

# Inserção de Marca D'água Digital em Imagens Digitais Utilizando Quantização Vetorial com Particionamento do Dicionário por PSO

Marcos Canejo, Jair Galvão e Francisco Madeiro  
Universidade de Pernambuco

Recife, Pernambuco 30332-0250

Email: marcoscanejo@gmail.com, jair.galvao@upe.br, madeiro@poli.br

**Resumo**—Segurança da informação envolvendo imagens digitais é uma área de estudo com problemas relevantes, dentre as quais podem ser citados esteganografia, cifragem de imagens e marca d'água digital. A quantização vetorial, quando aplicada à marca d'água, envolve geralmente o particionamento de dicionário. No presente trabalho, avalia-se o desempenho do algoritmo PSO (*particle swarm optimization*) nesse particionamento. Mostra-se que o PSO leva a marcas d'água mais robustas quando comparadas às marcas obtidas com o uso de algoritmo genético.

## I. INTRODUÇÃO

Devido ao crescimento do uso da Internet, a criação, replicação e transmissão de conteúdo digital se tornou bastante comum, principalmente devido ao barateamento dos dispositivos de armazenamento e uma maior disponibilidade de largura de banda [1].

O desenvolvimento de soluções para proteção de direitos autorais e identificação de propriedades tem se tornado bastante importante [2]. Marca d'água é uma técnica que pode ser usada para fins de autenticação de dados e proteção de direitos autorais através da inserção de um código identificador na imagem, vídeo ou áudio, que não modifica significativamente seu conteúdo original.

Há três requisitos principais no âmbito da marca d'água. Eles são: fidelidade, robustez e carga (Figura 1) [3].

A fidelidade ou transparência é a similaridade entre o objeto original e o marcado. A marca d'água não deve afetar a qualidade do objeto marcado após sua marcação.

Robustez é a capacidade de extrair a marca d'água após certas operações de processamento de sinal. A marca d'água deve ser robusta contra manipulações.

A carga diz respeito à quantidade de bits que podem ser ocultos. Assim, quanto maior for o tamanho do objeto de cobertura, maior será a sua capacidade de armazenar bits que compõe o código identificador.

A marca d'água pode ser classificada de acordo com sua robustez e sua visibilidade. De acordo com a Figura 2, a marca d'água pode ser frágil, semi-frágil ou robusta e visível ou invisível. Cada tipo de marca d'água possui as suas características e deve ser usada de acordo com o propósito. As visíveis são pouco usadas devido a sua sensibilidade a ataques, pois sabendo sua localização, um ataque pode concentrar




Figura 1. Relação inversa entre as características de marca d'água.

o esforço na região. As invisíveis são as mais utilizadas e consistem na alteração de bits ou coeficientes espectrais do objeto de cobertura. A marca d'água frágil deve ser facilmente destruída caso o objeto marcado seja manipulado. Este método serve para a proteção e verificação do conteúdo original. Uma marca d'água robusta deve resistir a vários tipos de ataques. Uma marca semi-frágil deve ser tolerante a alguns tipos de manipulações [3].




Figura 2. Classificação de marca d'água.

Este trabalho contempla um método de marca d'água baseado em Quantização Vetorial (QV) aplicado a imagens digitais utilizando o algoritmo *Genetic Codebook Partition* (GCP) proposto em [4]. No presente artigo avalia-se o *Particle swarm optimization* (PSO) [5, 6] como alternativa ao Algoritmo Genético (AG) na etapa de particionamento do dicionário para aumentar sua qualidade. Os resultados mostram um ganho de 0,11 dB em termos de relação sinal-ruído de pico na imagem Lena ao se usar PSO em substituição a AG. Além disso, esse ganho de qualidade não é obtido a custas de comprometimento da robustez da marca aos ataques.

