) e foi observado que é possível diminuir o impacto dos erros de transmissão nas imagens reconstruídas se os dicionários forem projetados considerando um valor de BEP maior do que o do canal.

Palavras-chave— Compressão de imagens, Quantização vetorial otimizada para canal, Canal binário simétrico.

1 Introdução

Métodos de compressão têm um papel fundamental em aplicações que envolvem transmissão e armazenamento de sinais, pois permitem reduzir a quantidade de bits necessária para representar o sinal (Gersho and Gray, 1992). Um desafio relevante é obter uma alta taxa de compressão a um custo baixo em termos de degradação o sinal.

A Quantização Vetorial (VQ, *Vector Quantization*) (Gray, 1984) é um exemplo de técnica de compressão com perdas que permite altas taxas de compressão. Entre várias aplicações existentes para VQ, podem ser citadas a compressão de imagem (Alkhalaf et al., 2015), esteganografia (Chang et al., 2015) e marca d'água digital (Hu et al., 2014). Sistemas de compressão baseados em Quantização Vetorial são muito sensíveis aos ruídos de canal, que podem levar a sinais reconstruídos de baixa qualidade. No caso de VQ de imagens, os erros provocados pelos ruídos do canal durante a transmissão da imagem geram artefatos espúrios que comprometem a qualidade

da imagem reconstruída (Farvardin, 1990) (Leitao et al., 2015). A Figura 1b apresenta uma imagem quantizada e transmitida por um canal ruidoso. Note os artefatos espúrios presentes na Figura 1b e não presentes na Figura 1a.

Em se tratando de VQ, um problema relevante é o projeto de dicionários robustos a erros de canal. Nesse cenário, a Quantização Vetorial Otimizada para Canal (COVQ, *Channel-Optimized Vector Quantization*) (Farvardin and Vaishampayan, 1991) tem sido utilizada. Considerando a transmissão do sinal por um canal ruidoso, COVQ leva a sinais reconstruídos com melhor qualidade do que os obtidos com o uso de VQ convencional (isto é, considerando canal sem erro). O algoritmo utilizado em quantizadores vetoriais otimizados para canal, em geral, se baseiam em uma modificação do algoritmo LBG (Linde-Buzo-Gray) (Linde et al., 1980) em que são levadas em conta algumas características específicas do canal de transmissão, como a probabilidade de erro do canal (Farvardin and Vaishampayan, 1991).

A contribuição deste trabalho consiste no uso



Figura 1: (a) Imagem transmitida por um canal sem ruído e (b) transmitida por um canal com 5% de probabilidade de erro de bit.

de fatores multiplicativos, de forma que a probabilidade de erro durante o projeto de dicionários COVQ seja maior que a probabilidade de erro do canal de transmissão. O objetivo é produzir dicionários mais robustos que os dicionários gerados pelo método COVQ convencional, com relação à qualidade do sinal após transmissão, ao projetar dicionários sob condições mais severas que as presentes no canal pelo qual o sinal será transmitido. Em simulações envolvendo Canais Binários Simétricos (BSC, *Binary Symmetric Channel*) observou-se uma superioridade da abordagem proposta sobre a abordagem convencional, para probabilidades de erro de bit (BEP, *Bit Error Probability*) altas, como 5% e 10%.

O restante do trabalho encontra-se organizado da seguinte forma: a Seção 2 apresenta conceitos fundamentais da Quantização Vetorial Otimizada para Canal, a Seção 3 apresenta o arranjo experimental e a contribuição do trabalho, na Seção 4 são apresentados os resultados de simulação, e na Seção 5 são apresentadas as conclusões.

