



Revista Internacional de Investigación e Innovación Tecnológica

Página principal: www.riiit.com.mx

Sistema de marcado de agua cero para imágenes digitales basados en redes neuronales Neural network – based zero - watermarking system for digital images

Arevalo-Ancona, R.E.*, Cedillo-Hernández, M., Ramírez-Rodríguez, A.E., Nakano-Miyatake, M., Pérez-Meana, H.M.

Instituto Politécnico Nacional, Sección de Estudios de Posgrado e Investigación de ESIME Culhuacán, C.P. 04430, Ciudad de México.

rarevaloa0900@alumno.ipn.mx*; mcedillo@ipn.mx; aramirezr0906@alumno.ipn.mx; mnakano@ipn.mx; hmperez@ipn.mx

Innovación tecnológica: Sistema para protección intelectual de imágenes digitales.

Área de aplicación industrial: Forense digital de imágenes, seguridad informática, internet de las cosas, procesamiento de imágenes.

Recibido: 25 marzo 2023

Aceptado: 19 enero 2024

Abstract

Image authentication has become a paramount necessity in response to the rampant transfer of digital information. In this context, this paper presents an approach for protection of distortion-free digital image. The proposed method is based on extracting a feature map using a deep neural network, which consists of two branches, one for watermark classification and another for feature extraction. This neural network model shares weights between the branches since the watermark maintains image features, thus increasing the system's efficiency. The use of a neural model for feature selection allows the generation of image-specific feature learning, detecting them regardless of whether the image has been distorted. Subsequently, the feature map is combined with the user's watermark, generated from image edge detection, creating a unique stego-image. To evaluate the robustness of the generated watermark, different tests were performed on different types of geometric attacks, such as translation, rotation, scaling, and cropping, as well as advanced image processing, such as JPEG compression, filtering, and noise addition. Three main

metrics were used to evaluate the efficiency: Bit Error Rate (BER), Normalized Cross-Correlation (NCC), and Structural Similarity Index (SSIM). The results demonstrate that the proposed method exhibits remarkable robustness to a variety of attacks, reflected in the values of the average BER of 0.0059, a high NCC of 0.9936, as well as an SSIM of 0.9195. These results highlight the effectiveness and reliability of the proposed approach in digital images protection and authentication.

Keywords: *Digital watermark, deep neural network, intellectual property protection, image security.*

Resumen

La autenticación de imágenes se ha convertido en una necesidad primordial respuesta a la desenfrenada transferencia de información digital. En este contexto, este artículo presenta un enfoque para la protección de imágenes digitales sin distorsiones. El método propuesto se basa en la extracción de un mapa de características mediante el uso de una red neuronal profunda, la cual consta de dos ramas, una para la clasificación de la marca de agua y otra para la extracción de características. Este modelo de red neuronal comparte pesos entre las ramas ya que la marca de agua mantiene características de la imagen, por lo tanto, permite aumentar la eficiencia del sistema. El uso de un modelo neuronal para la selección de características permite generar un aprendizaje de características específicos de cada imagen, detectándolas sin importar si la imagen ha sido distorsionada. Posteriormente, el mapa de características se combina con la marca de agua del usuario, la cual se genera a partir de la detección de los bordes de la imagen, creando así una estego-imagen única. Para evaluar la robustez de la marca de agua generada, se realizaron una serie de pruebas ante diferentes tipos de ataques geométricos, como traslación, rotación, escalamiento y recorte, así como procesamiento avanzados de imágenes, como compresión JPEG, filtrado y adición de ruido. Para evaluar la eficiencia se usaron tres métricas principales: el promedio de bits erróneos (BER), la correlación cruzada normalizada (NCC) y el índice de similitud estructural (SSIM). Los resultados obtenidos demuestran que el método propuesto exhibe una notable robustez ante una variedad de ataques, lo que se refleja en los valores del BER promedio, que se sitúa alrededor de 0.0059, una alta NCC de 0.9936, así como un SSIM de 0.9195. Estos resultados resaltan la eficacia y la confiabilidad del enfoque propuesto en la protección y autenticación de imágenes digitales.

Palabras clave: *Marca de agua digital, redes neuronales profundas, protección intelectual, seguridad en imágenes.*

I Introducción

En los últimos años, ha existido un incremento en el uso de tecnologías para el intercambio de información, motivado en gran medida por el uso excesivo de las redes sociales y a la vez, agravándose por la

digitalización de diversos trámites. Este fenómeno ha adquirido una relevancia significativa, ya que ha impulsado la transferencia de imágenes que pueden contener información sensible. Además, en este contexto también se ha generado un incremento en la manipulación de imágenes,

con fines como la falsificación de documentos, así como la distribución no autorizada de contenido visual [1].

Lo anterior ha generado riesgos de seguridad, donde los datos personales quedan expuestos. Por consiguiente, se ha vuelto imperativo abordar la protección de la propiedad intelectual de imágenes digitales. Por este motivo, la autenticación y protección de derechos de autor referentes a imágenes se han convertido en un requisito indispensable [2], [3].

La protección de la propiedad intelectual comienza en el momento en que se crea una imagen. Sin embargo, en numerosas ocasiones es esencial incorporar una marca o señal distintiva para identificar al propietario y obtener su autorización para su uso [5]. Las marcas de agua digitales se desempeñan como una de firma digital para identificar al titular del contenido y verificar su autenticidad [6].

Las características fundamentales de una marca de agua son su imperceptibilidad, robustez, capacidad de carga de datos y la seguridad que ofrece. La imperceptibilidad se refiere a la capacidad de la marca de agua para no generar distorsiones visuales evidentes al ser insertada en la imagen, ya que esto podría generar errores al analizar la información de la imagen, afectando diversas tareas relacionadas. La robustez es la capacidad de recuperar la marca de agua de manera íntegra o con la menor cantidad de errores posible, incluso cuando la imagen ha sido sometida a alteraciones, ataques o procesamientos. Mientras que la capacidad de carga de datos se relaciona con la cantidad de información que la marca de agua puede llevar o incorporar en la imagen sin comprometer su calidad visual. Por último, la seguridad se refiere a la capacidad de la marca de agua de mantenerse intacta o sufrir la menor cantidad de alteraciones

posible al ser detectada, garantizando así su función de identificación o autenticación [5].

Los algoritmos convencionales de marcado de agua tienen como objetivo incorporar información referente a la propiedad intelectual en una imagen para garantizar su protección [6], [7], [8]. No obstante, este proceso puede dar lugar a ciertas distorsiones que afectan negativamente al análisis de la imagen. Un ejemplo de este enfoque que aborda esta problemática es el presentado por Yuan et al. [9], en su método utilizan la Transformada Discreta de Coseno (DCT) para obtener los coeficientes de frecuencias bajas para insertar la marca de agua. Este enfoque logra un marcado de agua invisible. La selección del bloque donde se realizará la inserción de los bits de la marca de agua se lleva a cabo mediante el algoritmo de selección pseudoaleatorio MD5. Otro enfoque es el propuesto por Ram en [10], este método hace uso del cuarto nivel de la Transformada Discreta de Wavelet (DWT) para descomponer la imagen en diferentes sub-bandas. Luego, se utiliza otra imagen como marca de agua, que se inserta en las sub-bandas LH3, HL3, LH2, HL2 y HH2 de la imagen original. Por otro lado, Veni y Meyyappan en [11] emplean una estrategia en la que descomponen la imagen en frecuencias mediante la DWT y se centran en la sub-banda HH. Luego, utilizan la descomposición de bloques mediante valores singulares (SVD) para determinar los coeficientes donde se insertará la marca de agua. Finalmente, a través de un algoritmo evolutivo, evalúan los cambios experimentados por la imagen para determinar si es factible insertar los bits de la marca de agua en los coeficientes seleccionados. Sin embargo, la mayoría de los métodos tradicionales, como los mencionados anteriormente, tienden a introducir distorsiones en las imágenes. Estas distorsiones pueden afectar negativamente la calidad visual y la

integridad de las imágenes, lo que a su vez puede influir en la precisión y confiabilidad de las tareas que se realicen sobre ellas.

