


12<sup>o</sup>  
ANIVERSARIO

RIIT Científica  
Bimestre Marzo-Abril 2024  
Vol. 12, No. 67



### Trading de criptomonedas mediante algoritmos de aprendizaje por refuerzo profundo y aprendizaje automático

Valdez-Rivera, W., Saucedo-Zendejo, F.R., Navarro-Acosta, J.A., Musi-Gutiérrez, J.



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

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



### Robot móvil interactivo para el aprendizaje de ángulos con alumnos de primaria

Soria-López, A., Silva-Ochoa, H., Ojeda-Misses, M.A.




### A versatile educational tool to detect adulterated honey with Arduino and Python-OpenCv

Sifuentes-Gallardo, C., Hernández-Ortiz, M., Ortega-Sigala, J., Rodríguez-González, B., Cardoso-Pérez, M., Esquivel-Félix, R., Guirette-Barbosa, O., Cruz-Domínguez, O., Durán-Muñoz, H.



### Toxicity essays and photoprotective effects of partitions of *Euphorbia tirucalli* L.

García-Hernández, D.G., Cabanillas-Lomelí, M.L., Tijerina-Saéñz, A., Vargas Pérez, M.P., González Luna, A.R., Heya, M.S.



### **Cintillo Legal**

**RIIT REVISTA INTERNACIONAL DE INVESTIGACIÓN E INNOVACIÓN TECNOLÓGICA**, Vol. 12, No. 67. Marzo - Abril 2024, es una publicación bimestral editada y publicada por **Universidad Autónoma de Coahuila**, boulevard Venustiano Carranza s/n colonia República Oriente, C.P. 25280, Saltillo, Coahuila, Tel. (844) 414 85 82, <https://riit.com.mx/>, correo electrónico: [publicacionesriit@uadec.edu.mx](mailto:publicacionesriit@uadec.edu.mx). Editor responsable: **Dra. Antonia Mtz.** Reserva de Derechos al Uso Exclusivo No. 04-2022-021512364600-102, ISSN: 2007-9753, ambos otorgados por el Instituto Nacional del Derecho de Autor. Responsable de la última actualización de este número, Departamento de Divulgación y Comunicación Digital de la Dirección de Investigación y Posgrado de la UAdeC, Q.F.B. **Fernando García**, Edificio “D” planta alta, unidad Camporredondo, Saltillo, Coahuila, C.P. 25280, Tel. (844) 414 85 82, fecha de última modificación: 01 Marzo 2024.

Las opiniones expresadas por los autores no necesariamente reflejan la postura del editor de la publicación.

Queda prohibida la reproducción total o parcial de los contenidos e imágenes de la publicación sin previa autorización de Universidad Autónoma de Coahuila.

### **Tabla de Contenido**

<b>Título artículo/ Autores</b>	<b>Páginas</b>
<b>Trading de criptomonedas mediante algoritmos de aprendizaje por refuerzo profundo y aprendizaje automático</b> Valdez-Rivera, W., Saucedo-Zendejo, F.R., Navarro-Acosta, J.A., Musi-Gutiérrez, J.	1 – 15
<b>Sistema de marcado de agua cero para imágenes digitales basados en redes neuronales</b> Arevalo-Ancona, R.E., Cedillo-Hernández, M., Ramírez-Rodríguez, A.E., Nakano-Miyatake, M., Pérez-Meana, H.M.	16 – 39
<b>Robot móvil interactivo para el aprendizaje de ángulos con alumnos de primaria</b> Soria-López, A., Silva-Ochoa, H., Ojeda-Misses, M.A.	40 – 56
<b>A versatile educational tool to detect adulterated honey with Arduino and Python-OpenCv</b> Sifuentes-Gallardo, C., Hernández-Ortiz, M., Ortega-Sigala, J., Rodríguez-González, B., Cardoso-Pérez, M., Esquivel-Félix, R., Guirette-Barbosa, O., Cruz-Domínguez, O., Durán-Muñoz, H.	57 – 69
<b>Toxicity essays and photoprotective effects of partitions of <i>Euphorbia tirucalli</i> L.</b> García-Hernández, D.G., Cabanillas-Lomelí, M.L., Tijerina-Saénez, A., Vargas Pérez, M.P., González Luna, A.R., Heya, M.S.	70– 82



## Revista Internacional de Investigación e Innovación Tecnológica

Página principal: [www.riit.com.mx](http://www.riit.com.mx)

### Trading de criptomonedas mediante algoritmos de aprendizaje por refuerzo profundo y aprendizaje automático

### Cryptocurrency trading using deep reinforcement learning and machine learning algorithms

Valdez-Rivera, W.<sup>a</sup>, Saucedo-Zendejo, F.R.<sup>a</sup>, Navarro-Acosta, J.A.<sup>a\*</sup>, Musi-Gutiérrez, J.<sup>b</sup>

<sup>a</sup> Centro de Investigación en Matemáticas Aplicadas, Universidad Autónoma de Coahuila. Unidad Saltillo, 25020, Saltillo, Coahuila, México.

