

# Algoritmo Baseado em Fireworks e LBG para Quantização Vetorial de Imagens

Charles S. Fonseca, Felipe A. B. S. Ferreira e Francisco Madeiro

**Resumo**— A quantização vetorial (QV) é uma técnica de compressão com perdas. O desempenho de sistemas de compressão de sinais baseados em QV depende da qualidade dos dicionários projetados. Este trabalho apresenta uma nova técnica de projeto de dicionários baseada no algoritmo de otimização por fogos de artifício – *Fireworks Algorithm* (FWA). É apresentada uma avaliação comparativa da técnica proposta com o tradicional algoritmo LBG (Linde-Buzo-Gray) e outros algoritmos de projeto de dicionários, no que diz respeito à qualidade de imagens quantizadas, avaliada por meio da relação sinal-ruído de pico. Neste trabalho apresenta-se uma alternativa para aceleração da técnica proposta, obtida por meio da incorporação de um método eficiente de busca do vizinho mais próximo à etapa de particionamento do projeto de dicionário.

**Palavras-Chave**— Compressão de Imagens, Quantização Vetorial, Projeto de Dicionários, Otimização por Fogos de Artifício.

**Abstract**— Vector quantization (VQ) is a lossy compression technique. The performance of VQ based signal compression systems depends on the quality of the designed codebooks. This work presents a new codebook design technique based on the Fireworks Algorithm (FWA). A comparative evaluation of the proposed technique with the traditional LBG (Linde-Buzo-Gray) algorithm and other codebook design algorithms is carried out, with regard to the quality of quantized images, evaluated by means of the peak signal-to-noise ratio. In this work, an alternative is presented for the acceleration of the proposed technique, obtained through the incorporation of an efficient nearest neighbor search method to the partitioning step of the codebook design.

**Keywords**— Image Compression, Vector Quantization, Codebook Design, Fireworks Algorithm.

## I. INTRODUÇÃO

A quantização vetorial (QV) [1], [2], que pode ser vista como uma extensão da quantização escalar em um espaço multidimensional, tem sido utilizada em diversos sistemas de processamento digital de sinais, com um amplo espectro de aplicações, dentre as quais podem ser citadas: compressão de sinais médicos [3], reconhecimento de padrões [4], compressão de voz [5], compressão de imagem [6], esteganografia e marca d'água digital [7], [8].

O desempenho de sistemas de processamento digital de sinais baseados em QV depende da qualidade dos dicionários projetados. Em se tratando de compressão de imagem baseada em QV, por exemplo, a qualidade das imagens reconstruídas depende da qualidade dos dicionários.

Dentre as técnicas de projeto de dicionários, o algoritmo LBG (Linde-Buzo-Gray) [9] destaca-se por sua ampla utilização. Alternativas ao LBG têm sido apresentadas na literatura, como, por exemplo: versões aceleradas do algoritmo LBG, como é o caso do algoritmo proposto por Paliwal e Ramasubramanian [10], denotado no presente trabalho como LBG-a (algoritmo LBG acelerado); versões modificadas do algoritmo *fuzzy k-means*, como é o caso do algoritmo proposto por Mata et al. [11], denotado por MFKM-2 (*Modified Fuzzy K-Means* – família 2); algoritmos que utilizam inteligência de enxames, como por exemplo o método proposto por Severo et al. [12], o qual corresponde a uma técnica de otimização que combina o algoritmo LBG com o algoritmo do vagalume [13], aqui denotado FA-LBGm (*Firefly Algorithm-LBG modified*).

No cenário de quantização vetorial otimizada para canal, algoritmos baseados em inteligência de enxames têm sido utilizados, como os baseados em PSO (*Particle Swarm Optimization*), FA (*Firefly Algorithm*) e FSS (*Fish School Search*), exemplificados respectivamente pelos trabalhos de Leitão et al. [14], Ferreira et al. [15], e Ferreira e Madeiro [16].

Em 2010, Tan e Zhu propuseram um algoritmo de otimização baseado na metáfora de como os fogos de artifício se espalham em seu processo de explosão [17], chamado *Fireworks Algorithm*. Em 2015, Zheng et al. [18] propuseram uma versão melhorada do *Fireworks Algorithm* utilizando operadores de evolução diferencial.