2 Quantização Vetorial Otimizada para Canal

Matematicamente, VQ pode ser descrita como o mapeamento de um vetor de entrada \vec{x} que pertence a um espaço Euclidiano k -dimensional, \mathbb{R}^k , em um subespaço finito $Y = \{\vec{y}_0, \vec{y}_1, \vec{y}_2, \dots, \vec{y}_{N-1}\}$ chamado dicionário, ou seja,

$$Q : \mathbb{R}^k \rightarrow Y, \quad (1)$$

em que k é a dimensão do quantizador e N é o número de vetores-código do dicionário. O mapeamento de um vetor de entrada \vec{x} em um vetor-código é realizado por um processo chamado de busca do vizinho mais próximo, de acordo com algum critério de distância mínima. O mapeamento Q pode ser definido como

$$Q(\vec{x}) = \vec{y}_i \Leftrightarrow d(\vec{x}, \vec{y}_i) < d(\vec{x}, \vec{y}_j) \quad \forall j \neq i, \quad (2)$$

em que $d(\vec{x}, \vec{y}_i)$ representa alguma medida de distância entre o vetor de entrada \vec{x} e o i -ésimo vetor-

código \vec{y}_i . Uma medida comumente utilizada em VQ é a distância Euclidiana quadrática, definida por

$$d(\vec{x}, \vec{y}_i) = \sum_{j=0}^{k-1} (x_j - y_{ij})^2, \quad (3)$$

em que x_j é a j -ésima componente do vetor de entrada \vec{x} e y_{ij} é a j -ésima componente do vetor-código \vec{y}_i .

O projeto do dicionário Y é fundamental para a qualidade final do mapeamento Q . O dicionário pode ser projetado por um algoritmo que tem como entrada um conjunto de vetores-treino. O alvo é reduzir a distorção média ao representar os vetores-treino pelos respectivos vetores-código. No projeto de dicionários de COVQ, a classificação dos vetores-treino em vetores-código é realizada com base na medida de distância entre os vetores e na probabilidade de erro de bit (BEP, *Bit Error Probability*) do canal. O processo de classificação Q' em COVQ, no projeto de dicionário, é dado por

$$Q'(\vec{x}) = \vec{y}_i \Leftrightarrow \sum_{a=0}^{N-1} P(a|i) d(\vec{x}, \vec{y}_a) < \sum_{b=0}^{N-1} P(b|j) d(\vec{x}, \vec{y}_b) \quad \forall j \neq i, \quad (4)$$

em que $P(a|i)$ representa a probabilidade de receber o índice a dado que foi enviado o índice i , $P(b|j)$ representa a probabilidade de receber o índice b dado que foi enviado o índice j . Então, dado um conjunto de treino $X = \{\vec{x}_0, \vec{x}_1, \vec{x}_2, \dots, \vec{x}_{M-1}\}$ e um limiar de distorção μ , o projeto de dicionários COVQ pode ser realizado em um processo iterativo da seguinte forma:

- **Passo 1:** Gere um dicionário inicial, $Y = \{\vec{y}_0, \vec{y}_1, \vec{y}_2, \dots, \vec{y}_{N-1}\}$ por algum método de inicialização, como geração aleatória;
- **Passo 2:** Classifique os vetores-treino em termos de distância mínima com relação aos vetores-código do dicionário atual de acordo com a Equação (4);
- **Passo 3:** Calcule a distância média geral, D , entre os vetores-treino e seus respectivos vetores-código mais próximos de acordo com

$$D = \frac{1}{kM} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} P(j|\xi(\vec{x}_i)) d(\vec{x}_i, \vec{y}_j), \quad (5)$$

em que $\xi(\vec{x}_i)$ é o índice do vetor-código mais próximo ao vetor-treino \vec{x}_i .

- **Passo 4:** Se a condição

$$\frac{D_{\text{anterior}} - D_{\text{atual}}}{D_{\text{anterior}}} < \mu, \quad (6)$$

não for satisfeita, seguir para o próximo passo. Caso contrário, encerrar a execução e retornar o dicionário Y atual. Os valores D_{anterior} e D_{atual} representam a distância média geral da iteração anterior e atual, respectivamente.

- **Passo 5:** Atualize cada vetor-código, \vec{y}_i , do dicionário Y de acordo com os vetores-treino e classificação realizada no **Passo 2**, conforme

$$\vec{y}_i = \frac{\sum_{j=0}^{N-1} \left(P(j|i) \sum_{S_j} \vec{x} \right)}{\sum_{j=0}^{N-1} P(j|i) |S_j|}, \quad (7)$$

em que S_j representa o conjunto de vetores-treino \vec{x} classificados pelo j -ésimo vetor-código e $|S_j|$ é o número de vetores-treino pertencentes ao conjunto S_j . Retorne ao **Passo 2**.