<sup>b</sup> Facultad de Sistemas, Universidad Autónoma de Coahuila. Unidad Saltillo, 25350, Arteaga, Coahuila, México.  
[wbaldo\\_valdez@uadec.edu.mx](mailto:wbaldo_valdez@uadec.edu.mx), [fesaucedoz@uadec.edu.mx](mailto:fesaucedoz@uadec.edu.mx), [alejandro.navarro@uadec.edu.mx](mailto:alejandro.navarro@uadec.edu.mx)<sup>\*</sup>,  
[jmusi@uadec.edu.mx](mailto:jmusi@uadec.edu.mx)

**Innovación Tecnológica:** Tecnología para la adopción y uso de criptomonedas.

**Área de aplicación industrial:** Transacciones bancarias, educación, entre otras.

Recibido: 05 septiembre 2023

Aceptado: 07 febrero 2024

#### Abstract

The aim of this article is to perform a comparison of the performance of machine learning and deep reinforcement learning algorithms for buying and selling cryptocurrencies based on price prediction. This is done by training and testing such models using daily data spanning the period from 2017-11-09 to 2022-05-01 and was downloaded from Yahoo finance page in their cryptocurrency section. It is observed that machine learning algorithms have high accuracy metrics in their predictions and execute quickly, although they do not result in high return on investment, nor do they surpass deep reinforcement learning in this regard.

**Keywords:** machine learning, cryptocurrencies, trading, reinforcement learning

## Resumen

El objetivo de este artículo es realizar una comparación del desempeño de algoritmos de aprendizaje automático y de aprendizaje por refuerzo profundo para la compra y venta de criptomonedas basándose en la predicción de precios. Esto se lleva a cabo mediante el entrenamiento y prueba de dichos modelos usando información diaria que abarca el periodo del 2017-11-09 al 2022-05-01 y fue descargada de la página de Yahoo finance en su sección de criptomonedas. Se observa que los algoritmos de aprendizaje automático tienen métricas de precisión altas en sus predicciones y se ejecutan de forma rápida, aunque no resultan en alto retorno de la inversión, ni tampoco sobrepasan al aprendizaje por refuerzo profundo en este sentido.

**Palabras clave:** aprendizaje automático, criptomonedas, trading, aprendizaje por refuerzo.

## I. Introducción

Las criptomonedas son un medio de cambio que se utiliza para realizar transacciones financieras, estas comparten tres características comunes: descentralización, pseudoanonimato y transparencia. Están descentralizadas en el sentido de que, en lugar de estar gobernados por una sola institución, se administran a través de una red de igual a igual, la mayoría de las cuales deben acordar qué transacciones son válidas. La seguridad en sus transacciones está basada en su criptografía, de donde heredan su nombre de criptomonedas (Trozze, 2022). Actualmente la criptomoneda con el mayor valor de capitalización, más establecida y estudiada es el Bitcoin. El uso del Bitcoin ha crecido vastamente en los últimos años como un activo financiero más que solo como una herramienta para transacciones (Sabry et al., 2020). En la actualidad existen más de 10 mil monedas y hasta 20,325 mercados para la transacción de estas (Soni, 2021). Para el 3 de noviembre del 2021 la capitalización total del mercado alcanzo un nuevo récord histórico de \$2.8 billones de dólares, con casi \$1 billón de dólares agregados en poco más de un mes. Por lo tanto, el número de instituciones financieras que incluyen criptomonedas en sus portafolios de inversión ha ido en aumento en los años recientes. Un ejemplo de esta tendencia es el caso de Indonesia, donde

el ministerio de comercio reporta que de 2020 a 2021 se incrementó en un 50% el número de personas invirtiendo en criptomonedas (Restuputri et al., 2023). En el ámbito académico, se ha observado que aproximadamente un 85% de los artículos de investigación existentes sobre el trading de criptomonedas han sido escritos apenas desde el 2018, siendo el trading la compra y venta de activos cotizados (acciones, divisas y futuros) con el fin de obtener ganancias (Bancomer, 2021). En este sentido, para llevar a cabo la optimización dinámica de un portafolio de inversión se ha demostrado que las redes neuronales recurrentes (RNN) y las redes de gran memoria de corto plazo (LSTM) muestran un mejor desempeño que la media móvil integrada autorregresiva (ARIMA) (McNally et al., 2018). Para este propósito también se propuso un multi agente basado en una red Double Q - Learning, y en una red de Double Dueling Q - Learning con el cual se obtuvieron mejores resultados con respecto a la técnica de comprar y mantener (Buy and Hold) en términos de acumulación de ganancias (Patel, 2018). En (Kolla, 2020) se hizo uso de RNN con LSTM mostrando que el precio de los activos podía ser predicho con una alta precisión y los resultados de la predicción se compararon con regresión lineal y RNN usando células LSTM. En general, las aproximaciones con aprendizaje

profundo son bastante comunes, y se tienen casos de estudio con Deep Q Learning (DQN) (Gu et al., 2016) y Deep Boltzmann Machine (DBM) (Salakhutdinov and Hinton, 2009). Por otro lado, existen otras aproximaciones para el manejo de un portafolio de inversión. En (Alessandretti et al., 2018) se aplicaron árboles de decisión para la potenciación del gradiente (XGBoost) y una red LSTM en un portafolio de criptomonedas, donde ambas generaron ganancias en todo el período de prueba. Por su parte (Jiang and Liang, 2017) aplicó una política de gradiente determinista usando una función de recompensa directa para resolver el problema del manejo del portafolio donde se obtuvieron buenos resultados en términos de ganancia acumulada. En otro aporte (Liang et al., 2018) se propone adaptar tres versiones del aprendizaje por refuerzo basado en una política de gradiente profunda determinista (DDPG), política de optimización proximal (PPO) y política del gradiente (PG) para el manejo dinámico de un portafolio donde se obtuvieron buenos resultados en la predicción de valores de activos. En otra aproximación (Bu and Cho, 2018) se propuso una combinación de una doble neurona Q y aprendizaje no supervisado pre-entrenado con una máquina de Boltzmann profunda (DBM) para generar y mejorar la función Q óptima con el cual se obtuvieron las más altas ganancias en comparación con los modelos de aprendizaje profundo existentes (LSTM, CNN, MLP). En cuanto al aprendizaje automático clásico existen una variedad de aproximaciones y técnicas utilizadas en el trading que han logrado buenos resultados. En un estudio (Guo and Tuckfield, 2020) se aplicó procesamiento de lenguaje natural utilizando Naive Bayes, Random Forest comparándolo contra el desempeño de redes CNN y LSTM para predecir precios de acciones y de índices donde se concluye que el grado de precisión de las redes solo fue ligeramente mejor. Como detalle final, se muestra que el uso de series de tiempo con