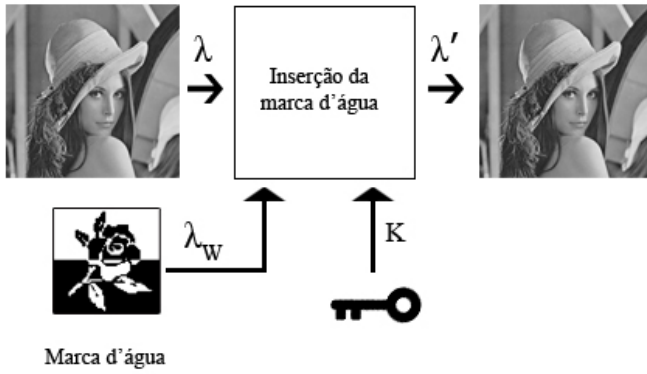


Figura 3. Sistema de inserção de marca d'água digital.

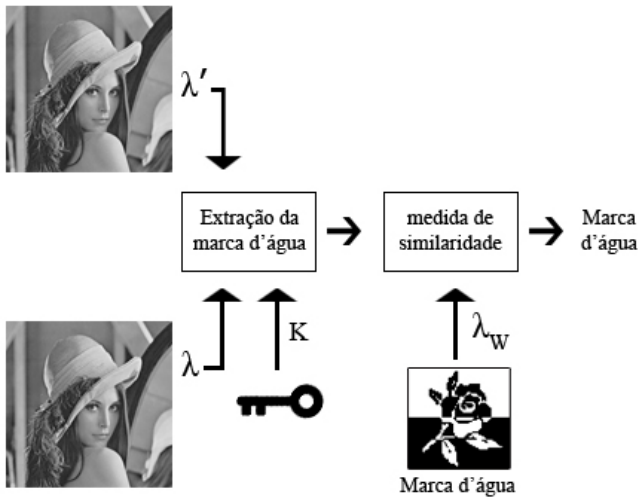


Figura 4. Sistema de extração de marca d'água digital.

## II. MARCA D'ÁGUA DIGITAL

A técnica de marca d'água digital [3] consiste na inserção de um código identificador numa imagem, vídeo ou áudio, que deve ser apenas acessível a pessoas autorizadas com o objetivo de identificar o autor ou o dono dos direitos autorias. No contexto de imagens, o código identificador pode ser representado por uma sequência de números, imagem ou uma logomarca da empresa.

Se uma imagem original  $\lambda$  e uma marca d'água  $\lambda_W$  são dadas, a imagem marcada  $\lambda'$  é representada pela seguinte expressão:  $\lambda' = \lambda + \alpha\lambda_W$  [3].

A imagem original  $\lambda$  e a marca d'água  $\lambda_W$  são as entradas do sistema,  $\alpha$  é um fator de escala e uma chave  $K$  pública ou privada pode ser usada para guiar o processo. A saída do sistema será a imagem marcada  $\lambda'$  como mostra a Figura 3.

Após sua inserção, a marca d'água pode ser extraída de duas formas ou mais formas, utilizando a imagem original para comparar e descobrir a marca d'água (extração não-cego) ou através da utilização de alguma medida de correlação (extração cego), ou seja, não há a necessidade de utilizar a imagem original. A Figura 4 ilustra este processo.

No método não-cego, a marca d'água incorporada pode ser extraída subtraindo o sinal original pela imagem marcada e então dividida pelo fator de escala  $\alpha$ . Precisamente,  $\lambda_W = (\lambda' - \lambda)/\alpha$ .

## III. QUANTIZAÇÃO VETORIAL

A quantização é uma técnica de compressão de sinais que pode ser dividida em duas classes, escalar e vetorial. A quantização escalar (QE) considera amostras individuais, ao passo que a quantização vetorial (QV) considera blocos de amostras. A QV consiste num mapeamento de um vetor  $x$  de um espaço euclidiano  $K$ -dimensional em um vetor pertencente a um subconjunto finito  $W$  de  $\mathbb{R}^K$  [7, 8], que é chamado de dicionário, ou seja,  $Q : \mathbb{R}^K \rightarrow W$ .