Debido a las limitaciones observadas en métodos tradicionales, en los que se generan distorsiones en las imágenes, ha surgido un interés continuo en desarrollar técnicas de marcado de agua que sean imperceptibles y evitando cualquier alteración en las imágenes. Por lo que, se han desarrollado diversos enfoques conocidos como marcado de agua libre de distorsiones. Dichos métodos crean un patrón a partir de la combinación de las características extraídas de la imagen y de información proporcionada por el usuario, lo que brinda una protección efectiva de la información sin modificar la calidad de la imagen. El patrón de marca de agua debe almacenarse de manera segura. Además, al utilizar características intrínsecas de la imagen, estos métodos ofrecen una mayor robustez ante diferentes ataques ya sean transformaciones geométricas o procesamiento de imagen. Este método presenta diversas ventajas, como la prevención de errores en el diagnóstico médico, la reducción de alteraciones en los resultados de investigaciones, la garantía de la seguridad de los datos en sistemas de sensado basados en imágenes o la protección de imágenes que requieren una alta calidad de la imagen [12]. Un ejemplo es el propuesto por Xing et al. en [13], que extrae las características principales de la imagen utilizando los valores de frecuencia alta de la DCT y los combina con los coeficientes de frecuencia alta de la Transformada Discreta de Fourier (DFT) para crear una estego-imagen utilizando patrones o características inherentes a la imagen para su protección y autenticación. Por otro lado, Fang et al. en [14], emplean el algoritmo de detección de características invariantes (SIFT) para obtener las características visuales más relevantes de la imagen. Posteriormente,

aplican la transformada de Bandelet para el análisis geométrico de estas características y utilizan la DCT para crear una matriz de características que protege la imagen sin distorsionarla. Li et al., por su parte, proponen en [15] el uso del algoritmo KAZE para detectar puntos de interés en la imagen y generar un vector de características que se combina con la marca de agua para crear una matriz de características que protege la imagen sin generar distorsiones. Estos enfoques representan avances significativos en la protección de imágenes sin comprometer su calidad visual.

Además, los sistemas de inteligencia artificial basados en redes neuronales profundas han abierto nuevas oportunidades de investigación, especialmente en el campo del procesamiento y la seguridad de imágenes. Estos sistemas buscan emular el funcionamiento del cerebro humano al aprender características para llevar a cabo diversas tareas. Las redes neuronales constan de dos etapas clave: la etapa de entrenamiento, donde se enseña al sistema a reconocer datos específicos en las imágenes, y la etapa de prueba, en la que el sistema reconoce automáticamente los datos en cada imagen.

La aplicación de sistemas de inteligencia artificial en métodos de marcado de agua ofrece la posibilidad de desarrollar algoritmos más eficaces, debido al reconocimiento y aprendizaje de características en imágenes por parte de las redes neuronales [16]. Un ejemplo es el enfoque propuesto por Hamamoto y Kawamura [17], que sugiere el desarrollo de un esquema para extraer coeficientes de baja frecuencia de la DCT utilizando redes neuronales profundas para aprender estos valores y reducir el error en la recuperación de la marca de agua. Han et al., en [18], presentan un método de marcado de agua libre de distorsiones en el cual utilizan un

modelo neuronal VGG16 para extraer características relacionadas con la imagen. Estas características se combinan con los coeficientes de baja frecuencia de la DFT, que son mezclados mediante la secuencia caótica de Hermite, brindando así una protección continua a la imagen sin generar distorsiones. Gong et al., desarrollaron en [19] un esquema de marca de agua libre de distorsiones basado en una red neuronal residual DenseNet para la extracción de características y utilizaron los coeficientes de la DCT para crear una matriz de características y combinarla con la marca de agua, dicha matriz de características es obtenida para cada set de imágenes. Estos enfoques destacan cómo la inteligencia artificial está revolucionando la protección y autenticación de imágenes al aprovechar las capacidades de aprendizaje profundo. Nawaz et al. propusieron una técnica innovadora de marca de agua para la protección de imágenes médicas, en su estudio [20]. En este enfoque, se realiza la extracción de características de las imágenes médicas mediante la representación de los coeficientes en el dominio de la DWT. Este proceso se lleva a cabo para el aprendizaje de puntos característicos mediante la utilización del modelo preentrenado ResNet101. Posteriormente, las características obtenidas por el modelo ResNet101 se someten a una DCT con el objetivo de generar un vector característico, que se integra de manera conjunta con la marca de agua. Huang et al. presentan en su investigación [21] un esquema de marca de agua para imágenes médicas que se basa en una red neuronal profunda VGG16. En este enfoque, los autores proponen la sustitución de los bloques convolucionales tradicionales por bloques convolucionales consecutivos o bloques sobre-parametrizados. Esta modificación tiene como objetivo generar un aprendizaje generalizado de los datos. De esta manera, la red neuronal se emplea para la extracción de características inherentes a

la imagen, las cuales se combinan con la marca de agua para generar la matriz de características. Dicha matriz se utiliza para la protección del contenido digital. Li et al. [22] han desarrollado una técnica de marca de agua que se fundamenta en el modelo neuronal DarkNet53. Este enfoque se centra en el aprendizaje de las características asociadas a los coeficientes de la imagen representados mediante la DCT. Además, la marca de agua es sometida a un proceso de encriptación mediante mapeos caóticos, culminando en la generación de la estego-imagen resultante. Dong et al. [23] proponen un algoritmo basado en redes neuronales que emplea el modelo NasNet-Mobile como extractor de características. En esta metodología, se obtiene un eigenvector al extraer los coeficientes de frecuencias bajas de la DCT relacionados con las características de la imagen. Este eigenvector se combina posteriormente con la marca de agua para generar la protección de la imagen. Fierro-Radilla et al. [24] llevan a cabo la extracción de características generales de un conjunto de imágenes mediante una red neuronal convolucional genérica. Posteriormente, estas características se combinan con la marca de agua encriptada para generar la estego-imagen. Zhong et al. [25] propusieron un marcado de agua ciego basado en redes neuronales no supervisadas donde generalizan las características de la imagen para reducir el tiempo de procesamiento para reducir la intervención del usuario. Quan et al. desarrollaron en [26] un sistema de marcado de agua utilizando un modelo neuronal profundo para la generación de una estego-imagen de manera la cual es insertada en la imagen para su protección, posteriormente usa la red neuronal para detectar la marca de agua y extraerla. Fei et al. [27] presentaron un método de marcado de agua para imágenes generadas mediante redes neuronales generativas, donde modifican la función de pérdida del

generador de imágenes para insertar la marca de agua.

Las contribuciones clave de este método son las siguientes:

1) **Detección de Características Únicas:** Realiza la detección y extracción de características específicas de cada imagen a través de un modelo neuronal, fortaleciendo significativamente la seguridad del sistema.

2) **Aprendizaje de Representaciones Invariantes:** El aprendizaje de representaciones invariantes de las características aumenta la robustez del algoritmo, permitiendo que la red neuronal las identifique incluso después de ser aplicadas alteraciones o manipulaciones en la imagen.