aprendizaje automático (Sen and Mehtab, 2020) muestra ser de las mejores aproximaciones para tratar el aspecto del trading financiero. Sin embargo, las comparaciones entre el desempeño de distintas técnicas usualmente se realizan entre técnicas de deep learning contra los algoritmos de aprendizaje automático. La comparación entre el aprendizaje por refuerzo y los enfoques antes mencionados es una situación no abordada en la literatura investigada hasta el momento. Por lo tanto, el objetivo de este artículo es estudiar estas técnicas contra las de aprendizaje automático, para tratar de determinar cuál enfoque presenta un mejor desempeño (retorno de inversión), las posibles causas de estos resultados y la conveniencia de aplicar uno u otro enfoque, con lo cual se brindará información importante y original para esta área de estudio. La estructura de este artículo es como sigue: La sección II presenta las técnicas computacionales y el equipo utilizado para este estudio, la Sección III brinda una descripción de la metodología experimental empleada en este artículo, la sección IV presenta los resultados obtenidos y su discusión correspondiente, mientras que algunas conclusiones son presentadas en la sección V.

## II. Técnicas y equipo

La ejecución del código se desarrolló en una computadora con sistema operativo Windows 10 de 64 bits, procesador Intel(R) Core (TM) i5-9400 CPU de 2.9 GHz con 16 GB de RAM. Los algoritmos fueron implementados en el lenguaje de programación Python (lenguaje de propósito general) haciendo uso de las siguientes librerías:

- Tensorflow: librería de computación matemática, que ejecuta gráficos de flujo de forma eficiente. Estos están formados por operaciones matemáticas representadas sobre nodos, y cuya

entrada y salida es un vector multidimensional o tensor de datos.

- Keras: librería de redes neuronales artificiales de código abierto, y debido a que las redes neurales son un tipo particular de gráfico de flujo de datos, TensorFlow y Keras combinan perfectamente.
- Scikit Learn: librería que acopla algoritmos de clasificación, regresión, clustering y reducción de dimensionalidad. Además, se usa en conjunto con otras librerías como NumPy, SciPy y Matplotlib.

La base de datos utilizada en esta investigación se descargó de Yahoo! Finance, la cual cuenta con una sección especial para las criptomonedas (<https://finance.yahoo.com/crypto/>). Dicha base de datos cuenta con la información diaria de diferentes criptomonedas, por lo que en términos técnicos dicha información corresponde a una serie de tiempo.

### Aprendizaje automático

El aprendizaje automático (Machine Learning) es una rama de la inteligencia artificial, y también puede considerarse un subcampo de ciencias de la computación que basa su estudio en el uso de algoritmos y datos con el objetivo de desarrollar esquemas que imiten la manera en la que aprenden los seres humanos (IBM, 2020). Fue definido en 1950 por el pionero Arthur Samuel como la automatización y mejora del proceso de aprendizaje de las computadoras basadas en sus experiencias sin ser explícitamente programadas para ello, asemejándose al aprendizaje humano y animal (Fradkov, 2020).

Los algoritmos de aprendizaje automático más comunes son:

- **Regresión Ridge (RegR):** La regresión lineal es la técnica estadística más simple y mayormente

usada para modelos predictivos. Esta, brinda una ecuación donde las características son variables independientes y nuestra variable objetivo es dependiente de estas características **Ec. (1)** (Shubham, 2017).

$$y = X\beta + \epsilon \quad (\text{Ec. 1})$$

Donde  $X$  son las variables,  $\beta$  son los parámetros de dichas variables y  $\epsilon$  es error distribuido de forma normal. Los parámetros  $\beta$  son desconocidos y hay que aproximarlos utilizando la técnica de mínimos cuadrados.

Básicamente se busca una recta que minimiza la suma de los residuales cuadrados de las distintas observaciones con respecto a ella, considerando varianzas y sesgos bajos.

- **Random Forest (RF):** Es un algoritmo tanto de clasificación como de regresión. Se basa en la construcción de árboles de decisión en distintas muestras de datos. Toma el voto mayoritario hecho por la predicción de los árboles en el caso de la clasificación y el valor promedio en caso de una regresión (Sruthi, 2021). En general se utilizan técnicas de ensamble, es decir, combinar varios modelos para hacer predicciones en lugar de utilizar un modelo individual. Los tipos de ensamble son (Vadapalli, 2020).

**Bagging:** Son un grupo de modelos también conocidos como embolsado cuyo objetivo es incrementar la precisión y la estabilidad del aprendizaje en donde los agentes aprenden en paralelo unos de otros de forma independiente y posteriormente se determina el resultado más votado o promedio.

**Boosting:** Es también un grupo de modelos, pero funciona de manera diferente a Bagging. En este grupo de modelos el aprendizaje se da de forma adaptativa y secuencial con el objetivo de mejorar secuencialmente las predicciones de los metalgoritmos.