Neste trabalho é apresentada uma nova técnica de projeto de dicionários baseada em inteligência computacional. Precisamente, é apresentado um algoritmo de projeto de dicionários que combina o algoritmo LBG com a versão melhorada do algoritmo *Fireworks*. O cenário de avaliação de desempenho é compressão de imagens baseada em QV. Neste artigo, apresenta-se, ainda, uma alternativa de aceleração do algoritmo supracitado, a qual consiste na introdução de um algoritmo de busca do vizinho mais próximo na etapa de particionamento do algoritmo proposto.

O presente trabalho é organizado da seguinte forma: na Seção II é apresentado o método proposto, na Seção III apresentam-se o arranjo experimental e os parâmetros escolhidos para cada algoritmo utilizado nas simulações, a Seção IV apresenta os resultados e na Seção V são apresentadas as conclusões do trabalho.

## II. MÉTODO PROPOSTO

Algoritmos de enxames são geralmente baseados em múltiplos agentes inteligentes percorrendo simultaneamente um espaço de busca, com um objetivo em comum. A posição

de cada agente no espaço de busca pode sofrer alteração por influência de outros agentes ou de fatores externos aos agentes. Um agente é uma abstração para uma possível solução de um problema e o espaço de busca para o domínio das soluções. Já o objetivo em comum dos agentes é uma abstração para a função que define o problema. O algoritmo *Fireworks* apresenta uma abstração dos agentes como fogos de artifícios (*fireworks*) e faíscas (*sparks*). O método proposto é uma técnica que combina o tradicional algoritmo de clusterização para o projeto de dicionários, LBG, com a técnica de enxame *Fireworks*. O projeto de dicionário é um processo iterativo para encontrar um dicionário representativo de um conjunto de treino específico. No método proposto, chamado FWA-LBG, cada agente inteligente, no caso do *Fireworks*, fogos de artifício, representa um dicionário. Já o espaço de busca, representa o espaço Euclidiano  $k$ -dimensional.

O método proposto foi concebido de forma que as etapas do LBG são executadas para cada agente (dicionário) e a condição de parada é verificada em relação à distorção, na iteração atual, do dicionário que apresenta maior valor da função objetivo. A função objetivo para o projeto de dicionários é o inverso da distorção  $D$ , ou seja,  $1/D$ . Assim, quanto menor a distorção, maior o valor atribuído à solução. Em seguida, no mesmo ciclo, se aplicam os operadores da técnica de enxames *Fireworks*. No final do algoritmo, o dicionário com a menor distorção é retornado como solução para o problema. Uma das etapas do algoritmo LBG tradicional é a etapa de busca pelo vizinho mais próximo (VMP). Na abordagem proposta, a busca pelo VMP é aplicada duas vezes a cada iteração: a primeira no início da iteração e, em seguida, após os operadores do *Fireworks*. Isso garante que esses operadores irão influenciar as novas soluções, bem como manterá a influência dos vetores de treino em cada ciclo. O FWA-LBG é apresentado na sequência de passos a seguir:

1. Gere  $N$  vetores-código aleatórios para cada um dos  $F$  *fireworks*;
2. Para cada um dos  $F$  *fireworks*, faça:
  - 2.1. Para cada vetor de treino busque o vizinho mais próximo;
  - 2.2. Atribua o vetor de treino à região de Voronoi correspondente;
3. Teste a condição de parada (condição do algoritmo LBG), de acordo com o limiar de distorção  $\epsilon$ , para o *firework* que apresenta o valor mais alto da função objetivo;
  - 3.1. Se a condição de parada for satisfeita, vá para o **Passo 12**;
  - 3.2. Caso contrário, continue;
4. Para cada um dos  $F$  *fireworks*, faça:
  - 4.1. Avalie a função objetivo,  $1/D$ ;
  - 4.2. Defina o número de *sparks*  $m$  e amplitude para os *sparks*;
  - 4.3. Gere os *sparks* de explosão;
5. Gere  $\hat{m}$  *sparks* Gaussianas;
6. Avalie a função objetivo para cada *spark*;
7. Selecione, dentre todos os *sparks* e *fireworks*, o que obtém maior valor para a função objetivo;