3) **Matriz de Características para Protección:** La matriz de características o estego-imagen creada para la protección del material multimedia contiene exclusivamente características de la imagen. Estas características son recuperadas por la red neuronal incluso después de alteraciones, eliminando posibles confusiones al recuperar la marca de agua.

4) **Selección del Modelo Neuronal:** La selección del modelo neuronal permite la extracción de características de la imagen y la clasificación de la marca de agua, reduciendo el tiempo de entrenamiento de la red neuronal al compartir pesos. Además, generaliza las características de la imagen para la rama utilizada en la clasificación de la marca de agua y para la rama encargada de extraer las características utilizadas en la generación de la estego-imagen.

5) **Contexto Global de Características:** El uso de redes neuronales permite al sistema aprender representaciones de la imagen en un contexto global de sus características, posibilitando la recuperación de la marca de agua sin pérdida de información, incluso ante alteraciones.

6) **Generalización de la Imagen:** La red neuronal propuesta generaliza la imagen al

compartir pesos, aumentando la robustez y eficiencia del detector de características para recuperar la marca de agua de manera intacta y en la extracción de características para la generación de la estego-imagen.

7) **Aumento de Datos para Eficiencia:** El aumento de datos mediante diversas manipulaciones a la imagen incrementa la eficiencia del sistema, permitiendo que la red neuronal generalice la representación de la imagen extrayendo las características más importantes.

8) **Compartir Pesos para Invarianza:** La red neuronal propuesta comparte pesos entre sus dos ramas para el aprendizaje de características invariantes, aumentando la eficiencia en la recuperación de la marca de agua.

9) **Aprendizaje Conjunto de Características:** El compartir pesos permite el aprendizaje conjunto de características. Mientras una rama se enfoca en la clasificación, la otra se especializa en la extracción de características. Esta configuración facilita que la red aprenda representaciones discriminativas y relevantes.

10) **Reducción del Espacio de Características:** La separación en dos ramas una para la extracción de características y otra la clasificación y el compartir pesos permite una representación más compacta y significativa de los datos. Esto puede ser beneficioso en términos de eficiencia computacional y almacenamiento.

11) **Tamaño de la Marca de Agua:** El tamaño de la marca de agua utilizado es de 256 x 256 píxeles, superando la mayoría de los métodos de marcado de agua libre de distorsiones. Esto mejora la capacidad de detección y la eficiencia en la autenticación de la marca de agua.

12) **Generación Individual de Estego-Imágenes:** La propuesta busca generar una estego-imagen para cada clase (cada imagen), destacando la utilidad al implementar el sistema propuesto al no

generalizar características de un grupo de imágenes similares.

13) La construcción de una estego-imagen única para cada imagen, genera robustez. Esto se debe a que cada imagen está marcada de manera única, lo que dificulta la reproducción y manipulación no autorizada. Lo cual proporciona una diferencia notable a la mayoría de los algoritmos basados en redes neuronales como extractores de características, ya que estos se centran en el entrenamiento del modelo neuronal a partir de un grupo de imágenes similares.

A continuación, se describe brevemente la distribución el resto del documento: Sección II (Materiales y Metodología): Describe los materiales y las bases de imágenes utilizadas en la investigación, así como la metodología empleada para evaluar el algoritmo. Sección III (Metodología): Proporciona los detalles y conceptos necesarios para la reproducción de la metodología utilizada. Sección IV (Sistema de marcado de agua cero para imágenes digitales basados en redes neuronales): Detalla el proceso utilizado para crear la marca de agua y la estego-imagen empleada en la protección de las imágenes digitales, así como la etapa referente a la recuperación de la marca de agua. Esta sección proporciona una visión detallada de cómo se implementa el sistema de marca de agua libre de distorsiones. Sección V (Resultados): Muestra los resultados obtenidos en los experimentos realizados, lo que incluye la efectividad y robustez del método propuesto. Sección VI (Conclusión): Proporciona una conclusión general de los hallazgos y destaca las contribuciones clave del trabajo.

II Materiales y métodos

1. Plataforma de Desarrollo:

El entorno de desarrollo utilizado fue Python 3.6 con Pytorch.

2. Hardware Utilizado:

Las especificaciones de hardware del sistema de cómputo utilizado son: un procesador Intel Core i7 y la tarjeta gráfica Geforce GTX 1650.

3. Base de Datos:

La base de imágenes utilizada consta de 812 imágenes naturales en el formato .jpeg y en el modelo de color Rojo-Verde-Azul (RGB) obtenida de KAGGLE [28] de tamaño 512 x 512 pixeles. Dicha base de datos está compuesta por 8 clases de imágenes naturales (aviones, carros, motocicletas, rostros de personas, frutas, flores, gatos y perros).

4. Aumento de Datos:

El aumento de imágenes se realiza para mejorar la detección de las características de cada imagen al entrenar la red neuronal, y evitar errores en la detección de la marca de agua al manipular la imagen, de esta manera se incrementa la eficiencia del sistema. Para realizar el aumento de imágenes se aplicaron diferentes ataques geométricos y de procesamiento avanzado de señal.

La Tabla 1 y la Tabla 2 muestran diferentes imágenes de las bases de datos utilizadas, junto con las transformaciones geométricas y los procesamientos de imágenes aplicados para el aumento de datos y para la evaluación del método propuesto.

Tabla 1. Transformaciones geométricas utilizadas.







Sin ataque 	Rotación 	Traslación 	Traslación 	Escalamiento 
Escalamiento 	Recorte centro 	Recorte superior 	Recorte inferior 	Transformada Affine 

Tabla 2. Procesamientos de imagen aplicados.

Compresión JPEG 70 	Compresión JPEG 50 	Compresión JPEG 30 	Filtro de Mediana 
Filtro Gaussiano 	Emborronamiento 	Ruido Gaussiano 	Ecualización de Histograma 

5. Experimentos Adicionales:

Se incluyeron experimentos adicionales con imágenes en formato *Neuroimaging Informatics Technology Initiative* (.nii) [29]. Esta base de imágenes contiene 125 imágenes pertenecientes a imágenes de ultrasonido del hígado con un tamaño de 512 x 512 píxeles. El uso de diferentes tipos de imágenes demuestra la versatilidad y las posibles aplicaciones del sistema propuesto en diversos campos.

6. Métricas para la evaluación del sistema de marcado de agua:

Se utilizaron las métricas del Promedio de Error por Bit (BER), la Correlación Cruzada

Normalizada (NC) y el Índice de Similitud Estructural (SSIM) para evaluar la eficiencia del método propuesto comparando la marca de agua original con la marca de agua recuperada.