3 Arranjo experimental

Foi utilizado um total de 9 imagens nas simulações, apresentadas nas Figuras 2 e 3. Todas as imagens são de 256×256 pixels e 8 bits/pixel, ou seja, 256 níveis de cinza.

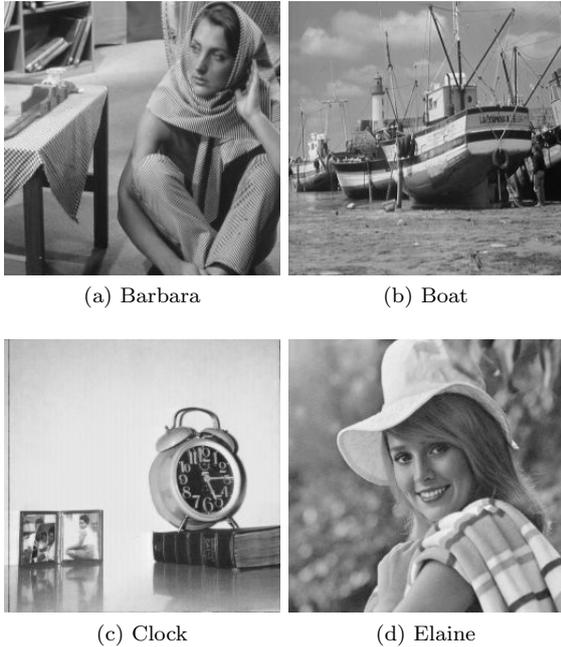
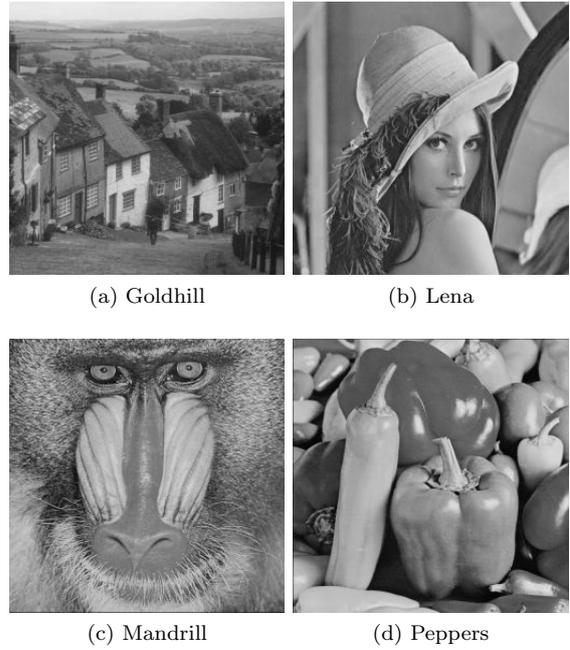


Figura 2: Imagens utilizadas nas simulações (a) Barbara, (b) Boat, (c) Clock e (d) Elaine.

A contribuição do trabalho diz respeito ao arranjo experimental realizado a fim de investigar a relação da probabilidade de erro usada no projeto de dicionários COVQ e a presente no canal de transmissão. A probabilidade apresentada nas Equações (2), (5) e (7) depende do canal pelo qual o sinal será transmitido. No presente trabalho foi



(e) Tiffany

Figura 3: Imagens utilizadas nas simulações (a) Goldhill, (b) Lena, (c) Mandrill, (d) Peppers e (e) Tiffany.

utilizado um Canal Binário Simétrico (BSC, *Binary Symmetric Channel*). Neste modelo de canal, cada bit transmitido tem uma probabilidade p de ser invertido durante a transmissão, e $1 - p$ de ser enviado corretamente. Um sistema com o COVQ convencional utiliza a mesma probabilidade de erro de bit p durante a fase de projeto de dicionários e durante a fase de transmissão. Neste trabalho estão sendo utilizados valores diferentes nestas duas etapas. Para um BSC de probabilidade de erro p , está sendo considerada durante a fase de projeto de dicionários uma probabilidade de erro $p \times f$, com $f \geq 1$. A intenção é que f funcione como um fator multiplicativo de forma que o dicionário seja projetado para um canal de f vezes a probabilidade de erro p , mas o sinal reconstruído é transmitido por um canal de probabilidade de erro p . A hipótese deste trabalho é que um dicionário projetado para uma probabilidade de erro maior que a probabilidade de erro do canal leva a uma maior qualidade da imagem após a transmissão. O arranjo experimental foi montado de forma a validar ou não esta hipótese e identificar

um possível f ideal para um conjunto de imagens, tamanho de dicionário N e probabilidade de erro de canal.