8. Exceto o *spark* ou *firework* selecionado no passo anterior, selecione  $F - 1$  *sparks* e *fireworks* dentre os restantes;
9. Aplique os operadores de evolução  $\gamma$  e  $c_r$  para os  $F - 1$  selecionados no passo anterior;
10. O agente selecionado no **Passo 7** e os  $F - 1$  agentes do passo anterior formam o novo conjunto de  $F$  *fireworks*;
11. Atualize o centroide de cada *firework*, onde cada vetor-código do dicionário passa a ser o centroide dos vetores de treino os quais representa, ou seja,

$$\bar{y}_{ij} = \frac{\sum_{\vec{x} \in S_j} \vec{x}}{|S_j|}, \quad (1)$$

em que  $\bar{y}_{ij}$  é o  $j$ -ésimo vetor-código do  $i$ -ésimo *firework*,  $\vec{x}$  é vetor do conjunto de treino e  $|S_j|$  é o conjunto de vetores de treino que são representados pelo vetor-código  $\bar{y}_{ij}$ .

12. Retorne o *firework* que obtém maior valor da função objetivo.

Os fatores  $\gamma$  e  $c_r$ , são utilizados nos operadores de evolução do *Fireworks Algorithm*, em que  $\gamma > 0$  é um coeficiente de mutação e  $c_r$  é a probabilidade de cruzamento entre os *fireworks*. Estes operadores foram propostos por Zheng et al. [18] com o objetivo de melhorar a diversidade das soluções e evitar a prematuridade na convergência do algoritmo.

### III. ARRANJO EXPERIMENTAL

Nas simulações foram utilizadas 4 imagens clássicas (Mandrill, Clock, Boat e Tiffany) apresentadas na Figura 1, todas no formato PGM, de tamanho  $256 \times 256$  *pixels*, codificados a 8 bpp (ou seja, 256 níveis de cinza), obtidas da base de imagens do *Signal and Image Processing Institute* (SIPI) da *University of Southern California* (USC) [19]. As condições para o projeto de dicionários foram:

- Dimensão  $K = 16$  (blocos de  $4 \times 4$  *pixels*);
- Tamanho  $N = 32, 64, 128, 256$  e  $512$  vetores-código;
- Quantidade de inicializações - 30 diferentes (compostas por vetores-código escolhidos aleatoriamente a partir das imagens originais) para cada tamanho de dicionário e cada imagem de treino. A etapa de geração dos dicionários aleatórios iniciais nas simulações foi realizada antecipadamente para possibilitar a aplicação dos mesmos dicionários iniciais em cada técnica;
- Para acelerar os algoritmos na obtenção do vizinho mais próximo nos cálculos de distância, foi utilizado o algoritmo *Improved Equal-average Equal-variance Nearest Neighbor Search* (IEENNS) [20] em todas as técnicas;
- Limiar de distorção  $\epsilon = 0,001$ .

O desempenho das técnicas foi avaliado segundo:

- Qualidade das imagens reconstruídas a partir da relação sinal-ruído de pico (*Peak Signal-to-noise Ratio*, PSNR);
- Tempo de execução.

A implementação dos códigos foi realizada na linguagem C++, executados em uma máquina equipada com um processador Intel Core(TM)-i3 de 2,27 GHz.

Para cada algoritmo foram realizadas simulações prévias com variações dos parâmetros para definir os valores que

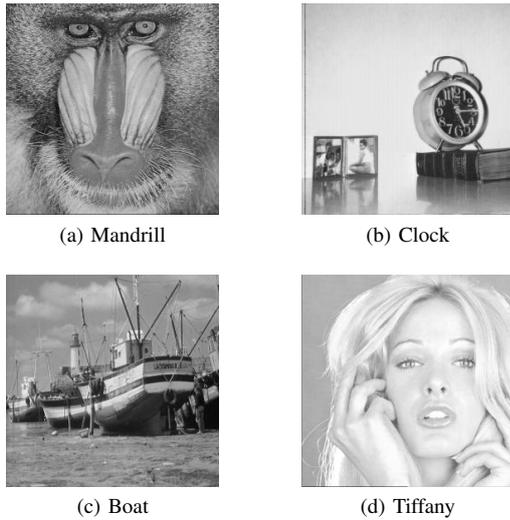


Fig. 1: Imagens utilizadas nas simulações.

possibilitam melhorar o desempenho do projeto de dicionários com relação à qualidade das imagens reconstruídas. Na Tabela I estão definidos os parâmetros usados em cada algoritmo, nas simulações.