El BER es una métrica empleada para cuantificar la calidad de la recuperación de la marca de agua. Ofrece una medida precisa de la exactitud al calcular los bits incorrectos entre la marca de agua original y la marca de agua detectada (ecuación 1). Cuanto menor sea el valor de BER, mayor será la precisión en la recuperación de la marca de agua [30].

$$BER = \frac{\text{Bits erróneos}}{\text{Total de bits}} \quad (1)$$

La NC se utiliza para evaluar la similitud entre la marca de agua (W) y la marca de agua extraída (Wr). Mide la correlación entre las dos imágenes, proporcionando una medida cuantitativa de la coincidencia (ecuación 2). Un valor alto de NC indica una mejor recuperación de la marca de agua y una mayor similitud [31].

$$NC = \frac{\sum_{i=1}^m \sum_{j=1}^n ((W(i, j))x(Wr(i, j)))}{\sum_{i=1}^m \sum_{j=1}^n W(i, j)^2} \quad (2)$$

El SSIM evalúa la calidad de la marca de agua recuperada. Considera aspectos relacionados a la luminancia, el contraste y la estructura de la imagen. Un valor cercano a 1 en el SSIM indica una alta similitud entre la imagen original y la imagen con marca de agua recuperada (ecuación 3) [32].

$$SSIM = [I(x, y)]^a [c(x, y)]^\beta [s(x, y)]^\gamma \quad (3)$$

$$I(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (4)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (5)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (6)$$

Donde μ_x, μ_y son los valores promedio locales. σ_x, σ_y son las desviaciones estándar y σ_{xy} la varianza. Si a, γ y β son igual a 1, además $C_3 = C_2 / 2$ (C_1 y C_2 son constantes para estabilizar la división en caso de que el

denominador sea cercano a 0), por consiguiente, el SSIM puede ser expresado como en la ecuación 7:

$$SIIM = \left(\frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \right) \left(\frac{2\sigma_{xy} + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \right) \quad (7)$$

III Metodología

1. Generación de la marca de agua

La marca de agua se crea utilizando características de la imagen que se desea proteger. Para la obtención de los patrones que se utilizan al generar la marca de agua, es aplicado un procesamiento de señal basado en filtro de Sobel para la detección de bordes. Se combinan las matrices para la detección de características horizontales (ecuación 8) y verticales (ecuación 9). La combinación de características genera una aproximación más precisa de las variaciones de intensidad en la imagen, mediante la ecuación 10, lo que nos permite identificar los bordes de manera eficiente (Figura 1). Como resultado se obtienen puntos específicos y únicos en cada imagen. Posteriormente la imagen es binarizada para poder combinarla de manera efectiva con las características extraídas de la red neuronal y crear de esta manera la estego-imagen (Sección IV).

$$Gx = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * img \quad (8)$$

$$Gy = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} * img \quad (9)$$

$$G = \sqrt{Gx + Gy} \quad (10)$$



Figura 1. Detección de bordes mediante filtro de Sobel.

En resumen, el uso de la detección de bordes como características para la generación de la marca de agua incrementa la seguridad, ya que se añade una capa de autenticación, ya que se puede utilizar para determinar si la imagen fue manipulada, cumpliendo la función para una prueba visual de la integridad de la imagen. Lo anterior resulta útil en aplicaciones donde la integridad de la imagen es fundamental, como en la autenticación de documentos, la protección de imágenes médicas o la seguridad en sistemas de reconocimiento de objetos.

2. Red neuronal para la extracción de características de la imagen

Las redes neuronales son modelos de procesamiento de información inspirados en el funcionamiento del cerebro humano. Están diseñadas para aprender y reconocer patrones a partir de datos. Los algoritmos de aprendizaje profundo tienen como objetivo llevar a cabo tareas de manera altamente eficiente. Actualmente los modelos neuronales profundos son utilizados en diversas áreas, como el procesamiento de

imágenes y la seguridad de imágenes [33], [34].

La red neuronal extrae características invariantes de la imagen para la creación de la marca de agua. Por otro lado, realiza un aprendizaje de características para su clasificación (para cada clase se realiza el entrenamiento de ambas redes neuronales).

La red neuronal propuesta es representada en la Figura 2, desempeñando una doble función como extractor de características y verificador de la marca de agua extraída. Esta estrategia se implementa con el propósito de reducir el costo computacional del entrenamiento, permitiendo llevar a cabo ambas tareas en una sola etapa. La red neuronal extrae características invariantes de la imagen para la construcción de la estego-imagen utilizada para la protección de la imagen. Además, se realiza el aprendizaje de características específicas para la clasificación, donde se requiere el entrenamiento de ambas redes neuronales para cada imagen.




Figura 2. Modelo neuronal para la extracción de características y discriminador.

Este enfoque se basa en un modelo de red neuronal siamesa [35], [36], que consta de dos redes neuronales profundas similares que comparten sus pesos. De esta manera, se logra acelerar el proceso de entrenamiento y optimizar el rendimiento del sistema, ya que una de las ramas se dedica a la extracción de características, mientras que la otra se encarga de la clasificación de la marca de agua.

Los bloques ResNet utilizados para la extracción de características abordan el problema de la degradación del rendimiento que puede ocurrir al aumentar la profundidad de una red neuronal. Al introducir conexiones permite realizar un aprendizaje de las características de la imagen de manera más eficiente, ya que transmite dichos patrones entre los bloques neuronales. Debido a las conexiones los bloques ResNet puede aprender a identificar y preservar características importantes, lo que reduce la redundancia de parámetros.

Las redes neuronales basadas en el aprendizaje de características compartidas se fundamentan en el uso de pares de datos, como imágenes pertenecientes a la misma categoría o con atributos similares, tal como se implementa en el sistema de marcado de agua propuesto en esta investigación. Estos modelos neuronales son entrenados con un

conjunto de datos para adquirir conocimientos sobre características generales. En este contexto, se busca determinar si la marca de agua recuperada coincide con la utilizada para generar la estego-imagen.

Adicionalmente, la adopción de una red neuronal propuesta posibilita la extracción de características de las imágenes y la identificación de su clase mediante dos modelos distintos, apoyándose en el concepto de aprendizaje de representaciones compartidas. Cada rama del modelo procesa una entrada diferente, especializándose en la extracción de características relevantes. En este escenario, una rama se utiliza para extraer características inherentes a la imagen con el propósito de construir una estego-imagen, mientras que la otra rama se emplea para clasificar la marca de agua, basándose en la detección de bordes en la imagen.

Por otro lado, la red neuronal logra extraer características invariantes, gracias al intercambio de pesos entre los modelos neuronales utilizados. Esta característica contribuye significativamente a incrementar la robustez del método de marcado de agua, asegurando su efectividad incluso si existen variaciones en la posición de las características extraídas.

La Tabla 3 presenta la configuración detallada de las redes neuronales propuestas

para la clasificación y extracción de características.

Tabla 3. Configuración de la red neuronal.

Red neuronal para la extracción de características					Red neuronal para clasificación de la marca de agua				
Capa	Neuronas	Stride	Padding	Kernel	Capa	Neuronas	Stride	Padding	Kernel
CNN 1	64	2	1	4	CNN 1	64	2	1	4
CNN 2	64	2	1	4	CNN 2	64	2	1	4
CNN 3	128	2	1	4	CNN 3	128	2	1	4
CNN 4	256	2	1	4	CNN 4	256	2	1	4
CNN 5	512	2	1	4	CNN 5	512	2	1	4
CNN 6	1024	2	1	4	CNN 6	1024	2	1	4
TCNN 1	512	2	1	4	TCNN 1	512	2	1	4
TCNN 2	256	2	1	4	TCNN 2	256	2	1	4
TCNN 3	128	2	1	4	TCNN 3	128	2	1	4
TCNN 4	64	2	1	4	TCNN 4	64	2	1	4
---	---	---	---	---	FC	100	2	1	4
---	---	---	---	---	Clasificador	2	2	1	4
Hiperparámetros									
Épocas					7				
Factor de aprendizaje					0.00003				
Tamaño de lote					25				

Durante el entrenamiento, se proporcionan pares de entradas a ambas ramas gemelas de la red siamesa. Cada rama realiza la propagación hacia adelante, procesando la entrada y generando una representación de características. Posteriormente las características extraídas de ambas ramas (O_1, O_2) se comparan con la imagen de referencia ($I(x, y)$) y se mantienen las características principales, es decir, características similares mediante la función de pérdida (Ecuación 11).

$$L(a, p, n) = \max \{ \sqrt{I(x, y) - O_1(x, y)} - \sqrt{I(x, y) - O_2(x, y)} \} \quad (11)$$

En la Figura 3 se muestra el proceso para extracción de características y validación de la marca de agua extraída.