O dicionário  $W = \{w_i; i = 1, 2, \dots, N\}$  é um subconjunto finito onde cada elemento é denominado vetor-código. O número de componentes ou amostras de cada vetor é denominado dimensão ( $K$ ). O tamanho de dicionário é a quantidade de vetores-código, denotado por  $N$ .

Como métricas de avaliação do desempenho da QV aplicado a imagens digitais, utiliza-se o valor de Relação Sinal-Ruído de Pico (Peak Signal to Noise Ratio), definida por  $PSNR = 10 \log_{10}(\frac{V_p^2}{MSE})$  onde  $V_p$  representa o valor de pico da amplitude do sinal de entrada e o  $MSE$  o erro quadrático médio. Sejam  $I$  e  $I_r$  imagens monocromáticas original e processada com largura e altura  $m \times n$ , o  $MSE$  é definido por  $MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [I(i, j) - I_r(i, j)]^2$  em que  $I(i, j)$  e  $I_r(i, j)$  são os valores de pixels na posição  $(i, j)$  de  $I$  e  $I_r$ .

A QV tem seu desempenho ligado diretamente ao dicionário projetado [9, 10]. Então, um bom dicionário é extremamente importante para que o sinal reconstruído seja o mais parecido ao original. O algoritmo proposto por Linde *et al.* em [11] é o algoritmo mais popular para o projeto de dicionários.

## IV. MARCA D'ÁGUA BASEADA EM QUANTIZAÇÃO VETORIAL

O método de marca d'água baseada em QV [4] consiste na divisão do dicionário  $W$  em dois sub-dicionários  $G_0$  e  $G_1$  utilizando uma chave  $C$ , onde  $C = \{c_1, c_2, \dots, c_i \mid c_i \in \{0, 1\}, 1 \leq i \leq N\}$ . Assim, os sub-dicionários  $G_0$  e  $G_1$  irão esconder os bits 0 e 1, respectivamente. O algoritmo 1 mostra a sequência de passos proposta por Wang *et al.*

Os passos para a extração dos bits escondidos da marca d'água são descritos no Algoritmo 2.

---

**Algoritmo 1:** Processo de inserção da marca d'água

---

1. Dividir o dicionário  $W$  em dois sub-dicionários  $G_0$  e  $G_1$  utilizando a chave  $C$ .
  2. Transformar a imagem de cobertura  $X$  em blocos de tamanho  $K$  pixels.
  3. Para o vetor de entrada  $x_i$  e o bit da marca d'água a ser inserido  $y_i \in \{0, 1\}$ , definir o vetor-código no sub-dicionário  $G_{y_i}$  que possui a menor distância euclidiana.
  4. Obtenha o vetor marcado  $x'_i$ .
  5. Repetir os passos 3-4 até que todos os bits da marca d'água sejam inseridos.
  6. Reconstruir a imagem quantizada  $X'$ , que também é a imagem marcada.
- 

---

**Algoritmo 2:** Processo de extração da marca d'água

---

1. Decomponha a imagem marcada  $X'$  em blocos não sobrepostos de tamanho  $K$  pixels.
  2. Para cada vetor de entrada  $x'_i$ , obtenha o vetor-código com a menor distância euclidiana no dicionário  $W$ .
  3. Seja  $w_j$  o vetor-código obtido, o bit escondido da marca d'água será o valor contido no índice  $j$  da chave.
  4. Repita os passos 2-3 para extrair todos os bits da marca d'água.
- 

## V. PARTICIONAMENTO UTILIZANDO PSO

O *particle swarm optimization* (PSO) é um método de inteligência computacional baseado no comportamento social do bando de pássaros. Diferentemente de outras técnicas [12, 13], o PSO se baseia na comunicação coletiva entre os indivíduos em busca da solução através de uma orientação global e outra local [6].