#### IV. RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados quanto ao desempenho do quantizador, com relação à qualidade das imagens reconstruídas. Os melhores resultados são destacados em **negrito**, os segundos melhores resultados estão sublinhados, e os terceiros melhores estão duplamente sublinhados.

##### A. Qualidade de reconstrução

A Tabela II apresenta os resultados de PSNR médio das imagens reconstruídas utilizando técnicas variadas de projeto de dicionários aplicados à imagem Mandrill (Figura 1a). O FA-LBGm se destaca entre as demais técnicas para  $N \geq 64$ . Com esse algoritmo é possível atingir até 0,49 dB de ganho, com relação ao LBG (método tradicional), para  $N = 512$ . Em seguida, a técnica proposta, o FWA-LBG, atinge os segundos melhores valores de PSNR para todos os valores de  $N$  considerados, com ganhos de até 0,35 dB (em comparação com o LBG).

Na Tabela III são apresentados os resultados de PSNR médio para a imagem Clock (Figura 1b). Neste caso, o FWA-LBG se destaca para tamanhos de dicionários 32, 64 e 128. Para os tamanhos 256 e 512, o destaque é para o FA-LBGm. Para  $N = 512$  é possível obter ganhos de PSNR, com relação ao LBG, de até 1,76 dB e 1,61 dB, com os algoritmos FA-LBGm e FWA-LBG, respectivamente. O FA-LBGm obtém os segundos melhores resultados para  $N = 32, 64$  e 128, enquanto o FWA-LBG obtém os segundos melhores resultados para  $N = 256$  e 512. O FSS-LBG fica em terceiro lugar, com relação aos valores de PSNR, para  $N = 32$  e 64.

Os resultados de PSNR médio para os métodos de projeto de dicionários aplicados à imagem Boat (Figura 1c) são

TABELA I: Configuração de parâmetros para cada algoritmo.

Técnica	Descrição	Valor
FSS-LBG	População	$P = 10$
	Peso inicial	$W_{\text{ini}} = 500$
	Passo inicial do movimento individual	$s_{\text{indIni}} = 1,0$
	Passo final do movimento individual	$s_{\text{indFin}} = 0,1$
	Passo inicial do movimento volitivo	$s_{\text{volIni}} = 1,0$
	Passo final do movimento volitivo	$s_{\text{volFin}} = 0,1$
	Número de iterações estimadas	$t = 30$
FWA-LBG	População	$F = 10$
	Número de <i>sparks</i>	$m = 80$
	Número de <i>sparks</i> Gaussianas	$\hat{m} = 10$
	Amplitude mínima inicial	$A_{\text{ini}} = 6$
	Amplitude mínima final	$A_{\text{fin}} = 2$
	Amplitude máxima	$\hat{A} = 40$
	Função exponencial para $A$	$\zeta = 0,85$
	Regulador do número de <i>sparks</i>	$a = 0,04$ e $b = 0,8$
FA-LBGm	Operadores evolucionais	$\gamma = 0,4$ e $c_r = 1$
	Fator aleatório	$\alpha = 0,7$
	Coefficiente de absorção de luz	$\gamma = 0,00001$
LBG-a	Fator de atratividade	$\beta = 0,4$
	Fator de escala	$a = 9$

apresentados na Tabela IV. Para  $N = 32$ , os métodos FSS-LBG e FWA-LBG obtêm os melhores resultados dentre as técnicas, com um PSNR de 24,98 dB. Para  $N = 64$ , o destaque é do método proposto, FWA-LBG, com 26,05 dB. Para tamanhos de dicionário 128, 256 e 512, o FA-LBGm se destaca, obtendo um ganho de até 1,41 dB em relação ao LBG. Para  $N = 128, 256$  e 512, o FWA-LBG obtém segundo lugar com um ganho de até 1,15 dB, em relação ao LBG. O MFKM-2 obtém os terceiros melhores resultados para tamanhos de dicionário 128, 256 e 512.

Quanto à imagem Tiffany, os resultados são apresentados na Tabela V. Para esta imagem, em todos os tamanhos de dicionários avaliados (32 até 512), o método FWA-LBG é superior aos demais. É possível obter, por exemplo, um ganho, com relação ao algoritmo LBG, de até 1,47 dB e 0,81 dB para  $N = 512$  e 256, respectivamente. O FA-LBGm obtém os segundos melhores resultados para quase todos os valores de  $N$  avaliados, ficando em terceiro lugar somente para  $N = 32$ . Com o FA-LBGm e  $N = 512$  e 256 é possível obter ganhos de até 1,31 dB e 0,64 dB, respectivamente, com relação ao algoritmo LBG.