- **XGBoost (XGB):** Extreme Gradient Boosting es un algoritmo de aprendizaje automático para clasificación y regresión basado en árboles de decisión que utiliza un marco de refuerzo de gradiente (Gradient Boosting) (Chen and Guestrin, 2016). El objetivo principal de Gradient Boost es minimizar la función de pérdida añadiendo predictores con mal desempeño mediante un algoritmo de optimización de descenso de gradiente. Tiene tres componentes principales (GreatLearning, 2020):

**Función de pérdida:** Cumple el papel de estimar cual es el mejor modelo para las predicciones utilizando los datos proporcionados.

**Predictores de mal desempeño:** Árboles de decisión que clasifican los datos de peor manera que si fuera de forma aleatoria.

**Modelo aditivo:** Proceso iterativo y secuencial donde se agregan árboles de decisión. Cada iteración, en principio, debe de reducir el valor de la función de pérdida. Se agrega una cantidad de árboles hasta que la pérdida es muy baja o ya no existe una mejora.

### Aprendizaje por refuerzo

El uso de técnicas de aprendizaje por refuerzo se ha extendido a diversas áreas de la ciencia. Este funciona como una intersección entre varias áreas de estudio como las ciencias computacionales, la ingeniería, el aprendizaje

automático, entre otras. El problema en general que resuelve este aprendizaje es el de la toma de decisiones de forma óptima. Los componentes básicos de este aprendizaje son conocidos como agente y entorno. El agente básicamente es un programa cuyo objetivo es la toma de decisiones para alcanzar una meta. Mientras que el entorno es el problema por resolver mediante las decisiones del agente. Existen además elementos adicionales a considerar (Torres, 2021):

- **Estado:** el conjunto de variables que representan al entorno es conocido como espacio de estados (space state). Un estado es un valor particular de ese espacio de variables. Usualmente el agente no tiene disponible todo el espacio de estados, entonces al estado que puede observar se le llama observación.
- **Acción y función de transición:** En cada estado, el entorno pone a disposición un conjunto de acciones (actions space) entre las que el agente puede elegir una utilizando distintos criterios. El agente influye en el medio ambiente a través de estas acciones. El entorno puede cambiar de estado como respuesta a la acción del agente. La función responsable de este mapeo se llama función de transición. El entorno también puede proporcionar una señal de recompensa como respuesta. A esto se le llama función de recompensa. El conjunto de funciones de transición y recompensa se denomina modelo del entorno (Morales, 2019).
- **Recompensa:** Existe una tarea u objetivo definido en un entorno, este puede proporcionar una señal de recompensa (reward) al agente como respuesta a sus acciones. Esta es un mecanismo de incentivo que le dice al agente qué es correcto y qué está mal usando recompensa y castigo. La idea

principal es que los agentes maximicen las recompensas totales (Zhang, 2021).

Las interacciones entre el entorno y el agente se pueden prolongar durante varios ciclos. A cada ciclo se le conoce como iteración. Al conjunto de un estado, acción, recompensa por la acción y estado subsecuente en cada iteración hasta el final se le llama experiencia y se representa como  $s_t, a_t, r_{t+1}, s_{t+1}$  (Torres, 2021). La tarea que el agente que está tratando de resolver puede tener un final o puede ser continua. Cuando se tiene un final se le llama tarea episódica (episodic tasks), cuando no lo tienen son tareas continuas (continuous tasks), y a la secuencia de iteraciones hasta el final de una tarea episódica se le llama episodio (episode). Cuando no se tiene un fin en la tarea, la secuencia de iteraciones se le conoce como trayectoria que se representa del siguiente modo:

$$\tau = (s_0, a_0, r_1, s_1, a_1, r_2, s_2, \dots, a_H, r_{H+1}, s_{H+1}) \quad (\text{Ec. 2})$$

Donde  $H$  es la longitud de la trayectoria conocida como horizonte. En general, los agentes requieren varios episodios para aprender la forma de resolver una tarea. A la suma de las recompensas a través de un episodio se le conoce como retorno (return), valor que debe de ser maximizado por el agente ya que representa el aumento en términos relativos de la inversión inicial.

### Q – Learning

Q-learning es una técnica de aprendizaje automático que pertenece a la familia de algoritmos de aprendizaje por refuerzo y basados en valor. Los algoritmos basados en valor actualizan la función de valor en función de una ecuación, en particular, la ecuación de Bellman (Para detalles ver (Lucarelli and Borrotti, 2020)). Este

algoritmo basa su aprendizaje en el seguimiento de una serie de normas que le indican a los agentes las acciones que deberían ser tomadas bajo determinadas circunstancias, sin requerir adaptaciones para tratar con problemas con recompensas o con transiciones estocásticas, o modelos del entorno. La función  $Q$  usa la ecuación de Bellman y toma dos valores de entrada, los estados  $s$  y las acciones  $a$ . A grandes rasgos los pasos a seguir por Q – learning son:

1. **Inicializar la tabla Q:** con columnas correspondientes a acciones, mientras que las filas corresponden a los diferentes estados (Fig. 1).
2. **Elegir una acción:** determinar una acción a realizar.
3. **Realizar la acción:** los pasos 2 y 3 son realizados de forma indefinida hasta que el entrenamiento se detiene. Una acción  $a$  se elige en un estado  $s$  basado en la tabla  $Q$ , al inicio todos los valores deben de ser 0. Después se va a actualizando según la ecuación de Bellman.
4. **Medir la recompensa:** después de realizada una acción, se observa un resultado y se obtiene una recompensa.
5. **Actualizar la tabla Q:** Esto se hace actualizando la función  $Q$ , maximizándola (Ec. (3)). En este caso, la función  $Q$  regresa la recompensa futura esperada de dicha acción en el estado actual:

$$Q(s, a)_{nuevo} = Q(s, a)_{actual} + \alpha [R(s, a) + \gamma(\max_{a'} Q^j(s^j, a^j) - Q(s, a)_{actual})] \quad (\text{Ec. 3})$$

Donde  $\alpha$  es la tasa de aprendizaje, con valores entre 0 y 1. Implica que tanto se actualizan los valores  $Q$ , si es cercano a 0 entonces nunca se actualizan y no se aprende nada, si es cercano a 1 entonces los valores se actualizan rápido y el aprendizaje es alto (DeepRobotics, 2016).