O PSO inicializa uma população de soluções (partículas) de forma aleatória que possuem coordenadas (posição e velocidade) associadas a um espaço de busca. As partículas “voam” neste espaço de busca influenciadas pela melhor posição conhecida da partícula (PBEST), melhor posição conhecida do bando (GBEST) e sua velocidade atual.

---

**Algoritmo 3:** Pseudocódigo do particionamento do dicionário do PSO

---

1. Geração das chaves  $\{C_1, C_2, \dots, C_S\}$  com valores aleatórios, onde  $C = c_1, c_2, \dots, c_i \mid c_i \in \{0, 1\}, 1 \leq i \leq N$ .
  2. Inserir a marca d'água  $\lambda_W$  na imagem de cobertura  $X$  utilizando o método descrito na seção 4.
  3. Calcular o desempenho da chave por meio do valor de PSNR entre a imagem de cobertura e a marcada  $X'$ .
  4. Atualizar os valores PBEST e GBEST.
  5. Atualizar a velocidade e posição da partícula.
  6. Repetir os passos 2 ao 5 para todas as partículas até que o limite de iterações seja atingido.
- 

Seja  $p_i(t)$  a posição da partícula  $i$  no espaço de busca no tempo  $t$ , a nova posição da partícula será a soma da velocidade

$v_i(t)$  e a posição atual, i.e.  $p_i(t+1) = p_i(t) + v_i(t)$ . O processo de otimização é conduzido pelo vetor velocidade definido por  $v_{ij}(t+1) = IW \times v_{ij} + fator_1 \times r_{1j}(t) \times [PBEST - p_{ij}(t)] + fator_2 \times r_{2j}(t) \times [GBEST - p_{ij}(t)]$  onde  $v_{ij}(t)$  representa a velocidade da partícula  $i$  na dimensão  $j$ ,  $fator_1$  e  $fator_2$  constantes positivas de aceleração usadas para dimensionar a contribuição dos fatores cognitivos e social respectivamente.  $r_{1j}(t)$  e  $r_{2j}(t)$  são valores aleatórios entre 0 e 1 obtidos numa distribuição uniforme.  $IW$  é uma constante positiva proposta em [14] para equilibrar a busca local e global.

Os valores das constantes do PSO utilizadas no particionamento foram:  $IW = 1$ , fator cognitivo e social igual a 2, escolhidas através de testes com os valores comumente utilizados na literatura. A função *fitness* utilizada para avaliar a chave foi a Relação Sinal Ruído de pico (PSNR) descrita na seção 3. Como o problema apresentado neste artigo possui um espaço de busca binário, é necessário fazer a modificação proposta em [15] na atualização da posição da partícula. O algoritmo 3 apresenta os passos para o particionamento utilizando o PSO.

## VI. RESULTADOS

Os algoritmos AG e PSO foram usados na etapa de particionamento do dicionário aplicado a técnica de inserção da marca d'água utilizando QV.

Os parâmetros adotados para o algoritmo AG foram: tamanho da população 10 indivíduos; 1000 iterações; taxa de seleção da população igual a 100%; taxa de cruzamento igual a 50%; taxa de mutação igual 0,1%; 15 pontos de cruzamento e método de seleção por roleta [13]. Os dicionários foram projetados pelo algoritmo LBG com limiar de distorção igual a  $10^{-4}$ , com tamanho  $N = 256$  com dimensão  $K = 16$  (correspondente a blocos  $4 \times 4$ ).

As simulações foram realizadas usando quatro imagens de cobertura  $512 \times 512$  pixels, Lena (a), Boat (b), Peppers (c) e Mandrill (d) como mostra a Figura 5, com 256 escalas de cinzas. A imagem Lena quantizada obteve o valor de PSNR de 33,65 dB sem a inserção da marca d'água, a imagem Boat 29,13 dB, 24,18 dB para imagem Mandrill e 32,01 dB para imagem Peppers. A imagem Rose de  $128 \times 128$  pixels com 1 bpp foi usada como marca d'água.

