

Um Esquema de Marca d'água Robusto em Imagens Baseado em Aprendizagem Profunda

Andy M. Ramos, Cecilio Pimentel, and Daniel P. B. Chaves

Resumo— Neste trabalho, propomos um esquema de marca d'água em imagens baseado em aprendizado profundo, no qual as camadas de inserção e extração são treinadas de forma iterativa para garantir alta robustez contra ataques. A camada de inserção adota uma estrutura paralela com redes neurais convolucionais inspiradas na rede *Inception*, enquanto a camada de extração emprega convoluções deformáveis. Estas permitem a extração adaptativa de características da imagem ao ajustar os filtros convolucionais de acordo com o conteúdo da imagem. Os bits inseridos na imagem correspondem aos bits de paridade de um código corretor de erros, contribuindo para a integridade da informação. O desempenho do sistema é avaliado sob diversos ataques comuns na literatura e os resultados demonstram que a abordagem proposta é eficaz e competitiva em relação a métodos recentes.

Palavras-Chave— marca d'água robusta, códigos corretores de erros, imagens, redes neurais convolucionais.

Abstract— In this work, we propose a deep learning-based image watermarking scheme, in which the embedding and extraction layers are trained iteratively to ensure high robustness against attacks. The embedding layer adopts a parallel structure with convolutional neural networks inspired by the *Inception* Net, while the extraction layer employs deformable convolutions. These convolutions enable dynamic feature extraction by adjusting convolutional filters based on image content. The bits embedded in the image correspond to the parity bits of an error-correcting code, contributing to information integrity. The system's performance is evaluated under a variety of attacks commonly addressed in the literature, and the results demonstrate that the proposed approach is both effective and competitive compared to recent methods.

Keywords— Robust watermark, error-correcting codes, images, convolutional neural networks.

I. INTRODUCTION

O termo marca d'água digital em imagens refere-se à técnica de inserção invisível de uma mensagem (composta por bits de marca d'água) em uma imagem, denominada imagem original. Posteriormente, as informações inseridas podem ser extraídas da imagem com marca d'água [1]. Essa técnica atende a diversos propósitos, incluindo identificação de propriedade [2], verificação de autenticidade [3].

Uma marca d'água robusta garante que os bits da marca permaneçam detectáveis ou recuperáveis mesmo após a imagem com marca d'água ser submetida a diversas transformações,

Os autores são do Departamento de Eletrônica e Sistemas, Universidade Federal de Pernambuco, Recife-PE; {andy.ramos,cecilio.pimentel,daniel.chaves}@ufpe.br.

Este trabalho foi parcialmente financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

como redimensionamento, compressão, recorte e filtragem [1]. Outro aspecto importante em sistemas de marca d'água é o domínio de inserção, que pode ser classificado em duas categorias: domínio espacial e domínio da frequência. No domínio espacial, a inserção da marca d'água é realizada por meio da modificação nos pixels da imagem original [4]. Por outro lado, no domínio da frequência, a marca d'água é incorporada através da manipulação dos coeficientes obtidos a partir de alguma transformada [5], [6].

Artiles et al. [7] e Ramos et al. [4] propuseram um método no qual os bits de marca d'água inseridos na imagem original são derivados dos bits de paridade de um código corretor de erros. A palavra de informação a ser codificada é formada por uma concatenação de bits de marca d'água com bits caóticos gerados a partir de uma chave secreta compartilhada entre os usuários legítimos. O principal diferencial do procedimento de extração proposto é seu uso exclusivo para recuperar os bits da marca d'água, uma vez que o algoritmo de extração possui conhecimento de uma parte da palavra-código (os bits caóticos), resultando em um esquema altamente robusto.