Um resultado geral, considerando todas as imagens avaliadas, é apresentado na Tabela VI, em termos do percentual de vezes em que cada técnica foi superior às demais para cada valor de  $N$  considerado neste trabalho. O FA-LBGm, para  $N = 256$  e  $512$ , apresenta superioridade sobre as demais técnicas em 75% das simulações. Para  $N = 128$ , os métodos FA-LBGm e FWA-LBG empatam na superioridade, sobre as demais técnicas, em 50% das simulações. O FWA-LBG, para  $N = 32$  e  $64$ , é superior às demais técnicas em 42,8% e 75% das simulações. O FSS-LBG é o melhor método em 28,6% das simulações realizadas com  $N = 32$ . O LBG e LBG-a empatam com 14,3% de superioridade nas simulações para  $N = 32$ . A superioridade nas simulações com  $N \geq 64$ , é dividida entre o FA-LBGm e FWA-LBG.

TABELA II: Valores médios de PSNR (dB) para a imagem Mandrill.

Técnica	N				
	32	64	128	256	512
LBG	<b>23,19</b>	23,79	24,45	25,21	26,17
LBG-a	<b>23,19</b>	<u>23,82</u>	24,50	25,31	26,36
MFKM-2	23,15	<u>23,81</u>	<u>24,51</u>	<u>25,34</u>	<u>26,40</u>
FSS-LBG	<b>23,19</b>	<u>23,82</u>	24,50	25,28	26,27
FA-LBGm	<u>23,17</u>	<b>23,83</b>	<b>24,56</b>	<b>25,47</b>	<b>26,66</b>
FWA-LBG	23,18	23,82	24,53	25,36	26,52

TABELA III: Valores médios de PSNR (dB) para a imagem Clock.

Técnica	N				
	32	64	128	256	512
LBG	26,29	27,29	28,28	29,48	30,83
LBG-a	26,36	27,38	28,43	29,74	<u>31,28</u>
MFKM-2	26,40	27,47	<u>28,58</u>	<u>29,88</u>	31,27
FSS-LBG	<u>26,46</u>	<u>27,57</u>	28,57	29,79	31,15
FA-LBGm	26,64	27,86	29,19	<b>30,74</b>	<b>32,59</b>
FWA-LBG	<b>26,69</b>	<b>27,93</b>	<b>29,25</b>	<u>30,62</u>	<u>32,44</u>

TABELA IV: Valores médios de PSNR (dB) para a imagem Boat.

Técnica	N				
	32	64	128	256	512
LBG	24,94	25,94	26,92	27,90	29,00
LBG-a	<u>24,96</u>	25,98	27,04	28,16	29,45
MFKM-2	24,94	25,98	<u>27,10</u>	<u>28,28</u>	<u>29,69</u>
FSS-LBG	<b>24,98</b>	<u>26,01</u>	27,01	28,04	29,20
FA-LBGm	<u>24,95</u>	<u>26,03</u>	<b>27,19</b>	<b>28,56</b>	<b>30,41</b>
FWA-LBG	<b>24,98</b>	<b>26,05</b>	<u>27,18</u>	<u>28,50</u>	<u>30,15</u>

TABELA V: Valores médios de PSNR (dB) para a imagem Tiffany.

Técnica	N				
	32	64	128	256	512
LBG	29,43	30,39	31,38	32,44	33,61
LBG-a	29,46	30,47	31,52	32,74	34,11
MFKM-2	29,46	<u>30,50</u>	31,58	<u>32,85</u>	<u>34,19</u>
FSS-LBG	<u>29,55</u>	<u>30,57</u>	<u>31,60</u>	32,67	33,95
FA-LBGm	<u>29,54</u>	<u>30,57</u>	<u>31,70</u>	<u>33,08</u>	<u>34,92</u>
FWA-LBG	<b>29,56</b>	<b>30,66</b>	<b>31,83</b>	<b>33,25</b>	<b>35,08</b>

TABELA VI: Percentual das vezes em que cada técnica foi, em média, superior às demais, considerando todas as imagens avaliadas.