A robustez da marca d'água foi mensurada avaliando o valor de correlação de bit (*bit-correct rate* – BCR) dado por  $BCR(Y, Y') = (1 - \frac{\sum_i^{L_w} |y_i - y'_i|}{L_w}) \times 100\%$  onde  $L_w$  representa o tamanho da marca d'água,  $y_i$  e  $y'_i$  o  $i$ -ésimo bit de  $Y$  e  $Y'$ , respectivamente.

As Tabelas I e II mostram os resultados de BPSNR e APSNR do AG e PSO para imagem Lena e Boat respectivamente, onde APSNR representa o valor médio de PSNR e BPSNR representa o melhor valor de PSNR entre os experimentos. A metodologia do trabalho consistiu na mesma utilizada em [4], ou seja, o número de iterações para ambos os algoritmos foi limitada em 1000 para 30 execuções e com número de chamadas *fitness* livre.

De acordo com a Tabela I, podemos observar que o PSO obteve uma superioridade sobre o AG, obtendo uma diferença de 0,11 dB no valor médio de PSNR. Nas Figuras 7 e 8, que




Figura 5. As imagens de cobertura (a) Lena, (b) Boat, (c) Peppers e (d) Mandrill utilizadas nos experimentos.



Figura 6. Imagem Rose utilizada como marca d'água.

representam o experimento com maior resultado final de PSNR obtido entre os 30 executados, nota-se que o PSO atingiu o valor máximo no intervalo entre 600 e 700 no número de iterações, considerando a imagem Lena.

Na Tabela II, os algoritmos atingiram valores semelhantes de PSNR para a imagem Boat, com uma diferença mínima de 0,05 dB tanto para o melhor valor de PSNR como em seu valor médio. As Figuras 9 e 10 apresentam o maior resultado final de PSNR obtidos pelo AG.

Tabela I. BPSNR E APSNR OBTIDOS DA IMAGEM LENA.

Método	AG	PSO	Aleatório
BPSNR	32,19 dB	32,27 dB	31,53 dB
APSNR	32,13 dB	32,24 dB	31,29 dB

Tabela II. BPSNR E APSNR OBTIDOS DA IMAGEM BOAT.

Método	AG	PSO	Aleatório
BPSNR	27,97 dB	28,02 dB	27,53 dB
APSNR	27,95 dB	28,00 dB	27,35 dB

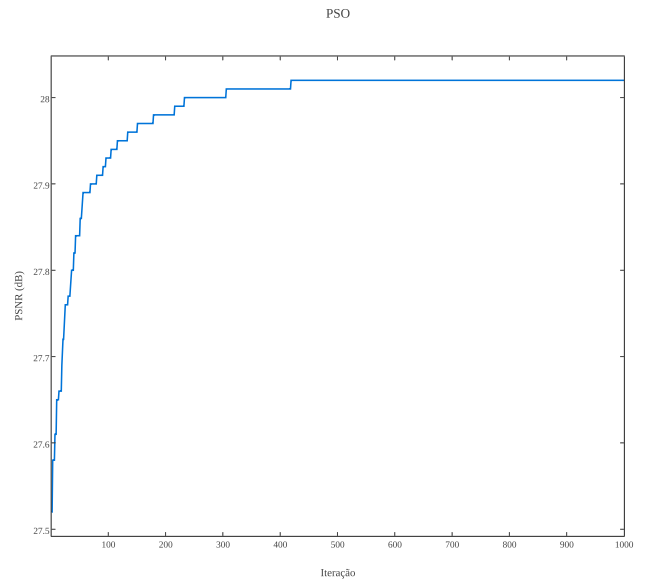


Figura 7. Valores de PSNR durante 1000 iterações do melhor resultado usando o PSO para imagem Boat.