A Figura 4 apresenta o esquema utilizado para o projeto de dicionários considerando uma das 9 imagens utilizadas. Na etapa 1 são gerados 10 dicionários iniciais. Cada dicionário inicial é gerado de forma aleatória extraindo *pixels* da imagem original. Foi considerada dimensão $k = 16$, então para formar os dicionários iniciais, foram escolhidos, em cada projeto, N conjuntos de 16 *pixels* aleatórios. Neste trabalho foram realizadas simulações com $N = 32, 64, 128$ e 256 . Essa etapa é realizada para cada um dos 4 tamanhos de dicionário utilizados. Na etapa 2, cada um dos 10 dicionários iniciais é utilizado como entrada para o quantizador vetorial otimizado para canal. Neste trabalho foram consideradas 4 probabilidades de erro de bit (BEP, *Bit Error Probability*): $0,005; 0,05; 0,01$ e $0,1$. Porém, nesta etapa, para cada BEP é aplicado um dos 12 fatores multiplicativos utilizados nas simulações. São eles: $1,0\times; 1,1\times; 1,2\times; 1,5\times; 1,7\times; 2,0\times; 3,0\times; 5,0\times; 6,0\times; 7,0\times; 8,5\times$ e $10,0\times$. Ao aplicar o fator $1,0\times$, a probabilidade de erro de canal original não é alterada e, portanto, neste caso, trata-se de um quantizador vetorial otimizado para canal convencional. Na etapa 3, a imagem é quantizada utilizando cada um dos dicionários projetados e é transmitida 20 vezes por um canal ruidoso com probabilidade de erro sem o uso de fator multiplicativo. A cada transmissão, a imagem é reconstruída e é calculado o respectivo PSNR (*Peak Signal-to-Noise Ratio*). Ao final das 20 transmissões, a média dos valores de PSNR é armazenada e utilizada para comparações.

A métrica PSNR, relação sinal-ruído de pico, é dada por

$$\text{PSNR} = 10 \log_{10} \left(\frac{\text{MAX}^2}{\text{MSE}} \right), \quad (8)$$

em que MAX indica o valor máximo de *pixel* em uma imagem. Como as imagens utilizadas neste trabalho possuem 8 bits/*pixel*, o valor máximo é $2^8 - 1 = 255$. O MSE (*Mean Squared Error*) representa o erro médio quadrático entre a imagem original e reconstruída, e é dado por

$$\text{MSE} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (O_{ij} - R_{ij}), \quad (9)$$

em que m e n são as dimensões da imagem, O_{ij} é o valor do *pixel* correspondente à i -ésima linha e j -ésima coluna da imagem original e R_{ij} é o valor do *pixel* correspondente à i -ésima linha e j -ésima coluna da imagem reconstruída. O valor do PSNR é dado em dB (decibéis).

As simulações foram executadas considerando a combinação de todas as variáveis apresentadas na Tabela 1. No total foram realizadas 1728 simulações