Figura 3. Descripción del modelo neuronal para los pesos compartidos.

El empleo de un modelo neuronal que comparte pesos es beneficioso en varios aspectos. Primero, facilita la comparación de las características extraídas y la selección de las más relevantes, aquellas que coinciden en los modelos utilizados. Además, esta estrategia contribuye a la optimización de los recursos computacionales.

IV Sistema de marcado de agua cero para imágenes digitales basados en redes neuronales

El método propuesto consta de 3 etapas: 1) extracción de características inherentes a la imagen, 2) construcción de la estego-imagen para la protección de la imagen digital, 3) recuperación de la marca de agua y comprobación de la marca de agua.

1. Extracción de características

La extracción de características de la imagen se basa en la generación de mapas de características a través de la red neuronal propuesta. Esta red neuronal es entrenada

utilizando la imagen, a la que se le aplican diversas distorsiones con el fin de mejorar la eficacia en el reconocimiento de patrones relacionados con la imagen, generando un aumento de datos. La elección del mapa de características se lleva a cabo mediante una llave compartida con usuario (sin la llave para la selección del mapa de características la marca de agua recuperada tendría alteraciones en el proceso de detección, ya que cada mapa de características contiene información diferente respecto a la imagen), aspecto que desempeña un papel crucial en la mejora de la seguridad del sistema, tal como se visualiza en la Figura 4.




Figura 4. Proceso de extracción de características.

2. Construcción de la estego-imagen para la protección de la imagen digital

El proceso para la construcción de la estego-imagen se detalla en la Figura 5 y consta de los siguientes pasos:

- Aplicar diversas manipulaciones a la imagen con el objetivo de aumentar la cantidad de datos y lograr un sistema de marcado de agua más eficiente. Este aumento de imágenes permite un mejor aprendizaje de las características o patrones, lo que facilita la recuperación de la marca de agua sin errores. La cantidad de imágenes generadas al aumentar los datos es de 300 imágenes (4 imágenes sin ataque, 4 imágenes por cada rotación efectuada cada 15° en un rango de $5^\circ - 350^\circ$, 4 imágenes por cada rotación efectuada cada 15° en un rango de $5^\circ - 350^\circ$ y escaladas

con un factor de 0.5, 4 imágenes trasladadas dentro de la misma imagen 150 píxeles en 'x' y 'y', 4 imágenes trasladadas dentro de la misma imagen 100 píxeles en 'x' y 'y', 4 imágenes trasladadas dentro de la misma imagen 50 píxeles en 'x' y 'y', 4 imágenes escaladas a 256×256 píxeles, 4 imágenes escaladas a 128×128 píxeles, 4 imágenes a las que se les aplicó en un recorte en la esquina superior derecha de 100×100 píxeles, 4 imágenes con un recorte en la esquina superior izquierda de 100×100 píxeles, 4 imágenes en las que se realizó un recorte de 150×100 píxeles la esquina inferior derecha, 4 imágenes en las que se realizó un recorte de 150×100 píxeles la esquina inferior izquierda, 4 imágenes con un recorte en el centro de 100×100 píxeles, 4 imágenes con

una traslación de 15 píxeles en 'x' y 'y', 4 imágenes con una traslación de 25 píxeles en 'x' y 'y', 4 imágenes con una traslación de 50 píxeles en 'y', 4 imágenes con una traslación de 25 píxeles en 'y', 4 imágenes con una traslación de 50 píxeles en 'x', 4 imágenes con una traslación de 25 píxeles en 'x', 4 imágenes con un factor de calidad de 70 realizado en una compresión JPEG, 4 imágenes con un factor de calidad de 30 realizado en una compresión JPEG, 4 imágenes con adición de ruido gaussiano con un $\sigma=0.009$, 4 imágenes con adición de ruido gaussiano con un $\sigma=0.009$ y escalamiento a una imagen de 56 x 56, 4 imágenes con adición de ruido gaussiano con un $\sigma=0.9$, 4 imágenes con adición de ruido gaussiano con un $\sigma=0.9$ y escalamiento a una imagen de 56 x 56, 4 imágenes con un filtro de suavizado, 4 imágenes con un filtro de suavizado y escalamiento a 256 x 256 píxeles, 4 imágenes con filtrado gaussiano, 4 imágenes con filtro gaussiano y escalamiento a 256 x 256, 4 imágenes con un filtro para

eliminar el ruido, 4 imágenes con un filtro para eliminar el ruido y escalamiento a 256 x 256, 4 imágenes con un filtro de mediana, 4 imágenes con un filtro de mediana y escalamiento a 256 x 256, 4 imágenes con un filtro de caja y 4 imágenes con filtro de caja y escalamiento).

- La selección del mapa de características para construir la estego-imagen se realiza mediante una llave, fortaleciendo la seguridad del sistema al garantizar la diferencia entre cada mapa de características.
- Realizar la detección de bordes para la generación de la marca de agua, utilizando las características de la imagen para mejorar la seguridad en la protección de la imagen digital.
- Combinar el mapa de características (*imf*) con la marca de agua (*Ws*) mediante una operación lógica XOR, como se describe en la Ecuación 12. La función de la estego-imagen (*MS*) es identificar la originalidad y la propiedad de la imagen digital.

$$MS = imf \oplus Ws \quad (12)$$




Figura 5. Generación de la estego-imagen.

En esta etapa se construye una estego-imagen que cumple con los objetivos para

autenticar y proteger la propiedad intelectual de la imagen digital.

3. Recuperación y comprobación de la marca de agua

El procedimiento para la reconstrucción de la marca de agua es representado en la Figura 6 y consta de los siguientes pasos:

- Extraer las características de la imagen utilizando la red neuronal previamente entrenada.
- Seleccionar el mapa de características con el cual se desea construir la estego-imagen mediante el uso de una llave. La eficiencia en la recuperación de la marca de agua depende directamente de la selección del mapa de características utilizado en el proceso de generación de la estego-imagen. Por lo tanto, es esencial conocer la llave correspondiente para asegurar la adecuada identificación y recuperación de la marca de agua durante el proceso de autenticación o

verificación del material multimedia. Este enfoque contribuye significativamente a la seguridad del sistema, ya que garantiza que solo aquellos con conocimiento de la llave puedan acceder y recuperar la información incrustada de manera precisa.

- Combinar el mapa de características (imf) con la estego-imagen (MS) mediante una operación lógica XOR para recuperar la marca de agua (Wr), como se describe en la Ecuación 13.

$$Wr = imf \oplus MS \quad (13)$$

- Clasificar la marca de agua extraída mediante la red neuronal para comprobar si es la marca de agua utilizada para la generación de la estego-imagen.




Figura 6. Recuperación de la marca de agua.

V Resultados

Los experimentos realizados tienen como objetivo evaluar la eficiencia y robustez del sistema en términos de recuperación de la marca de agua con la menor cantidad de errores posible. Los resultados se presentan en las Figuras 7, 8 y 9 mostrando el BER, el SSIM y NCC, respectivamente. Además, para demostrar la robustez del sistema de marca de agua y propuesto, se llevaron a cabo pruebas mediante la aplicación de

diversos ataques geométricos, así como ataques de procesamiento de imagen. También se comparó la eficiencia del algoritmo utilizando dos bases de imágenes distintas para demostrar la versatilidad del sistema en diversas aplicaciones. Estos experimentos y comparaciones demuestran la capacidad del sistema para recuperar la marca de agua íntegra en diversas condiciones y con diferentes conjuntos de datos de entrada.