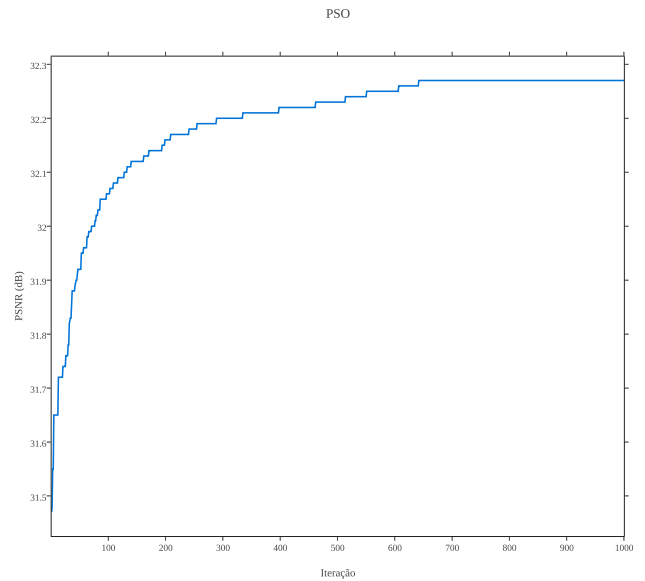


Figura 8. Valores de PSNR durante 1000 iterações do melhor resultado usando o PSO para imagem Lena.

Tabela III. BPSNR E APSNR OBTIDOS DA IMAGEM PEPPERS.

Método	AG	PSO	Aleatório
BPSNR	30,50 dB	30,54 dB	29,90 dB
APSNR	30,45 dB	30,52 dB	29,70 dB

O PSO foi o que levou aos melhores resultados de APSNR e BPSNR para as imagens Peppers e Mandrill, conforme se observa nas tabelas III e IV, respectivamente. Na Tabela III, ele conseguiu obter uma diferença de 0,64 dB no melhor resultado de PSNR em comparação com o particionamento aleatório e

0,36 dB para a imagem Mandrill. Em relação ao AG, o PSO também conseguiu melhores resultados em ambas as métricas, porém com uma pequena diferença.

Tabela IV. BPSNR E APSNR OBTIDOS DA IMAGEM MANDRILL.

Método	AG	PSO	Aleatório
BPSNR	23,49 dB	23,53 dB	23,17 dB
APSNR	23,48 dB	23,51 dB	23,06 dB

As imagens marcadas resultantes dos melhores resultados do particionamento do dicionário realizado pelo PSO e AG, sofreram os ataques de compressão JPEG e logo em seguida tiveram a marca d'água extraída e avaliadas pelo valor de BCR. Na compressão JPEG, quanto menor for o fator de qualidade, mais a marca será afetada e consecutivamente menos parecida com a original. Os valores de BCR para a imagem Lena são apresentados na Tabela V e os da imagem Boat na Tabela VI.

Tabela V. VALORES DE BCR DA MARCA D'ÁGUA EXTRAÍDA DA IMAGEM LENA APÓS ATAQUES.

	BCR (%)		
	AG	PSO	Aleatório
JPEG, QF=25%	79,30%	76,10%	82,92%
JPEG, QF=40%	89,63%	89,70%	91,94%
JPEG, QF=60%	96,63%	97,10%	97,07%
JPEG, QF=80%	99,66%	99,70%	99,76%

Tabela VI. VALORES DE BCR DA MARCA D'ÁGUA EXTRAÍDA DA IMAGEM BOAT APÓS ATAQUES.