O aprendizado profundo emerge como uma ferramenta poderosa em sistemas de marca d'água devido à sua capacidade de aprender características complexas dos dados com base na minimização de uma função de perda a partir de conjuntos de dados de treinamento. Em esquemas de marca d'água baseados em aprendizado profundo, dois tipos de redes são comumente empregados: Redes Neurais Convolucionais (CNNs) [8], [9] e Redes Geradoras Adversárias (GANs) [10]. Este trabalho propõe um novo esquema de marca d'água robusto no domínio espacial com as seguintes características:

- A camada de inserção utiliza uma estrutura paralela com CNNs, semelhante à rede *Inception* [11]. Essa rede aproveita convoluções paralelas para capturar representações complexas dos dados de entrada, apresentando alta eficiência computacional em comparação com blocos convencionais de CNNs [11].
- Adota-se a estratégia de codificação descrita em [4], [7] para a inserção de bits de paridade de um código corretor de erros na imagem original. No entanto, nossa abordagem difere ao empregar um código com proteção desigual de erros (UEP, *Unequal Error Protection*). O código UEP prioriza a proteção da primeira posição da palavra-código, a qual corresponde aos bits da marca d'água inseridos no espaço de características da imagem.
- A camada de extração usa convoluções deformáveis [12] permitindo que a janela de convolução se adapte e se deforme dinamicamente com base nas características do conteúdo da imagem. Essa adaptação aprimora a captura

de características espaciais, melhorando assim a extração dos bits de paridade no decodificador [12].

O restante deste trabalho está organizado em quatro seções. O esquema proposto é detalhado na Seção II. A Seção III discute o ambiente de treinamento e algumas métricas utilizadas para avaliar a imperceptibilidade e a robustez do esquema de marca d'água. Os resultados e comparações de desempenho são apresentados na Seção IV. As considerações finais são resumidas na Seção V.

II. DESCRIÇÃO DOS ESQUEMAS DE INSERÇÃO E EXTRAÇÃO

O diagrama em blocos do esquema proposto, mostrado na Fig.1, é composto por três camadas principais: inserção, ataque e extração. Adotamos a estratégia proposta em [4], [7], na qual os bits inseridos na imagem original C_O de dimensão $N \times M$ são derivados dos bits de paridade p_i de um código corretor de erros. A palavra de informação do código é construída combinando os bits de uma imagem binária de marca d'água W de dimensão $M' \times M'$ com bits caóticos gerados a partir de uma chave secreta. O fator de força α controla o compromisso entre imperceptibilidade e robustez. A imagem com marca d'água C_W é submetida a diversos ataques, resultando em uma imagem corrompida C'_W , que é a entrada da camada de extração. Essa camada é responsável por extrair os bits de paridade corrompidos \hat{p}_i . Por fim, um processo de decodificação estima os bits da marca d'água W' com base em uma regra de decisão. A seguir, apresentamos os detalhes da estrutura da rede.

A. Codificação da Marca d'água

A codificação dos bits da marca d'água é realizada nas etapas a seguir.

- 1) Gere uma sequência caótica utilizando o mapa logístico [13] com a chave K . A sequência caótica é então quantizada para gerar a sequência binária caótica \mathbf{f}_1 .
- 2) Considere um código UEP $C(15, 11)$, em que o comprimento da palavra-código é 15 e o comprimento da palavra de informação é 11. A matriz geradora deste código é dada em [14].
- 3) Construa a sequência de verificação de paridade \mathbf{p} do código UEP $C(15, 11)$ da seguinte forma. A imagem de marca d'água binária de tamanho $M' \times M'$ é convertida em uma sequência ℓ_1 . Os 11 bits de informação são obtidos pela concatenação de k_1 bits provenientes de ℓ_1 e k_2 bits provenientes da sequência caótica \mathbf{f}_1 , em que $k_1 + k_2 = 11$. Após a codificação, obtém-se uma palavra-código de 15 bits com 4 bits de paridade. Ao repetir esse processo para toda a sequência ℓ_1 , é gerada uma sequência de paridade $\mathbf{p} = \mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_{M' \times M'}$ de comprimento $4 \times M' \times M'$. Essa sequência é então representada como uma imagem quadrada e embaralhada com o mapa de Arnold (Arnold cat map). Após o embaralhamento, essa sequência é inserida na imagem original. O uso do código UEP prioriza a proteção dos k_1 bits (bits da marca d'água) nas primeiras posições da palavra-código.

B. Camada de Inserção

Os principais componentes da camada de inserção são compostos pelos módulos Rede *Inception*, Concatenação, Redução de Dimensionalidade e pulo de conexão (*skip connection*), conforme ilustrado na Fig. 2. Essa rede recebe como entrada blocos de tamanho de 32×32 pixels extraídos da imagem original. Blocos da sequência de paridade, cada um com tamanho 4×4 (obtidos da sequência \mathbf{p}), são inseridos em cada bloco da imagem original.