Figura 7. BER a) transformaciones geométricas, b) procesamiento de imágenes.

Las gráficas en la Figura 7 proporcionan los valores promedio del BER obtenidos al aplicar diferentes ataques geométricos y de procesamiento de imágenes. Los resultados demuestran que el sistema tiene un bajo promedio de error, siendo inferior a 0.005

para imágenes naturales y de 0.006 para imágenes médicas. Esto indica que la red neuronal propuesta es altamente eficiente en la recuperación de la marca de agua, prácticamente sin errores.




Figura 8. NCC a) transformaciones geométricas, b) procesamiento de imágenes.

En la Figura 8, demuestra que la marca de agua recuperada es altamente similar a la marca original, ya que el promedio de la NCC es mayor a 0.9940 para imágenes naturales y mayor a 0.9902 para imágenes

médicas. Lo anterior resalta la capacidad del sistema para mantener la integridad de la marca de agua incluso después de ataques de procesamiento de imagen.








Figura 9. SSIM a) transformaciones geométricas, b) procesamiento de imágenes.

Finalmente, en la Figura 9 se compara la similitud estructural, incluyendo cambios en la luminosidad de la imagen, donde el SSIM promedio es mayor a 0.9190 para imágenes naturales y mayor a 0.8780 para imágenes médicas. Los resultados confirman la capacidad del sistema para preservar la

estructura y calidad de la imagen original en presencia de diversas transformaciones. En conjunto, estos hallazgos respaldan la eficiencia y robustez del sistema de marca de agua propuesto en una variedad de situaciones y conjuntos de datos.

Tabla 4. Comparación de la marca de agua original y la marca de agua recuperada.

Ataque	Rotación	Traslación	Escalamiento	Recorte
Marca de Agua Original				
Marca de Agua Recuperada				
Ataque	Adición de Ruido	Compresión JPEG 70	Compresión JPEG 30	Filtro Gaussiano
Marca de Agua Original				
Marca de Agua Recuperada				

Marca de Agua Recuperada				
Ataque	Recorte Superior	Filtro Mediana	Histogram Equalization	Transformada Affine
Marca de Agua Original				
Marca de Agua Recuperada				

En la Tabla 4 se presenta una comparación entre la marca de agua recuperada y la marca de agua original, lo que permite evidenciar la similitud entre ambas imágenes. Los resultados muestran que la marca de agua recuperada es altamente similar a la marca de agua original, demostrando que existe una

pérdida mínima de información en el proceso de extracción y validación de la marca de agua. La similitud evidencia la efectividad del sistema en la preservación de la integridad de la marca de agua durante su recuperación.




Figura 10. a) Tiempo de entrenamiento, b) tiempo de detección de características para recuperar la marca de agua.

La Figura 10a muestra el tiempo necesario para el entrenamiento y aprendizaje de las

características específicas de cada imagen. En contraste, la Figura 10b representa el

tiempo de procesamiento requerido para la extracción de características y la recuperación de la marca de agua. Es evidente que el tiempo empleado para recuperar la marca de agua es muy bajo,

siendo en promedio inferior a 0.5 segundos. Esto indica que el costo computacional del sistema es aceptable en relación con su eficacia demostrada.




Figura 11. Eficiencia de la red neuronal al clasificar la marca de agua.

La Figura 11 muestra la eficiencia de la red neuronal al clasificar la marca de agua recuperada, obteniendo un valor promedio mayor a 0.96, demostrando un índice alto al

determinar si la marca de agua recuperada es similar a la utilizada para la generación de la estego-imagen.

Tabla 5. Comparativa con métodos reportados previamente.

	Xing et al. [13]	Han et al. [18]	Li et al. [15]	Zhong [25]	Quan [26]	Fei [27]	Método Propuesto
Técnica Usada	Combina características de coeficientes en frecuencias de la DCT y DFT con la marca de agua para un marcado de agua libre de distorsiones.	Combina características extraídas por una red neuronal VGG19, para un marcado de agua libre de distorsiones.	Combinan las características extraídas mediante un algoritmo KAZE con la marca de agua, para un marcado de agua libre de distorsiones.	Utiliza una red neuronal para generalizar las características de las imágenes y detectar la zona de inserción.	La red neuronal detecta las características de la imagen donde se realizará la inserción de la marca de agua.	Utiliza la función de pérdida de la red generativa para la inserción de la marca de agua.	Combina características extraídas por una red neuronal con la marca de agua generada a partir de las características de los bordes de la imagen.
Tamaño Marca de Agua	128 x 128	64 x 64	32 x 32	32 x 32	40 x 40	Una marca de agua de 100 bits	256 x 256
Tipo de Imagen	Sensado remoto	Médica	Médica	Naturales	Naturales	Generadas	Naturales y médicas
Métrica para evaluar	Correlación normalizada	Correlación normalizada, Promedio de ruido en la imagen recuperada (PSNR)	Correlación normalizada, Promedio de ruido en la imagen recuperada (PSNR)	Promedio de bit erróneos	Correlación normalizada	Promedio de bit erróneos	Correlación normalizada cruzada, promedio de bits erróneos e índice de similitud estructural
Distorsiones geométricas							
Rotación	NC = 0.882	NC = 0.94054 PSNR =	NC = 1 PSNR = 18.44	---	---	---	BER = 0.0051 NC = 0.9910

		26.647					SSIM = 0.9195
Traslación	---	---	NC = 0.96	---	---	---	BER = 0.0052 NC = 0.9923 SSIM = 0.9195
Escalamiento	---	---	NC = 1 PSNR = 13.98	---	---	---	BER = 0.0050 NC = 0.9916 SSIM = 0.9195
Recorte	NC = 0.953	NC = 0.93826 PSNR = 26.561	---	BER = 0.1	---	---	BER = 0.0052 NC = 0.9914 SSIM = 0.9193
Transformada Affine	---	---	---	---	---	---	BER = 0.0050 NC = 0.9917 SSIM = 0.9194
Procesamiento de imágenes							
Compresión JPEG	---	---	NC = 0.96 PSNR = 35.14	BER = 0.1	NC = 0.9915	BER = 0.90	BER = 0.0050 NC = 0.9917 SSIM = 0.9193
Ecuilización de Histograma	NC = 0.85	---	---	---	NC = 0.9953	BER = 0.80	BER = 0.0061 NC = 0.9901 SSIM = 0.9189
Filtro de Mediana	NC = 0.986	---	---	---	NC = 0.9953	---	BER = 0.0050 NC = 0.9947 SSIM = 0.9193
Filtro Gaussiano	NC = 0.986	---	NC = 0.86 PSNR = 22.01	BER = 0.1	NC = 0.9953	BER = 0.90	BER = 0.0048 NC = 0.9947 SSIM = 0.9196
Emborramiento	---	---	---	---	NC = 0.9953	---	BER = 0.0047 NC = 0.9948 SSIM = 0.9196
Adición de Ruido Gaussiano	NC = 0.942	---	---	BER = 0.5	---	---	BER = 0.0050 NC = 0.9945 SSIM = 0.9194

La Tabla 5 proporciona una comparativa entre el método propuesto y algunos métodos previamente reportados. Uno de los aspectos destacados del método propuesto es el tamaño de la marca de agua, que es significativamente más grande que las utilizadas en otros métodos. Además, el enfoque emplea diversas métricas de evaluación, lo que brinda una perspectiva más completa de la eficiencia del sistema en comparación con los métodos anteriores. Los valores obtenidos en estas métricas se encuentran detallados en las respectivas publicaciones.