### Deep Q – Learning (DQN)

El algoritmo Q - Learning funciona de forma adecuada cuando el entorno no es muy complejo, y la cantidad de estados y acciones es limitada. Pero cuando dichos valores aumentan, el uso de este algoritmo se vuelve poco conveniente. Con esto en mente, el algoritmo Deep Q-Network o DQN fue desarrollado (Mnih et al., 2015). Este algoritmo constituye una combinación de redes neuronales profundas (Deep Neural Networks) con el algoritmo Q – learning, en el que se utiliza una red neuronal en la aproximación de la función Q con el objetivo de descartar el uso de una tabla para su representación.

Las redes neuronales artificiales (RNA) imitan el funcionamiento de las neuronas cerebrales de los seres vivos, que trabajan y

están conectadas entre sí. La cuales, con entrenamiento y experiencia, crean y refuerzan conexiones para aprender algo (Julian, 2016). Una red neuronal sencilla se compone de tres capas, los valores de entrada (input layer), la capa escondida (hidden layer), y la capa de salida (output layer). En la primera capa se encuentran los valores de entrada en la forma de un vector columna de tamaño  $n$ . La última capa tiene todos los valores de salida posibles con valores entre 0 y 1 representando que tan probable es que cada valor sea cierto. Y finalmente se tiene la capa media, la capa escondida, aquí se realizan las transformaciones de los valores iniciales para dar con el resultado de la capa final. En ocasiones cuando el problema a resolver es complejo, se requiere el uso de una RNA con una estructura más compleja, es decir, una RNA con una cantidad grande de capas ocultas (Fig. 1).




Figura 1. Esquema de neurona con  $n$  capas ocultas (Shukla, 2019).

Estas redes son conocidas como Redes Neuronales Profundas. En general, el aprendizaje profundo se considera como una colección de estrategias usando las propias redes neuronales para la resolución de problemas del aprendizaje automático (Para detalles ver (Torres, 2020)).

En DQN, los estados son los valores de entrada de la neurona, y los resultados son los valores Q de todas las acciones posibles (Gupta, 2018). Los pasos para el desarrollo del algoritmo son los siguientes (Choudary, 2019):

1. Toda la experiencia es guardada.

2. La siguiente acción es determinada por el valor máximo arrojado por la red neuronal.
3. Una vez que se tiene la función objetivo (ecuación de Bellman para DQL):

$$Q(s, a) = R(s, a) + \gamma(\max_{a'} Q(s^j, a')) \quad (\text{Ec. 4})$$

Se calcula la función de pérdida (loss function):

$$L = E[(R(s, a) + \gamma(\max_{a'} Q(s^j, a')) - Q(s, a))^2] \quad (\text{Ec. 5})$$

Que será la función por minimizar con el algoritmo de descenso del gradiente estocástico (Stochastic Gradient Descendent).

Una vez que se ha calculado la pérdida entre los valores objetivos  $Q$  y los valores  $Q$  actuales, se puede hacer retropropagación en la red y actualizar los valores de sesgo  $b$  y los pesos  $W$  (Youngson, 2020).

### III. Métodos experimentales

Para el entrenamiento de los algoritmos de aprendizaje automático, se dividió el conjunto de datos en conjuntos de entrenamiento-validación que abarca el periodo 2017-11-09 al 2021-08-01 obteniendo 1360 registros, mientras que el conjunto de prueba comprende el periodo 2021-08-02 al 2022-05-01 es decir, 273 registros. Posteriormente se utilizaron modelos autorregresivos para pronósticos de series de tiempo. Siendo la autorregresión un modelo de series de tiempo que utiliza observaciones de pasos de tiempo anteriores como valores de entrada a un modelo de regresión para la predicción del valor en el siguiente paso de tiempo (Brownlee, 2021). Se consideraron ventanas de 10 días (lags) antes de la fecha a predecir el valor de cierre de la moneda durante todo el intervalo de

datos de entrenamiento. Además, para evaluar el desempeño de los algoritmos, se hace uso del backtesting sobre el conjunto entrenamiento-validación. La idea detrás de este método es evaluar la precisión de un modelo de pronóstico utilizando datos históricos existentes. El proceso es iterativo y se repite en varias fechas presentes de los datos históricos. Esto es útil para evitar resultados sesgados debido al sobreentrenamiento de los modelos. Los modelos aplicados para la autorregresión fueron la regresión Ridge (RegR), Random Forest (RF) y XGBoost (XGB). Los hiperparámetros de estos modelos se eligieron usando Grid Search (GS). GS es el proceso de ajustar los hiperparámetros para mejorar el desempeño de un modelo determinado, para detalles ver (Lutins, 2017). Para empezar el proceso de trading se consideran únicamente 3 acciones: comprar, vender y mantener. Para este proceso se inicia con la cantidad de 350 dólares de presupuesto para el programa que sigue tres reglas:

1. Si la predicción obtenida es mayor al precio actual de la moneda, y se tiene el dinero suficiente, entonces se compra. Se le resta el precio de la moneda al presupuesto y aumenta en 1 el inventario (que empieza en ceros).
2. Si la predicción obtenida es menor al precio actual de la moneda, y se tiene alguna moneda en el inventario, entonces se vende. Se agrega el precio de venta al presupuesto y disminuye en 1 el inventario.
3. Si ya no se tiene dinero ni monedas en el inventario se acaba la simulación.