- **Redimensionamento.** Para inserir um bloco 4×4 de paridade em cada bloco 32×32 da imagem original utilizando a arquitetura proposta, cada bloco desta imagem é reestruturado para o formato $4 \times 4 \times 64$.
- **Rede *Inception*.** Adotamos uma estrutura paralela semelhante à rede *Inception*. A camada principal se ramifica em três caminhos paralelos. O primeiro é composto por duas camadas convolucionais circulares, enquanto os outros dois contêm uma camada convolucional circular cada. Todas as camadas utilizam 64 filtros com kernel de tamanho 2×2 , *stride* igual a 1 e funções de ativação ELU (Exponential Linear Unit). A convolução circular elimina a necessidade de preenchimento com zeros nos mapas de características, o que contribui para o aumento da robustez da marca d'água [8]. As operações convolucionais paralelas permitem que a rede aprenda representações mais complexas dos dados de entrada, facilitando a extração de características locais e globais. Essa abordagem também reduz o custo computacional em comparação com o uso de um único bloco convolucional com um grande número de filtros de mesma dimensão [11].
- **Concatenação.** A saída da rede *Inception* (um tensor no formato $4 \times 4 \times (3 \times 64)$) é concatenada com os blocos de paridade 4×4 , resultando em um tensor com dimensões $4 \times 4 \times ((3 \times 64) + 1)$. A inserção da marca d'água no espaço de características, ao invés de dispersá-la diretamente na imagem original, aumenta a robustez da rede contra diversos tipos de ataques [15].
- **Redução de Dimensionalidade.** Uma operação de redução de dimensionalidade é realizada utilizando uma camada convolucional padrão $1 \times 1 \times 193$ com 64 filtros e função de ativação ELU. Essa operação tem como objetivo reduzir as dimensões do tensor de saída da camada de concatenação para $4 \times 4 \times 64$.
- **Pulo de Conexão.** Após a aplicação de uma operação de multiplicação pelo fator de força α , o tensor resultante é reestruturado para o formato 32×32 , sendo então denominado residual. Para acelerar o processo de retropropagação e garantir uma representação abrangente do bloco, um pulo de conexão é implementado. Em seguida, o residual é somado ao bloco de entrada, resultando em um bloco com marca d'água.
Ao iterar esse processo sobre toda a imagem C_O e a sequência \mathbf{p} , obtém-se a imagem com marca d'água C_W .

C. Camada de Ataques

A camada de ataque recebe C_W como entrada e simula uma variedade de ataques. Por meio do treinamento de ponta

de informação de 11 bits. Ao fixar esses k_2 bits, os k_1 bits restantes determinam 2^{k_1} possíveis sequências de paridade. A estimativa dos k_1 bits da marca d'água é obtida por meio da minimização da distância de Hamming entre $\hat{\mathbf{p}}_i$ e as possíveis sequências de paridade.

III. MÉTRICAS E TREINAMENTO

Durante o treinamento, utilizamos uma combinação ponderada de duas funções de perda L_1 and L_2

$$L_t = \lambda_1 L_1 + \lambda_2 L_2 \quad (1)$$

em que L_1 é o erro quadrático médio entre a imagem original e a imagem com marca d'água

$$L_1 = \frac{1}{M \times N} \sum_{i=1}^N \sum_{j=1}^M (C_O(i, j) - C_W(i, j))^2 \quad (2)$$

e L_2 é a entropia cruzada

$$L_2 = - \sum_{pixels} y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (3)$$

em que y denota a classe a ser prevista e \hat{y} representa a probabilidade atribuída a essa classe. Os hiperparâmetros λ_1 e λ_2 são determinados empiricamente.

Para avaliar a imperceptibilidade da marca d'água inserida, utilizamos duas métricas amplamente empregadas na literatura: a razão sinal-ruído de pico (PSNR, *peak signal-to-noise ratio*) e o índice de similaridade estrutural (SSIM, *structural similarity index*). A qualidade da marca d'água extraída é avaliada por meio da taxa de erro de bit (BER, *bit error rate*), calculada entre as imagens W (original) e W' (extraída).