	BCR (%)		
	AG	PSO	Aleatório
JPEG, QF=25%	81,12%	82,55%	84,36%
JPEG, QF=40%	88,58%	89,53%	91,46%
JPEG, QF=60%	93,81%	93,86%	95,00%
JPEG, QF=80%	97,82%	97,57%	97,35%

Podemos observar nas Tabelas V e VI, através dos valores de BCR, que para a compressão JPEG com fator de qualidade 80% e 60%, a marca d'água pôde ser reconhecida mesmo após a imagem marcada ter sofrido os ataques. Nas compressões JPEG o PSO se demonstrou superior ou bastante próximo ao AG para as duas imagens testadas. A Figura 11 apresenta as marcas d'água extraídas da imagem de marcada Lena após sofrer os ataques de compressão JPEG.

Tabela VII. VALORES DE BCR DA MARCA D'ÁGUA EXTRAÍDA DA IMAGEM PEPPERS APÓS ATAQUES.

	BCR (%)		
	AG	PSO	Aleatório
JPEG, QF=25%	77,25%	78,36%	80,61%
JPEG, QF=40%	90,96%	91,13%	91,88%
JPEG, QF=60%	96,79%	97,27%	97,50%
JPEG, QF=80%	99,79%	99,74%	99,83%

Tabela VIII. VALORES DE BCR DA MARCA D'ÁGUA EXTRAÍDA DA IMAGEM MANDRILL APÓS ATAQUES.

	BCR (%)		
	AG	PSO	Aleatório
JPEG, QF=25%	90,67%	91,66%	90,73%
JPEG, QF=40%	97,53%	97,90%	97,48%
JPEG, QF=60%	99,56%	99,68%	99,69%
JPEG, QF=80%	100%	100%	100%

Observando as Tabelas VII e VIII podemos dizer que o PSO também conseguiu gerar imagens marcadas mais robustas para as imagens Peppers e Mandrill. Nos ataques JPEG QF 25%, 40% e 60%, o valor de BCR foi maior ou quase igual aos do AG, o que indica que as marcações via particionamento PSO apresenta uma maior robustez aos ataques de compressão JPEG que a marcação via particionamento AG.




Figura 9. Valores de PSNR durante 1000 iterações do melhor resultado usando o AG para imagem Boat.

Tabela IX. TESTE DE WILCOXON PARA OS ALGORITMOS PSO, AG E ALEATÓRIO.

Imagem	Algoritmo	PSO
Lena	AG	1,30e-11
	Aleatório	1,36e-11
Boat	AG	1,09e-11
	Aleatório	1,29e-11
Peppers	AG	1,55e-11
	Aleatório	1,23e-11
Mandrill	AG	6,58e-12
	Aleatório	8,31e-12

Realizando o teste de Wilcoxon com 5% de significância (95% de confiabilidade) entre o PSO, AG e aleatório, podemos verificar que as amostras são consideradas diferentes, pois o  $p - value$  apresentou-se bem menor que 0,05%, como podemos ver na tabela IX. Assim, o PSO apresenta desempenho superior em relação aos outros algoritmos.




Figura 10. Valores de PSNR durante 1000 iterações do melhor resultado usando o AG para imagem Lena.




Figura 11. Marcas D'água extraídas da imagem Lena após o ataque (a) QF=25%, (b) QF=40%, (c) QF=60%, (d) QF=80%.

## VII. CONCLUSÃO

A técnica proposta por Wang e Jaine em [4], abordada neste trabalho, utiliza do *Genetic Codebook Partition* (GCP) na busca da melhor configuração da chave utilizada para particionar o dicionário em dois sub-dicionários.

No presente trabalho, o algoritmo PSO foi avaliado como alternativa ao algoritmo genético no problema de partici-

onamento de dicionários para marca d'água baseada em quantização vetorial. Observou-se uma superioridade do PSO sobre o algoritmo genético no que diz respeito à robustez da marca, por meio do BCR (taxa de correlação de bit), e PSNR (relação sinal-ruído de pico) da imagem reconstruída.

Como trabalhos futuros, pretende-se avaliar outras técnicas de inteligência computacional para melhorar o particionamento do dicionário (como por exemplo o algoritmo do vagalume [16] e o *Honey-Bees Mating Optimization* [17]), e testar a robustez da marca d'água através de outros ataques.