Técnica	N				
	32	64	128	256	512
LBG	14,3%	----	----	----	----
LBG-a	14,3%	----	----	----	----
MFKM-2	----	----	----	----	----
FSS-LBG	28,6%	----	----	----	----
FA-LBGm	----	25,0%	<b>50,0%</b>	<b>75,0%</b>	<b>75,0%</b>
FWA-LBG	<b>42,8%</b>	<b>75,0%</b>	<b>50,0%</b>	25,0%	25,0%

### B. Tempo de execução

A Tabela VII apresenta resultados de desempenho em termos de tempo de execução do projeto de dicionário, considerando os métodos baseados em enxames analisados neste trabalho, FSS-LBG, FA-LBGm e FWA-LBG. Devido aos múltiplos dicionários, a complexidade computacional desse tipo de abordagem tende a ser maior que a apresentada por métodos que utilizam apenas um dicionário. Conforme apresentado nos resultados da subseção anterior, a complexidade computacional das técnicas de enxames tem como contrapartida resultados de PSNR superiores aos obtidos com o tradicional algoritmo LBG, sendo possível obter, em alguns casos, ganhos de mais de 1 dB.

A etapa mais custosa do algoritmo LBG é a de particionamento. Algoritmos eficientes de busca do vizinho mais próximo podem ser utilizados para obter resultados de busca similares ou iguais aos obtidos por busca exaustiva (força bruta), com um menor tempo de execução. Para reduzir o tempo do projeto de dicionário das técnicas com enxames analisadas neste trabalho, avaliamos seu desempenho aplicando a técnica eficiente de busca do vizinho mais próximo denominada IEENNS. O FSS-LBG obtém menores tempos de execução para  $64 \leq N \leq 512$ . O FA-LBGm é executado em um menor tempo, para  $N = 32$ , enquanto o FWA-LBG é executado, em média, mais lentamente que as demais para  $N \leq 128$ .

TABELA VII: Tempo (s) médio de execução do projeto de dicionário para todas as imagens.

Técnica	N				
	32	64	128	256	512
FSS-LBG	2,10	<b>3,44</b>	<b>5,52</b>	<b>8,84</b>	<b>14,19</b>
FA-LBGm	<b>2,04</b>	3,74	7,04	13,40	25,54
FWA-LBG	3,15	4,89	7,68	12,87	23,01

## V. CONCLUSÕES

A qualidade do projeto de dicionários afeta diretamente o desempenho de sistemas de processamento de sinais baseados em Quantização Vetorial (QV). Em particular, em sistemas de compressão de imagens baseados em QV, a qualidade do dicionário projetado é traduzida em qualidade das imagens reconstruídas.

Neste trabalho, foi introduzida uma técnica de computação bio-inspirada, mais precisamente, de inteligência de enxames, para ser associada ao algoritmo LBG, com o propósito de projeto de dicionário: o *Fireworks Algorithm* (FWA). O FWA foi acoplado aos ciclos do algoritmo LBG, sendo denominado FWA-LBG. A técnica de computação bio-inspirada acoplada ao LBG levou a melhores desempenhos em termos de PSNR para imagens reconstruídas em dicionários com tamanhos  $N = 32$  e  $64$ , considerando o conjunto das 4 imagens utilizadas nas simulações. Para  $N = 128$ , houve um empate entre o FWA-LBG e o FA-LBGm, cada um com 50% de superioridade, em termos de PSNR, nas simulações, e para  $N = 256$  e  $512$ , o FA-LBGm apresentou uma superioridade sobre as demais técnicas consideradas.

Para reduzir a complexidade computacional do projeto de dicionário das técnicas baseadas em enxames, uma técnica eficiente de busca do vizinho mais próximo, IEENNS, usada originalmente na fase de codificação da QV, foi aplicada ao projeto dos dicionários. Os resultados das simulações mostram que, dentre as técnicas de enxame consideradas, o algoritmo FSS-LBG é o de menor tempo médio de execução. Como trabalhos futuros, pode-se considerar a aplicação de novas técnicas de busca do VMP na etapa de particionamento do FWA-LBG e avaliar a qualidade das imagens reconstruídas utilizando SSIM (*Structural Similarity Index*).

## AGRADECIMENTOS

Os autores gostariam de agradecer ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e FACEPE (Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco) pelo suporte financeiro a este trabalho.