Utilizamos os conjuntos de dados CIFAR-10 [16] e BOSS [17] como imagens originais para o treinamento da rede. O conjunto CIFAR-10 é composto por 60.000 imagens de tamanho 32×32 pixels. O conjunto BOSS consiste em 10.000 imagens em escala de cinza, cada uma com resolução de 512×512 pixels. Essas imagens são divididas em blocos de tamanho 32×32 pixels, resultando em um total de 297.011 blocos em escala de cinza para treinamento. Todos os blocos são normalizados para o intervalo $[-0,5, 0,5]$.

Os resultados são obtidos utilizando TensorFlow com Keras na versão 2.10.0, em um ambiente Python com Anaconda em um sistema Windows 10. O otimizador Adam é utilizado com taxa de aprendizado 10^{-4} . Atribuímos coeficientes iguais para cada componente da função de perda ($\lambda_1 = \lambda_2 = 1$). Para aumentar a robustez do algoritmo, adotou-se $\alpha = 1$ durante o treinamento. O tamanho de cada lote (*batch*) é fixado em 32.

IV. RESULTADOS

Nesta seção, apresentamos os resultados obtidos durante a fase de testes. Utilizamos o conjunto de dados Granada [18], que é composto por 49 imagens em escala de cinza com tamanho 512×512 pixels, como conjunto de teste. Essas imagens são segmentadas em 256 blocos de tamanho 32×32 pixels. A imagem de marca d'água W , uma imagem binária aleatória de tamanho 32×32 bits, passa por um processo de codificação que gera um vetor de paridade com $32 \times 32 \times 4 =$

4096 bits, segmentado em 256 blocos de 4×4 bits de paridade. Cada bloco é então incorporado em um dos blocos da imagem com marca d'água.

Resultados de imperceptibilidade e robustez são apresentados na Tabela I, para diversos tipos de ataques e três valores distintos de α . Os ataques considerados são ruído Gaussiano com desvio padrão σ , ruído sal & pimenta com densidade s , recorte (*cropping*) e recorte em grade (*grid cropping*) com percentagem c , compressão JPEG com fator de qualidade Q . Os resultados são para imagens específicas como Barbara, Bridge, Baboon e Lena, além do conjunto Granada. Observa-se que o aumento do valor de α melhora a robustez do algoritmo, porém reduz a imperceptibilidade da marca d'água.

O desempenho do sistema proposto é comparado com métodos que utilizam técnicas de aprendizado profundo [8], [9]. A Tabela II apresenta os resultados dessa comparação considerando $\alpha = 1$ em todos os casos. Os três métodos apresentam valores de PSNR similares para este valor de α . O método proposto supera os demais para alguns ataques, como ruído Gaussiano, ruído sal & pimenta, recorte, recorte em grade, filtro Gaussiano. É importante destacar que, embora o sistema proposto seja treinado para 4 ataques específicos, ele também demonstra robustez contra diversos outros tipos de ataques.

V. CONCLUSÕES

O esquema proposto integra uma abordagem de aprendizagem profunda paralelizável com técnicas de codificação para criar um esquema robusto de marca d'água em imagens. Ao empregar treinamento iterativo, com estruturas paralelas de CNNs e convoluções deformáveis, o sistema alcança uma extração de características dinâmica e resiliente. O uso inovador de códigos UEP em conjunto com sequências caóticas garante robustez contra erros, priorizando a proteção dos bits da marca d'água. Os resultados demonstram que o método proposto é eficaz e apresenta desempenho competitivo quando comparado aos métodos disponíveis na literatura. Uma continuação natural deste trabalho é estender o esquema para imagens coloridas.