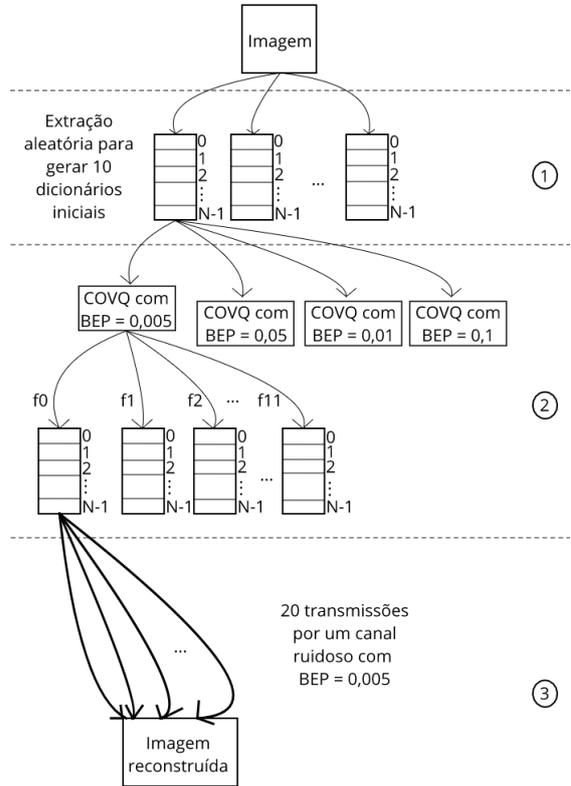


Figura 4: Esquema utilizado no projeto de dicionário das simulações realizadas.

4 Resultados e discussão

Dentre os 11 fatores multiplicadores para a probabilidade de erro de bit que foram analisados, os resultados de simulação mostraram que, em geral, não convém utilizar os seguintes: $1,1\times; 1,2\times; 1,5\times; 6,0\times; 7,0\times; 8,5\times$ e $10,0\times$. Em um número elevado de simulações, os fatores $6,0\times; 7,0\times; 8,5\times$ e $10,0\times$ produziram dicionários que levaram a imagens reconstruídas com valor de PSNR menor que o obtido pelo projeto convencional, isto é, sem fator multiplicativo. Dentre os fatores multiplicativos $1,7\times; 2,0\times; 3,0\times$ e

Tabela 1: Variáveis utilizadas em combinação para realização das simulações.

Fator	Imagem	N	BEP
$1,0\times$	Barbara	32	0,005
$1,1\times$	Boat	64	0,050
$1,2\times$	Clock	128	0,010
$1,5\times$	Elaine	256	0,100
$1,7\times$	Goldhill	—	—
$2,0\times$	Lena	—	—
$3,0\times$	Mandrill	—	—
$5,0\times$	Peppers	—	—
$6,0\times$	Tiffany	—	—
$7,0\times$	—	—	—
$8,5\times$	—	—	—
$10,0\times$	—	—	—

5,0×, a grande maioria dos melhores (mais elevados) valores de PSNR das imagens reconstruídas estão associados ao fator 3,0×. A segunda melhor alternativa é o fator 2,0×.

De uma forma geral, dentre as quatro BEP consideradas, o uso de fator multiplicativo parece ser uma alternativa adequada, isto é, que leva a valores de PSNR maiores que os obtidos com dicionários projetados pelo método convencional, para probabilidades 0,05 e 0,1. Para as probabilidades de erros mais baixas, isto é, 0,005 e 0,01, o uso de fator multiplicativo leva a valores de PSNR que muitas vezes são inferiores aos obtidos com o método convencional. É importante mencionar que o uso do fator multiplicativo proposto neste trabalho não afeta a complexidade computacional do projeto de dicionários, visto que a única diferença é a utilização de uma probabilidade de erro diferente da do canal de transmissão.

As Figuras 5, 6, 7, 8, 9, 10, 11, 12 e 13 apresentam a curva de PSNR *versus* BEP para as 9 imagens utilizadas neste trabalho (Barbara, Boat, Clock, Elaine, Goldhill, Lena, Mandrill, Peppers e Tiffany, respectivamente) considerando tamanho de dicionário $N = 256$ e diversos fatores multiplicativos. As curvas são próximas para probabilidades de erro de bit iguais a 0,005 e 0,01, e começam a se distanciar para $BEP = 0,05$. Para $BEP = 0,1$; note que a linha azul, referente ao fator multiplicativo 3,0×, está, em geral, acima de todas as demais. Em todos os casos a linha azul está acima da linha vermelha (referente ao fator multiplicativo 1,0×, ou seja, COVQ convencional).

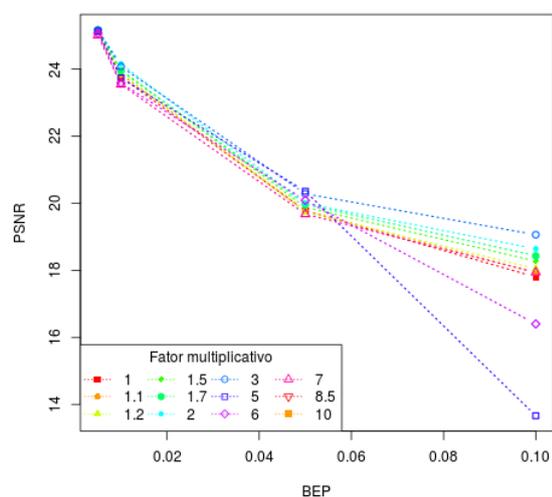


Figura 5: PSNR para a imagem Barbara.