Una de las principales desventajas del sistema propuesto es la necesidad de almacenar tanto la estego-imagen como los pesos obtenidos durante el entrenamiento para la detección de la marca de agua. Sin embargo, es importante destacar que el método ha sido sometido a pruebas exhaustivas con diversos ataques, lo que demuestra su robustez ante diferentes

manipulaciones. El análisis de los resultados confirma que la marca de agua se recupera con un error muy bajo, obteniendo una alta similitud entre la marca de agua original y la recuperada. Dichos resultados demuestran la efectividad y robustez del sistema propuesto para proteger la propiedad intelectual de las imágenes en diversas situaciones y condiciones.

Aunque se debe realizar el almacenamiento adicional de los pesos obtenidos en el entrenamiento para el aprendizaje de las características de cada imagen, la eficiencia del sistema y su robustez ante diferentes distorsiones y procesamiento de imagen respaldan su viabilidad y eficacia en aplicaciones donde la calidad de la imagen y la seguridad de la marca de agua son esenciales.

VI Conclusiones

El algoritmo de marcado de agua propuesto para imágenes digitales demuestra ser

altamente efectivo en la protección de imágenes sin comprometer su calidad. Una contribución significativa de este método radica en su eficacia, fundamentada en el empleo de una red neuronal de pesos compartidos para la extracción de características y clasificación de la marca de agua. Esta red, entrenada con un conjunto de imágenes manipuladas que incluyen diversas distorsiones y procesamientos, confiere robustez al sistema al enfocarse en la detección y extracción de las características más relevantes de las imágenes.

El uso de técnicas de aumento de datos en el entrenamiento contribuye a mitigar errores en la extracción de características para la detección de la marca de agua. Esto ayuda a la red neuronal a identificar y aprender características únicas incluso en condiciones al alterar las imágenes. Por otro lado, la inclusión de imágenes distorsionadas en el conjunto de datos de entrenamiento mejora la eficiencia del modelo para la extracción de características referentes a las imágenes para recuperar la marca de agua de manera eficiente.

Una red neuronal con pesos compartidos permite aprender características significativas e invariantes tanto para la generación de la estego-imagen como para la clasificación de la marca de agua. La red neuronal se centra en la identificación de características únicas para cada imagen. Compartir información entre las dos ramas de la red neuronal favorece una generalización más efectiva de las representaciones de cada imagen, lo que resulta en modelos más robustos y eficientes. Esta estrategia conduce a modelos más robustos y eficientes, ya que la red puede aprovechar la información aprendida durante el entrenamiento en un conjunto de datos para mejorar el rendimiento en otro conjunto de datos relacionado.

Los resultados experimentales respaldan la eficacia del sistema, con un bajo BER promedio inferior a 0.006, indicando una resistencia a distorsiones geométricas y procesamientos de señales avanzados. Además, los valores obtenidos en las métricas NC y SSIM sugieren una alta similitud entre la marca de agua recuperada y la original, evidenciando la capacidad del sistema para recuperar la marca de agua de manera precisa.

La incorporación de sistemas de inteligencia artificial, como las redes neuronales, en la protección de imágenes mediante marcas de agua libres de distorsiones, ofrece una contribución importante ya que se evidencia un aumento de la eficiencia y a la reducción de errores en la extracción y recuperación de marcas de agua. Este enfoque demuestra ser altamente efectivo en diversas aplicaciones donde la calidad de la imagen y la integridad en la recuperación de la marca de agua son de suma importancia. Resaltando que no solo se enfoca en un tipo específico de imágenes, siendo una ventaja en comparación a los métodos propuestos en diversas publicaciones.

VII Agradecimientos

Al Consejo Nacional de Humanidades, Ciencia y Tecnología y al Instituto Politécnico Nacional por el apoyo brindado para el desarrollo de esta investigación.

VIII Referencias

- [1] W. Wan, J. Wang, Y. Zhang, J. Li, H. Yu y J. Sun, "A comprehensive survey on robust image watermarking", *Neurocomputing*, vol. 488, 2022, pp. 22-24, doi: <https://doi.org/10.1016/j.neucom.2022.02.083>.
- [2] P. Aparna y P. V. V. Kishore, "A Blind Medical Image Watermarking for Secure E-Healthcare Application Using Crypto-Watermarking System", *Journal of*

- Intelligent Systems*, vol. 29, n° 1, pp. 1558-1575, 2020, doi: <https://doi.org/10.1515/jisys-2018-0370>.
- [3] M. Magdy, N. Ghali, S. Ghoniemy y K. Hosny, "Multiple Zero-Watermarking of Medical Images for Internet of Medical Things", *IEEE Access*, vol. 10, pp. 38821-38831, 2022, doi: <https://doi.org/10.1109/ACCESS.2022.3165813>.
- [4] O. P. Singh, K. Singh y G. Srivasta, "Image watermarking using soft computing techniques", *Multimedia Tools and Applications*, 2020, pp. 30367-30398, doi: <https://doi.org/10.1007/s11042-020-09606-x>.
- [5] S. Xing, Z. Cheng, C. Y. Ji, J. Chen y L. Qi, "Remote Sensing Image Zero-Watermarking Algorithm Based on Bemd", *Journal of Physics: Conference Series*, vol. 1865, 2021, doi: <https://doi.org/10.1088/1742-6596/1865/4/042035>.
- [6] M. Abdullad, A. Ismail y A. Abubakar, "Imperceptibility Analysis for Watermaking Technique Based on Image Block Division Scheme," *International Multi-Conference on Systems, Signals & Devices*, Tunasia, 2021, doi: <https://doi.org/10.1109/SSD52085.2021.9429305>.
- [7] N. Jimson y K. Hemachandran, "DFT Based Coefficient Exchange Digital Image Watermarking," in *Conference on Intelligent Computing and Control Systems*, Madurai, India, 2018, doi: <https://doi.org/10.1109/ICCONS.2018.8663122>.
- [8] Y. Guanghai y Q. Hao, "Digital watermarking secure scheme for remote sensing image protection," *China Communications*, vol. 17, no. 4, pp. 88-98, 2020, doi: <https://doi.org/10.23919/JCC.2020.04.009>.
- [9] Z. Yuan, D. Liu, X. Zhang, H. Wang y Q. Su, "DCT-based color digital image blind watermarking method with variable steps", *Multimedia Tools and Applications*, vol. 2020 n° 79, pp. 30557–30581, 2020, doi: <https://doi.org/10.1007/s11042-020-09499-w>.
- [10] B. Ram, "Digital Image Watermarking Technique Using Discrete Wavelet Transform and Discrete Cosine Transform". *SSRN*, doi: <http://dx.doi.org/10.2139/ssrn.4173742>.
- [11] M. Veni y T. Meyyappan, "Digital image Watermark embedding and extraction using oppositional fruit Fly algorithm", *Multimedia Tools and Applications*, vol. (2019), n°78, pp. 27491–27510, 2019, doi: <https://doi.org/10.1007/s11042-019-7650-0>.
- [12] L. Jing, Z. Sun, K. Chen, X. Wen y X. Cheng, "Remote Sensing Image Zero Watermarking Algorithm Based on DFT", *Journal of Physics: Conference Series*, vol. 16865, 2021, doi: <https://doi.org/10.1088/1742-6596/1865/4/042034>.
- [13] S. Xing, T. Y. Li y J. Liang, "A Zero-Watermark Hybrid Algorithm for Remote Sensing Image Based on DCT and DFT", *Journal of Physics: Conference Series*, vol. 1952, 2021, doi: <https://doi.org/10.1088/1742-6596/1952/2/022049>.
- [14] Y Fang, J. Liu, J. Li1, J. Cheng, J. Hu, D. Yi, X. Xia y U. A. Bhatti, "Robust zero-watermarking algorithm for medical images based on SIFT and Bandelet-DCT", *Multimedia Tools and Applications*, vol. (2022), n° 81, pp. 16863–16879, doi: <https://doi.org/10.1007/s11042-022-12592-x>.
- [15] D. Li, Y. Chen, J. Li, L. Cao, U. A. Bhatti y P. Zhang, "Robust watermarking algorithm for medical images based on accelerated-KAZE discrete cosine

transform”, *IET Biometrics*, 2022, doi: <https://doi.org/10.1049/bme2.12102>.