REFERÊNCIAS

- [1] I. Cox, M. Miller, J. Bloom, J. Fridrich, and T. Kalker, *Digital Watermarking and Steganography*, 2nd ed. Burlington, USA: Morgan Kaufmann, 2007.
- [2] Anand, Ashima, Singh, and A. Kumar, "Cloud based secure watermarking using IWT-Schur-RSVD with fuzzy inference system for smart healthcare applications," *Sustainable Cities and Society*, vol. 75, p. 103398, Dec. 2021.
- [3] S. Kumar, N. K. Sharma, Kumar, and Naveen, "WSOmark: An adaptive dual-purpose color image watermarking using white shark optimizer and Levenberg-Marquardt BPNN," *Expert Systems with Applications*, vol. 226, p. 120137, Sep. 2023.
- [4] A. M. Ramos, J. A. P. Artiles, D. P. B. Chaves, and C. Pimentel, "A fragile image watermarking scheme in DWT domain using chaotic sequences and error-correcting codes," *Entropy*, vol. 25, no. 3, p. 508, Mar. 2023.
- [5] C. Qu, X. Xi, J. Du, and T. Wu, "Robust watermarking scheme for vector geographic data based on the ratio invariance of DWT-CSVD coefficients," *ISPRS International Journal of Geo-Information*, vol. 11, no. 12, p. 583, Nov. 2022.
- [6] C. Wang, S. Li, Y. Liu, L. Meng, K. Zhang, and W. Wan, "Cross-scale feature fusion-based JND estimation for robust image watermarking in quaternion DWT domain," *Optik*, vol. 272, p. 170371, Feb. 2023.

TABELA I: Resultados de robustez e imperceptibilidade para imagens específicas e para o conjunto Granada.

Imagem	α	Imperceptibilidade		Robustez BER (%)														
		PSNR (dB)	SSIM	Ruído Gaussiano			Sal & Pimenta(%)			Recorte (%)			Recorte em Grade (%)			JPEG		
				0,05	0,10	0,25	2	6	10	10	20	30	20	30	40	90	70	50
Barbara	1,0	37,34	0,9580	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	1,46	0,00	2,70	6,10	0,00	2,60	13,81
	0,8	38,72	0,9815	0,09	0,09	0,09	0,09	0,19	0,48	0,58	1,07	2,31	1,52	4,32	6,92	0,97	8,21	22,94
	0,6	39,11	0,9864	0,97	0,97	0,97	1,17	1,56	1,75	1,85	1,75	2,53	3,22	6,73	10,05	4,29	13,27	27,83
Bridge	1,0	35,81	0,9818	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,09	0,68	1,17	2,44	6,25	0,00	4,00	10,25
	0,8	37,68	0,9883	0,00	0,00	0,00	0,00	0,09	0,58	0,00	0,87	1,85	1,56	4,78	8,30	0,87	10,64	19,33
	0,6	39,10	0,9915	0,97	0,97	0,97	1,26	1,46	2,44	2,14	4,00	5,85	3,61	6,93	10,93	4,10	17,28	22,07
Baboon	1,0	36,26	0,9799	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,19	0,78	0,48	1,36	6,05	0,00	4,50	12,10
	0,8	37,36	0,9868	0,29	0,29	0,29	0,29	0,39	1,26	0,78	1,17	2,44	1,85	4,00	7,12	0,87	10,05	16,50
	0,6	38,58	0,9901	2,92	2,92	3,02	3,2	2,73	5,17	3,90	5,66	9,27	7,42	7,03	11,71	5,37	17,57	23,53
Lena	1,0	38,64	0,9695	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,68	1,17	3,12	6,15	0,00	0,09	10,25
	0,8	40,58	0,9802	0,00	0,00	0,00	0,00	0,00	0,09	0,19	0,00	2,14	0,68	2,24	6,25	0,09	2,63	20,41
	0,6	41,93	0,9853	0,00	0,00	0,00	0,09	0,09	0,58	0,68	0,97	2,05	1,75	3,71	6,15	0,58	7,32	26,17
Granada	1,0	36,71	0,9709	0,00	0,00	0,00	0,00	0,00	0,04	0,00	0,03	1,02	0,84	2,75	5,75	0,00	2,46	11,83
	0,8	38,63	0,9810	0,11	0,11	0,12	0,15	0,23	0,46	0,27	0,48	1,81	1,39	3,49	6,72	0,61	6,67	19,74
	0,6	40,10	0,9860	0,80	0,80	0,80	1,00	1,17	1,87	1,26	1,76	3,35	2,78	5,21	8,44	2,43	12,25	25,08

 TABELA II: Comparação da BER média para o conjunto Granada para $\alpha = 1$. Os melhores valores estão indicados em negrito.