Este proceso se realiza con las ventanas de 10 días durante todo el período de prueba (273 días). Durante toda la simulación se mide el tiempo de ejecución, el retorno de inversión (ROI) y el error porcentual cuadrático medio (MAPE). Por lo tanto, se esperan obtener valores altos de ROI con niveles bajos de

MAPE. Esto nos indica que tanto hemos aumentado en términos relativos la inversión inicial. Para garantizar la validez de los resultados la experimentación se realiza 20 veces y se considera el promedio de los valores.

### Configuración experimental para Aprendizaje por refuerzo profundo

Se define a el agente que será el encargado de llevar las transacciones de los activos. Los atributos para el DQN fueron:

- **Tamaño de estados:** Ventana de tiempo para predicciones.
- **Acciones:** Número de acciones a tomar (comprar, vender y mantener).
- **Inventario:** Cantidad de monedas disponibles.
- **Gamma:** Factor de descuento de la ecuación de Bellman.
- **Épsilon:** política codiciosa inicial (porcentaje de veces que se toma una decisión aleatoria).
- **Épsilon final:** Valor final de épsilon.
- **Decaimiento de épsilon:** Tasa de decaimiento del valor (que tanto porcentaje del valor original de conserva tras cada iteración).

Después se describe la arquitectura de la red con un modelo secuencial:

- **Primera capa:** Densamente conectada con 128 neuronas. Función de activación: Relu.
- **Segunda capa:** Densamente conectada con 64 neuronas. Función de activación: Relu.
- **Tercera capa:** Densamente conectada con 32 neuronas. Función de activación: Relu.
- **Cuarta capa:** Capa de activación de salida con la misma cantidad de neuronas que acciones posibles del agente. Función de activación: Lineal.

Se compila el modelo con la función de pérdida del MAPE utilizando el optimizador del gradiente descendiente estocástico (SGD) con una tasa de aprendizaje (learning rate) de 0.001. Se cargan los datos de BNB (2019-01-01 al 2022-05-01) que se utilizarán para entrenar a la red. Con una función se crean los estados que alimentan a la red y los elementos son los siguientes:

- **Dinero:** Inversión inicial.
- **Data:** Datos de los precios de cierre diarios de la moneda a analizar.
- **Timestep:** Fecha en la cual se quiere hacer una predicción.
- **Window size:** Tamaño de la ventana de tiempo (cantidad de días previos a la fecha de predicción para la construcción de estados).


Se define la ventana de tiempo de 10 días, el número de episodios (o epochs) como 20 (cantidad de veces que se recorre todo el data set), el batch size de 32 (datos a analizar antes de retropropagar y ajustar los pesos de la red) y una inversión inicial de 100 dólares. Con esto finalmente se crea el objeto agente para llegar a la parte del bucle de entrenamiento. Se crean los estados correspondientes con las siguientes condiciones para la toma de decisiones:

1. Si la acción seleccionada por la red es 0, entonces se mantiene la posición (no se compra ni se vende nada).
2. Si la acción seleccionada por la red es 1, entonces se compra la moneda. Se añade al inventario y se resta su valor al dinero disponible.
3. Si la acción seleccionada por la red es 2, entonces se vende (considerando que el inventario no está vacío). Para el precio de venta se utiliza el último valor del día y se vende a ese precio. Se agrega el precio de venta al dinero disponible y se le resta una unidad al inventario. La recompensa que se le

- da al agente es la diferencia entre el valor del portafolio actual y el inicial.
4. Si ya no hay dinero ni acciones se acaba el episodio.
  5. Si se llega al último día del set de datos se acaba el episodio.

#### IV. Discusión de Resultados


El primer algoritmo de ML que se puso a prueba es la Regresión Ridge, con hiperparámetros sin ajuste, es decir sin el uso de Grid Search. La Figura 2 muestra las predicciones que dicho algoritmo brinda en comparación con los valores reales de la serie de tiempo (datos de prueba).



**Figura 2.** Predicciones de la regresión Ridge sin Grid Search.

Las métricas que se obtuvieron fueron un R cuadrado de 0.626 y un MAPE de 8.84. Posteriormente se aplica el ajuste de hiperparámetros considerando distintas combinaciones entre los lags y lambda. Para lambda se consideraron 10 valores entre  $10^{-3}$  y  $10^3$  separados de forma uniforme en una escala logarítmica, para los lags se

consideraron distintos valores entre 1 y 20. Los parámetros obtenidos fueron: Lambda de 0.001 y Lags igual a 1. Alcanzando así métricas de R cuadrado de 0.947 y un MAPE de 3.04. Es decir, se lograron obtener mejores métricas. La Figura 3 muestra la mejora en las predicciones del modelo.



**Figura 3.** Predicciones de la regresión Ridge con Grid Search.

Este proceso se ejecuta 20 veces con el fin de corroborar el desempeño del modelo aplicando una estrategia de compra y venta y se obtienen los resultados promedio de tiempo de ejecución de 1.64 segundos, un ROI de 1.4 y MAPE de 3.04. Este mismo proceso se sigue para los algoritmos Random

Forest y XGBoost. Por compacidad la Tabla 1 muestra los resultados de los tres algoritmos de ML al realizar las predicciones, es decir, los hiperparámetros con y sin ajuste (HSA y HCA respectivamente), Así como las mejores métricas obtenidas.