## REFERÊNCIAS

- [1] R. M. Gray, "Vector quantization," IEEE ASSP Magazine, pp. 4–29, 1984.
- [2] A. Gersho e R. M. Gray, Vector Quantization and Signal Compression. Massachusetts, USA: Kluwer Academic Publishers, Boston, MA, 1992.
- [3] H. Tang, J. Zhang, J. Sun, T. Qiu e Y. Park, "Phonocardiogram signal compression using sound repetition and vector quantization," Computers in Biology and Medicine, vol. 71, n. 1, pp. 24–34, 2016.
- [4] B. Ramesh, C. Xiang e T. H. Lee, "Multiple object cues for high performance vector quantization," Pattern Recognition, vol. 67, n. 1, pp. 380–395, 2017.
- [5] K. K. Patel e M. L. Fowler, "Vector quantizer design for speech signal compression," in 7th IEEE International Conference on Cloud Computing, Data Science & Engineering-Confluence, pp. 744–749, 2017.
- [6] M. U. A. Ayoobkhan, E. Chikkannan e K. Ramakrishnan, "Lossy image compression based on prediction error and vector quantisation", EURASIP Journal on Image and Video Processing, vol. 2017, n. 1, pp. 35–47, 2017.
- [7] C.-T. Huang, D.-E. Sun e S.-J. Wang, "A security-based steganographic scheme in vector quantization coding through correlated neighboring blocks," Multimedia Tools and Applications, vol. 2018, n. 1, pp. 1–21, 2018.
- [8] A. Tiwari, M. Sharma e R. K. Tamrakar, "Watermarking based image authentication and tamper detection algorithm using vector quantization approach," AEU-International Journal of Electronics and Communications, vol. 78, n. 1, pp. 114–123, 2017.
- [9] Y. Linde, A. Buzo e R. Gray, "An algorithm for vector quantizer design," IEEE Transactions on Communications, vol. 28, n. 1, pp. 84–95, 1980.
- [10] K. K. Paliwal e V. Ramasubramanian, "Comments on modified k-means algorithm for vector quantizer design," IEEE Transactions on Image Processing, vol. 9, n. 11, pp. 1964–1967, 2000.
- [11] E. Mata, S. Bandeira, P. M. Neto, W. T. A. Lopes, e F. Madeiro, "Accelerating families of fuzzy k-means algorithms for vector quantization codebook design," Sensors, vol. 16, n. 11, pp. 1963–1981, 2016.
- [12] V. Severo, H. Leitão, J. Lima, W. Lopes, e F. Madeiro, "Modified firefly algorithm applied to image vector quantisation codebook design," International Journal of Innovative Computing and Applications, vol. 7, n. 4, pp. 202–213, 2016.
- [13] X.-S. Yang, Nature-Inspired Metaheuristic Algorithms, 2nd ed. University of Cambridge, United Kingdom: Luniver Press, 2010.
- [14] H. A. S. Leitão, W. T. A. Lopes e F. Madeiro, "PSO algorithm applied to codebook design for channel-optimized vector quantization," IEEE Latin America Transactions, vol. 13, n. 4, pp. 961–967, 2015.
- [15] F. A. B. S. Ferreira, H. A. S. Leitão, W. T. A. Lopes e F. Madeiro, "Hybrid firefly-Linde-Buzo-Gray algorithm for channel-optimized vector quantization codebook design," Integrated Computer-Aided Engineering, vol. 24, n. 3, pp. 297–314, 2017.
- [16] F. A. B. S. Ferreira e F. Madeiro, "A fish school search based algorithm for image channel-optimized vector quantization," in IEEE International Conference on Systems, Man, and Cybernetics (SMC), pp. 1–6, 2016.
- [17] Y. Tan e Y. Zhu, "Fireworks algorithm for optimization," Advances in Swarm Intelligence. Springer Berlin Heidelberg, pp. 355–364, 2010.
- [18] Y.-J. Zheng, X.-L. Xu, H.-F. Ling, e S.-Y. Chen, "A hybrid fireworks optimization method with differential evolution operators," Neurocomputing, vol. 148, n. 1, pp. 75–82, 2015.
- [19] USC, "SIPI Image Database - Misc," 2018. [Online]. Disponível em: <http://sipi.usc.edu/database/database.php>.
- [20] S. Baek, B. Jeon, e K.-M. Sung, "A fast encoding algorithm for vector quantization," IEEE Signal Processing Letters, vol. 4, n. 12, pp. 325–327, 1997.