## VIII. AGRADECIMENTOS

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pelo apoio financeiro.

## REFERÊNCIAS

- [1] S. Prabhishkek, R S Chadha, "A Survey of Digital Watermarking Techniques Applications and Attacks.", *International Journal of Engineering and Innovative Technology (IJEIT)*, vol. 2, Issue 9, March 2013.
- [2] I. P. Christine, Edward J. Delp, "Digital Watermarking: Algorithms and Applications.", *IEEE Signal processing Magazine*, July 2001.
- [3] H. Ensaf, A. B. Mohamed, "Digital Watermarking Techniques, Applications and Attacks Applied to Digital Media: A Survey.", *International Journal of Engineering Research & Technology (IJERT)*, ISSN: 2278-0118, vol. 1, Issue 7, September-2012
- [4] F.-H. Wang, L. C. Jain, e J.-S. Pan, "VQ-based Watermarking Scheme with Genetic Codebook Partition.", *Journal of Network and Computer Applications*, vol. 30, no 1, pp. 4–23, Jan. 2007.
- [5] A. P. Engelbrecht, "Fundamentals of Computational Swarm Intelligence.", John Wiley & Sons, Inc.(2005)
- [6] J. Kennedy e R. Eberhart, "Particle Swarm Optimization.", *Proc. IEEE International Conf. on Neural Networks* (Perth, Australia), IEEE Service Center, Piscataway, NJ, 1995 (in press).
- [7] R. M. Gray, "Vector Quantization.", *IEEE ASSP Magazine*, no. 1, pp. 4–29, 1984.
- [8] A. Gersho e R. M. Gray, "Vector Quantization and Signal Compression.", Boston, MA, Kluwer Academic Publishers, 1992.
- [9] V. Severo, H. A. S. Leitão, J. B. Lima, F. Madeiro, "Algoritmo PSO Modificado Aplicado ao Projeto de Quantizadores Vetoriais", *Congresso Brasileiro de Inteligência Computacional*, Curitiba, PR, Brasil, 2015.
- [10] V. Severo, H. A. S. Leitão, J. B. Lima, W. T. A. Lopes, F. Madeiro, "Algoritmo FA Modificado Aplicado ao Projeto de Quantizadores Vetoriais", *Congresso Brasileiro de Inteligência Computacional*, Curitiba, PR, Brasil, 2015.
- [11] Y. Linde, A. Buzo, R.M. Gray, "An Algorithm for Vector Quantizer Design.", *IEEE Transactions on Communications*, vol. 28, no. 1, p. 84–95, 1980.
- [12] L. J. Fogel, (1994), "Evolutionary Programming in Perspective: the Top-down View, In Computational Intelligence: Imitating Life."J.M. Zurada, R J. Marks Q and C. J. Robinson, E &. EEE Press, Pisमतaway, NJ.
- [13] D. E. Goldberg (1989), "Genetic Algorithms in Search Optimization, and Machine Learning."Reading MA: Addison-Welsey .
- [14] Y. Shi and R. Eberhart, "A Modified Particle Swarm Optimizer.", *Proceedings of IEEE International Conference on Evolutionary Computation*. pp. 69–73.
- [15] J. Kennedy, R. C. Eberhart, "A Discrete Binary Version of the Particle Swarm Optimization." *Proc. Of the conference on Systems, Man, and Cybernetics SMC97*, pp. 4104-4109, 1997.
- [16] M. -H. Horng, "Vector quantization using the firefly algorithm for image compression.", *Expert Systems with Applications*, vol 39, Issue 1, pp. 1078–1091, January 2012.

- [17] M.-H. Horng, T.-W. Jiang, "Image vector quantization algorithm via honey bee mating optimization", *Expert Systems with Applications*, vol. 38, Issue 3, pp. 1382–1392, March 2011.