Trabalhos já foram publicados com melhorias do quantizador vetorial otimizado para canal com relação à qualidade final da imagem reconstruída (Leitao et al., 2015), (Ferreira et al., 2017), (Ferreira and Madeiro, 2016). De maneira geral,

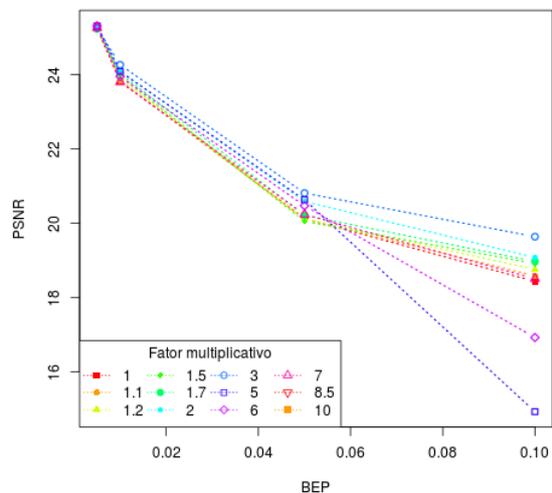


Figura 6: PSNR para a imagem Boat.

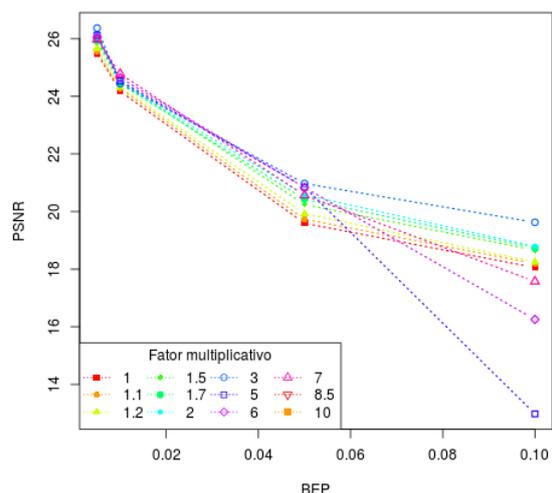


Figura 7: PSNR para a imagem Clock.

os maiores ganhos de PSNR são obtidos para baixas probabilidade de erro de canal, como 0,005 e 0,01. Para probabilidades de erro mais altas, como 0,05 e 0,1, os esforços computacionais desses algoritmos, de maneira geral, não contribuem para ganhos de PSNR. Observa-se, diante do exposto, a contribuição da técnica ora investigada.

5 Conclusões

Neste trabalho é proposto o uso de fatores multiplicativos na probabilidade de erro de canal durante o projeto de dicionários em um quantizador vetorial otimizado para canal. O objetivo é projetar dicionários considerando probabilidades de erro de bit maiores do que a probabilidade de erro de bit presente no canal, ou seja, projetar dicionários

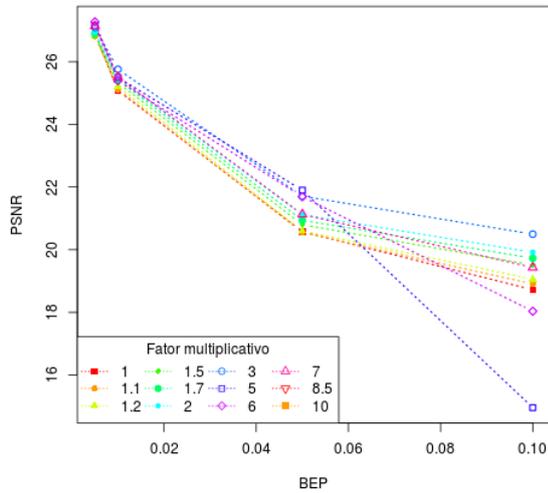


Figura 8: PSNR para a imagem Elaine.