Ataque		Proposto			[8]	[9]
		PSNR = 36,71 dB BER (%)	PSNR = 35,93 dB BER (%)	PSNR = 37,38 dB BER (%)		
Ruído Gaussiano	$\sigma = 0,05$	0,00	0,00	0,09		
	$\sigma = 0,15$	0,00	2,60	3,71		
	$\sigma = 0,25$	0,00	12,70	10,30		
Sal & Pimenta	$s = 0,02$	0,00	0,00	-		
	$s = 0,04$	0,00	-	0,00		
	$s = 0,06$	0,00	0,10	0,00		
Recorte	$c = 10\%$	0,00	6,00	0,68		
	$c = 20\%$	0,03	11,30	3,81		
	$c = 30\%$	1,02	17,10	4,05		
Recorte em Grade	$c = 20\%$	0,84	3,30	-		
	$c = 30\%$	2,75	6,90	-		
	$c = 40\%$	5,75	11,40	-		
JPEG	$Q = 90$	0,00	0,00	0,00		
	$Q = 70$	2,46	0,00	0,00		
	$Q = 50$	11,83	1,20	1,36		
Gaussian Filter	$r = 1,0$	0,52	0,10	-		
	$r = 1,6$	16,70	29,00	-		
Sharpening	$r = 1$	0,01	0,00	0,00		
	$r = 5$	0,16	0,10	0,00		
	$r = 10$	0,37	0,20	0,00		
	$r = 20$	0,74	-	0,19		
Median Filter	3×3	3,94	2,90	-		
Resizing	0,50	3,76	5,90	14,4		
	0,75	0,61	0,00	5,56		
	1,50	0,32	0,00	0,48		
No Attack		0,00	0,00	-		

- [7] J. A. P. Artiles, Chaves, D. P. B., and C. Pimentel, "Robust image watermarking algorithm using chaotic sequences," *Journal of Information Security and Applications*, vol. 68, p. 103219, Aug. 2022.
- [8] M. Ahmadi, A. Norouzi, N. Karimi, S. Samavi, and A. Emami, "ReD-Mark: Framework for residual diffusion watermarking based on deep networks," *Expert Systems with Applications*, vol. 146, p. 113157, May 2020.
- [9] Y. Zhao, C. Wang, X. Zhou, and Z. Qin, "DARI-Mark: Deep learning and attention network for robust image watermarking," *Mathematics*, vol. 11, no. 1, p. 209, Dec. 2023.
- [10] J. Huang, T. Luo, L. Li, G. Yang, H. Xu, and C.-C. Chang, "ARWGAN: Attention-guided robust image watermarking model based on GAN," *IEEE Transactions on Instrumentation and Measurement*, vol. 72, pp. 1–17, June 2023.
- [11] T. Ganegedara, *TensorFlow in Action*. Shelter Island, NY.: Simon and Schuster, 2022.
- [12] J. Dai, H. Qi, Y. Xiong, Y. Li, G. Zhang, H. Hu, and Y. Wei, "Deformable

convolutional networks," in *Proceedings IEEE International Conference on Computer Vision*. Venice, Italy: IEEE, Oct. 2017, pp. 764–773.

- [13] S. Steven, *Nonlinear Dynamics and Chaos*, 1st ed. Boca Raton, FL.: Westview Press, 2001.
- [14] W. J. van Gils, "On linear unequal error protection codes," Master's thesis, Eindhoven University of Technology, Eindhoven, July 1982.
- [15] M. Jamali, N. Karimi, P. Khadivi, S. Shirani, and S. Samavi, "Robust watermarking using diffusion of logo into auto-encoder feature maps," *Multimedia Tools and Applications*, vol. 82, no. 29, pp. 45 175–45 201, Apr. 2023.
- [16] A. Krizhevsky, V. Nair, and G. Hinton, "CIFAR-10," on-line, 2014. [Online]. Available: <https://www.cs.toronto.edu/~kriz/cifar.html>
- [17] D. Bhowmik and C. Oakes, M. and Abhayaratne, "BOSS," International Conference on Information Hiding, 2011. [Online]. Available: <https://dde.binghamton.edu/download/>
- [18] V. Fernandez, "Dataset of standard 512 x 512 grayscale test images," 2019. [Online]. Available: <https://ccia.ugr.es/cvg/CG/base.htm>