**Tabla 1.** Resultados de los algoritmos.

Técnica		HSA	HCA	Métricas	
RF	# de árboles	100	500	Tiempo	180.33 s
	Prof. Max.	sin	5	MAPE	4.95
	Lags	1	10	ROI	1.38
XGB	# de árboles	100	100	Tiempo	7.64 s
	Prof. Max.	4	4	MAPE	5.75
	Lags	10	10	ROI	0.96
RegR	Lambda	1	0.001	Tiempo	1.64 s
	Lags	10	1	MAPE	3.04
				ROI	1.4
DQN	Configuración descrita en sección III	No aplica		Tiempo	3417 s
				MAPE	1.75
				ROI	60

Elaboración propia.

Como se puede observar los retornos de inversión mayores los brindan los algoritmos de RF y RegR, lo cual es coherente al observar las métricas MAPE de estas técnicas. Sus valores indican que dichos algoritmos tienen una capacidad similar de predicción sobre la serie de tiempo.

A continuación, se procede a implementar el enfoque DQN. El cual presenta un tiempo de ejecución bastante mayor a los algoritmos de ML, cerca del 3000% mayor en comparación con RegR. Sin embargo, este enfoque da un retorno de inversión mayor de alrededor de 40% en comparación con el mejor algoritmo de ML presentado en este trabajo.

Teniendo en cuenta los resultados de todos los algoritmos analizados se puede concluir que las técnicas de aprendizaje automático son estrategias rápidas y seguras para la implementación de algoritmos de trading automatizado de criptomonedas, mientras que los algoritmos de aprendizaje por refuerzo profundo presentan una alternativa atractiva para conseguir retornos de inversión mucho mayores, con un costo computacional y riesgos mayores. Por lo tanto, la elección de la técnica de aprendizaje para un algoritmo de trading automatizado debe estar basada en una estrategia de inversión bien establecida.

## V. Conclusiones

Cómo se puede apreciar en los resultados, el mayor retorno, así como el menor tiempo de ejecución que se obtuvo con los algoritmos de ML los consiguió la regresión Ridge. Considerando estos resultados, entonces este algoritmo (de entre los implementados en las condiciones mostradas) resulta ideal para una estrategia moderada de trading, disminuyendo los riesgos lo máximo posible. Por otro lado, los valores elegidos utilizando la técnica del Grid Search no resultaron en una mejora significativa de los algoritmos, pero no se descarta su uso aplicando otros enfoques de ajuste de hiperparámetros.

En el caso del aprendizaje por refuerzo profundo se obtuvieron muy buenos resultados con la estrategia empleada. Se obtuvieron retornos de hasta 60 veces la inversión inicial. Sin embargo, el costo computacional empieza a hacerse presente en este caso, tomando hasta más de 3500 segundos (casi un día entero) en la ejecución de cada episodio. Si se requiriera ampliar el análisis a más monedas durante un tiempo mayor, y con una mayor cantidad de episodios, el costo computacional es un factor para tener en cuenta. El usar DQN representa una estrategia que en un inicio puede ser algo inestable (con retornos variados de la inversión) y que consume una gran cantidad de recursos, pero que representa un enfoque interesante de implementar debido a los grandes retornos.

Finalmente, todos los resultados anteriores muestran que los algoritmos de aprendizaje pueden ser aplicados exitosamente con fines productivos, específicamente en el sector de trading automatizado de criptomonedas. Sin embargo, estos resultados podrían servir de punto de partida en el análisis de técnicas de aprendizaje automático para el trading automatizado en otros sectores de la economía.

## VI. Referencias

- Alessandretti, L., ElBahrawy, A., Aiello, L. M., & Baronchelli, A. (2018). Anticipating cryptocurrency prices using machine learning. *Complexity*, 2018, 1-16. Accedido 07-03-2021.
- Bancomer, B. (2021). 'trading'? Obtenido de <https://www.bbva.com/es/que-es-trading-que-hace-falta-para-operar/>. Accedido 21-02-2021.
- Brownlee, J. (2017). Autoregression models for time series forecasting with python. *Machine Learning Mastery*, 2(01). Obtenido de <https://machinelearningmastery.com/autoregressionmodels-time-series-forecasting-python/>. Accedido 06-07-2022.
- Bu, S. J., & Cho, S. B. (2018). Learning optimal Q-function using deep Boltzmann machine for reliable trading of cryptocurrency. In *Intelligent Data Engineering and Automated Learning-IDEAL 2018: 19th International Conference*, Madrid, Spain, November 21-23, 2018, Proceedings, Part I 19 (pp. 468-480). Springer International Publishing. Accedido 22-02-2021.
- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794). Accedido 01-12-2022.
- Choudhary, A. (2019). A hands-on introduction to deep q-learning using openai gym in python. *Analytics Vidhya*. Obtenido de <https://www.analyticsvidhya.com/blog/2019/04/introduction-deep-qlearning-python/>. Accedido 27-05-2021.
- DeepRobotics (2016). A comprehensive approach to reinforcement learning.