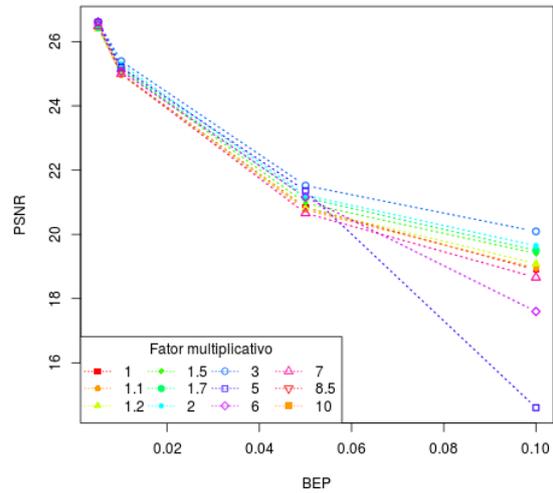


Figura 10: PSNR para a imagem Lena.

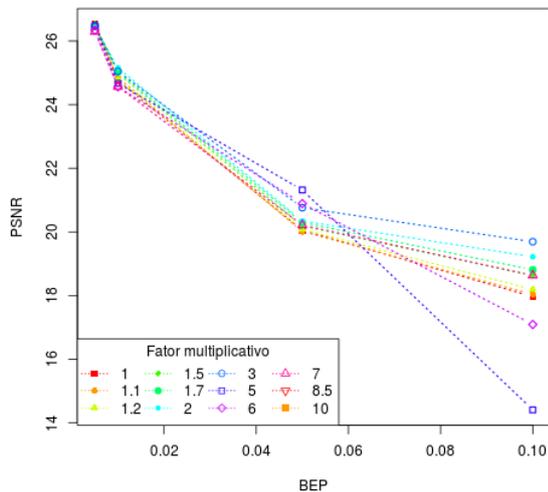


Figura 9: PSNR para a imagem Goldhill.

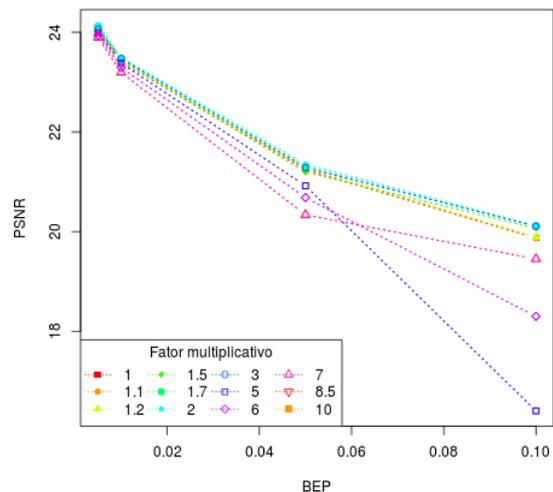


Figura 11: PSNR para a imagem Mandrill.

onários sob condições mais severas do que as do meio de transmissão. Foram realizados diversos experimentos considerando 9 imagens, 12 fatores multiplicativos, 4 tamanhos de dicionário e 4 probabilidades de erro de canal, com um total de 1728 simulações executadas. Como resultado deste trabalho foram obtidas as seguintes conclusões:

- É possível obter ganhos de PSNR utilizando fatores multiplicativos de BEP na fase de projeto de dicionário para COVQ;
- Dentre os fatores multiplicativos avaliados, o que mais se destacou foi 3,0×;
- Os maiores ganhos de PSNR foram obtidos para probabilidade de erro de canal elevadas, como 0,05 e 0,1.

Recentemente, um conjunto de técnicas bioinspiradas vêm sendo aplicadas no projeto de dicionários COVQ com o objetivo de melhorar o desempenho do quantizador quanto à qualidade de reconstrução das imagens (Leitao et al., 2015), (Ferreira et al., 2017), (Ferreira and Madeiro, 2016). Como trabalho futuro, pretende-se investigar o uso de fatores multiplicativos de BEP em conjunto com essas técnicas com o objetivo de obter melhores resultados de PSNR das imagens reconstruídas, em condições mais severas de canal.