[16] Q. Zhang, J. Lu y Y. Jin, “Artificial intelligence in recommender systems”, *Complex & Intelligent Systems volume*, vol. 7, 2021, p. 439–457, doi: <https://doi.org/10.1007/s40747-020-00212-w>.

[17] I. Hamamoto y M. Kawamura, “Image Watermarking Technique Using Embedder and Extractor Neural Networks”, *IEICE Transactions on Information and Systems, Special Section on Enriched Multimedia - Making Multimedia More Convenient and Safer*, vol. E102.D, n° 1, 2019, pp. 19-30, doi: <https://doi.org/10.157/transinf.2018MUP0006>.

[18] B. Han, J. Du, Y. Jia y H. Zhu, “Zero-Watermarking Algorithm for Medical Image Based on VGG19 Deep Convolutional Neural Network”, *Journal of Healthcare Engineering*, vol. 2021, doi: <https://doi.org/10.1155/2021/5551520>.

[19] C. Gong, J. Liu, M. Gong, J. Li, U. A. Bhatti y J. Ma, “Robust medical zero-watermarking algorithm based on Residual DenseNet”, *IET Biometrics*, 2022, doi: <https://doi.org/10.1049/bme2.12100>.

[20] S. A. Nawaz, J. Li, M. U. Shoukat, U. A. Bhatti y M. A. Raza, “Hybrid medical image zero watermarking via discrete wavelet transform-ResNet101 and discrete cosine transform”, *Computers and Electrical Engineering*, n°112, vol. 108985, 2023, doi: <https://doi.org/10.1016/j.compeleceng.2023.108985>.

[21] T. Huang, J. Xu, S. Tu y B. Han, “Robust zero-watermarking scheme based on a depthwise overparameterized VGG network in healthcare information security”, *Biomedical Signal Processing and Control*, n° 81, vol. 104478, 2023, doi: <https://doi.org/10.1016/j.bspc.2022.104478>.

[22] D. Li, J. L. U. A. Bhatti, S. A. Nawaz, J. Liu, Y. W. Chen y L. Cao, “Hybrid Encrypted Watermarking Algorithm for Medical Images Based on DCT and Improved DarkNet53”, *Electronics*, n° 12, vol. 1554, 2023, doi: <https://doi.org/10.3390/electronics12071554>.

[23] F. Dong, J. Li, U. A. Bhatti, J. Liu, Y. W. Chen y D. Li, “Robust ZeroWatermarking Algorithm for Medical Images Based on Improved NasNet-Mobile and DCT”, *Electronics*, n° 12, vol. 3444, 2023, doi: <https://doi.org/10.3390/electronics12163444>.

[24] A. N. Fierro, M. Nakano, M. Cedillo-Hernandez, L. Cleofas-Sanchez y H. M. Pérez, “A Robust Image Zero-watermarking using Convolutional Neural Networks”, 2019 7th International Workshop on Biometrics and Forensics (IWBF), Cancun, Mexico, 2019, doi: 10.1109/IWBF.2019.8739245.

[25] X. Zhong, P-C. Huang, S. Mastorakis y F. Y. Shih, “Automatend and Robust Image Watermarking Scheme Based on Deep Neural Networks”, *IEEE Transactions on Multimedia*, vol. 23, 2021, doi: 10.1109/TMM.2020.3006415.

[26] Y. Quan, H. Teng, Y. Chen y H. Ji, “Watermarking Deep Neural Networks in Image Processing”, *IEEE Transactions on Neural Networks and Learning Systems*, vol. 32, n° 5, 2021, doi: 10.1109/TNNLS.2020.2991378.

[27] J. Fei, Z. Xia, B. Tondi, M. Barni, “Supervised GAN Watermarking for Intellectual Property Protection”.

[28] “Kaggle”. Available: <https://www.kaggle.com/datasets/prasunroy/natural-images?resource=download>. [Último acceso: 25 01 2023], Roy, Prasun, Ghoshm Subhankar Bhattacharya, Saumik and Pal,” Effects of Degradations on Deep Neural

Network Architectures”, preprint arXiv:1807.10108, 2018.

[29] “Medical Segmentation Decathlon”, [En línea]. Available: <http://medicaldecathlon.com/>. [Último acceso: 24 07 2023]. Amber L. Simpson, Michela Antonelli, Spyridon Bakas, Michel Bilello, Keyvan Farahani, Bram van Ginneken, Annette Kopp-Schneider, Bennett A. Landman, Geert Litjens, Bjoern Menze, Olaf Ronneberger, Ronald M. Summers, Patrick Bilic, Patrick F. Christ, Richard K. G. Do, Marc Gollub, Jennifer Golia-Pernicka, Stephan H. Heckers, William R. Jarnagin, Maureen K. McHugo, Sandy Napel, Eugene Vorontsov, Lena Maier-Hein, M. Jorge Cardoso, “A large annotated medical image dataset for the development and evaluation of segmentation algorithm, 2019, doi: <https://doi.org/10.48550/arXiv.1902.09063>

[30] R. P. Naik, U. S. Acharya, S. Lal y P. Krishnan “Performance investigation of underwater wireless optical system for image transmission through the oceanic turbulent optical medium”, *Optical and Quantum Electronics*, vol. 54, n° 251, 2022, doi <https://doi.org/10.1007/s11082-022-03611-0>.

[31] L. Yu, S. Feng, B. Liang y X. Chen, "High-precision Solar Image Registration Using Normalized Cross-correlation and Intensity", *2021 40th Chinese Control Conference (CCC)*, Shanghai, China, pp. 3253-3257, 2021, doi: [10.23919/CCC52363.2021.9550094](https://doi.org/10.23919/CCC52363.2021.9550094).

[32] A.N. Omara, Tarek M. Salem, Sherif Elsanadily, M.M. Elsherbini, “SSIM-based sparse image restoration”, *Journal of King Saud University - Computer and Information Sciences*, vol. 34, n° 8, Part B, pp. 6243-6254, 2022, doi: <https://doi.org/10.1016/j.jksuci.2021.07.024>.

[33] M. Fullan, J. Quinn y J. McEachen, “Deep learning engage the world change the world”, Thousands Oaks, California: Corwin, 2018.

[34] M. Ekman, “Learning deep learning: Theory and practice of neural networks, computer vision, natural language processing, and transformers using tensorflow”, *Boston: Nvidia*, 2022.

[35] A. Krizhevsky, I. Sutskever, G. Hinton, “Imagenet classification with deep convolutional neural networks,” *Communications of the ACM*, vol. 60, n° 6, 2017, p. 84–90, doi: <https://doi.org/10.1145/3065386>.

[36] A. N. Fierro, M. Nakano, H. M. Pérez y K. Yanai, “Redes Convolucionales Siamesas y Tripletas para la Recuperación de Imágenes Similares en Contenido”, *Información tecnológica*, 2019, doi: <http://dx.doi.org/10.4067/S0718-07642019000600243>.