Agradecimentos

Os autores gostariam de agradecer ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e à FACEPE (Fundação de Amparo

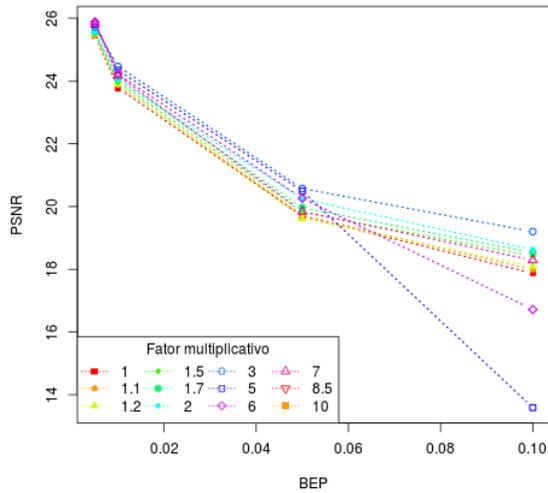


Figura 12: PSNR para a imagem Peppers.

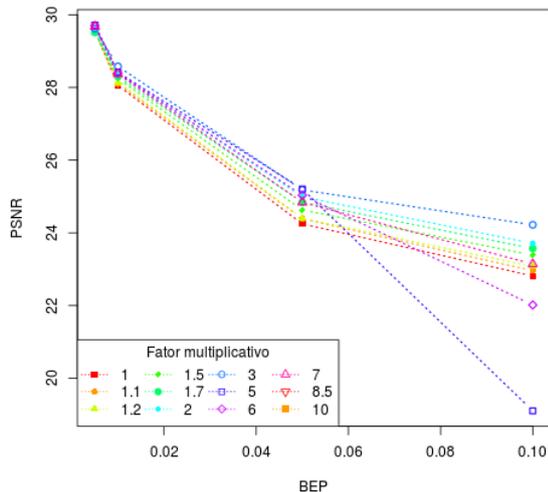


Figura 13: PSNR para a imagem Tiffany.

à Ciência e Tecnologia do Estado de Pernambuco) pelo suporte financeiro ao presente trabalho.

Referências

- Alkhalaf, S., Alfarraj, O. and Hemeida, A. M. (2015). Fuzzy-VQ image compression based hybrid PSOGSA optimization algorithm, *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, IEEE, pp. 1–6.
- Chang, C.-C., Nguyen, T. S. and Lin, C.-C. (2015). A reversible compression code hiding using SOC and SMVQ indices, *Information Sciences* **300**: 85–99.

Farvardin, N. (1990). A study of vector quantization for noisy channels, *IEEE Transactions on Information Theory* **36**(4): 799–809.

Farvardin, N. and Vaishampayan, V. (1991). On the performance and complexity of channel-optimized vector quantizers, *IEEE Transactions on Information Theory* **37**(1): 155–160.

Ferreira, F. A., Leitão, H. A., Lopes, W. T. and Madeiro, F. (2017). Hybrid firefly-lindebuzo-gray algorithm for channel-optimized vector quantization codebook design, *Integrated Computer-Aided Engineering* **24**(3): 297–314.

Ferreira, F. A. and Madeiro, F. (2016). A fish school search based algorithm for image channel-optimized vector quantization, *Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference on*, IEEE, pp. 001680–001685.

Gersho, A. and Gray, R. M. (1992). *Vector quantization and signal compression*, Springer Science & Business Media, Massachusetts, USA.

Gray, R. M. (1984). Vector quantization, *IEEE ASSP Magazine* pp. 4–29.

Hu, H.-T., Hsu, L.-Y. and Chou, H.-H. (2014). Variable-dimensional vector modulation for perceptual-based DWT blind audio watermarking with adjustable payload capacity, *Digital Signal Processing* **31**: 115–123.

Leitao, H. A. S., Lopes, W. T. A. and Madeiro, F. (2015). PSO algorithm applied to codebook design for channel-optimized vector quantization, *IEEE Latin America Transactions* **13**(4): 961–967.

Linde, Y., Buzo, A. and Gray, R. M. (1980). An algorithm for vector quantizer design, *IEEE Transactions on Communications* **28**(1): 84–95.