- Obtenido de <https://vmayoral.github.io/robots,/ai,/deep/learning,/rl,/reinforcement/learning/tutorial/>. Accedido 28-05-2021.
- Fradkov, A. L. (2020). Early history of machine learning. *IFAC-PapersOnLine*, 53(2), 1385-1390.
- GreatLearning (2020). Understanding xgboost algorithm I what is xgboost algorithm? Obtenido de <https://www.mygreatlearning.com/blog/xgboostalgorithm/>. Accedido 05-07-2022.
- Gu, S., Lillicrap, T., Sutskever, I., & Levine, S. (2016). Continuous deep q-learning with model-based acceleration. In *International conference on machine learning* (pp. 2829-2838). PMLR. Accedido 24-02-2021.
- Guo, J. and Tuckfield, B. (2020). News-based machine learning and deep learning methods for stock prediction. *Journal of Physics: Conference Series*, 1642:012014. Accedido 15-03-2022.
- Gupta, S. (2018). Sentiment analysis: Concept, analysis and applications. *Toward Data Science*. Obtenido de <https://towardsdatascience.com/sentiment-analysis-concept-analysis-and-applications-6c94d6f58c17>. Accedido 25-02-2021.
- IBM (2020). Machine learning. Obtenido de <https://www.ibm.com/cloud/learn/machine-learning>. Accedido 12-04-2022.
- Jiang, Z., & Liang, J. (2017). Cryptocurrency portfolio management with deep reinforcement learning. In *2017 Intelligent systems conference (IntelliSys)* (pp. 905-913). IEEE. Accedido 22-02-2021.
- Juchli, M. (2018). Limit order placement optimization with deep reinforcement learning: Learning from patterns in cryptocurrency market data. Accedido 2402-2021.
- Julián, G. (2016). Las redes neuronales: qué son y por qué están volviendo. *Revista Xataka*. Obtenido de <https://www.xataka.com/robotica-e-ia/las-redes-neuronales-queson-y-porque-estan-volviendo>. Accedido 20-05-2021.
- Keller, A., & Scholz, M. (2019). Trading on cryptocurrency markets: Analyzing the behavior of bitcoin investors. Accedido 28-02-2021.
- Kolla, B. (2020). Predicting cryptocurrency prices using machine learning and deep learning techniques. *International Journal of Advanced Trends in Computer Science and Engineering*, 9. Accedido 22-02-2021.
- Liang, Z., Chen, H., Zhu, J., Jiang, K., & Li, Y. (2018). Adversarial deep reinforcement learning in portfolio management. *arXiv preprint arXiv:1808.09940*. Accedido 2202-2021.
- Lucarelli, G., & Borrotti, M. (2019). A deep reinforcement learning approach for automated cryptocurrency trading. In *Artificial Intelligence Applications and Innovations: 15th IFIP WG 12.5 International Conference, AIAI 2019, Hersonissos, Crete, Greece, May 24–26, 2019, Proceedings 15* (pp. 247-258). Springer International Publishing. Accedido 21-02-2021.
- Lucarelli, G., & Borrotti, M. (2020). A deep Q-learning portfolio management framework for the cryptocurrency market. *Neural Computing and Applications*, 32, 17229-17244. Accedido 21-02-2021.
- Lutins, E. (2017). Grid searching in machine learning: Quick explanation and python implementation. *Medium*,

Medium, 5. Obtenido de <https://elutins.medium.com/gridsearching-in-machine-learning-quick-explanation-and-pythonimplementation-550552200596>. Accedido 07-07-2022.

McNally, S., Roche, J., & Caton, S. (2018, March). Predicting the price of bitcoin using machine learning. In 2018 26th euromicro international conference on parallel, distributed and network-based processing (PDP) (pp. 339-343). IEEE. Accedido 22-02-2021.

Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A., Veness, J., Bellemare, M., Graves, A., Riedmiller, M., Fidjeland, A., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., and Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518:529-33. Accedido 27-05-2021.

Morales, M. (2019). Deep Reinforcement Learning. Accedido 2-12-2021.

Patel, Y. (2018). Optimizing market making using multi-agent reinforcement learning. arXiv preprint arXiv:1812.10252. Accedido 22-02-2021.

Restuputri, D.P.; Refoera, F.B.; Masudin, I. Investigating Acceptance of Digital Asset and Crypto Investment Applications Based on the Use of Technology Model (UTAUT2). *FinTech* 2023, 2, 388-413. <https://doi.org/10.3390/fintech2030022>

Sabry, F., Labda, W., Erbad, A., and Malluhi, Q. (2020). Cryptocurrencies and artificial intelligence: Challenges and opportunities. *IEEE Access*, 8: 175840-175858. Accedido 21-02-2021.

Salakhutdinov, R. and Hinton, G. (2009). Deep Boltzmann Machines, volume 5 of *Proceedings of Machine Learning*

Research. Hilton Clearwater Beach Resort, Clearwater Beach, Florida USA. Accedido 24-02-2021.

Sen, J. (2022). Machine learning and deep learning in stock price prediction. *Machine Learning in the Analysis and Forecasting of Financial Time Series*, 29-67. Accedido 15-03-2022.

Shubham, J. (2017). A comprehensive beginners guide for linear, ridge and lasso regression in python and r. Obtenido de [https://www.analyticsvidhya.com/blog/2017/06/a-comprehensive-guidefor-linear-ridge-and-lasso-regression/h2\\_5](https://www.analyticsvidhya.com/blog/2017/06/a-comprehensive-guidefor-linear-ridge-and-lasso-regression/h2_5). Accedido 14-04-2022.

Shukla, L. (2019). Fundamentals of neural networks. Obtenido de <https://wandb.ai/site/articles/fundamentals-of-neural-networks>. Accedido 21-05-2021.

Soni, S. (2021). Crypto rally: Total market cap hits new all-time high of 2,8t; It added in just over a months time. Obtenido de <https://www.financialexpress.com/market/crypto-rally-total-market-caphits-new-all-time-high-of-2-8t-1-t-added-in-just-over-a-months-time-/2362504/>. Accedido 25-11-2021.

Sruthi, E. (2021). Understanding random forest. Obtenido de <https://www.analyticsvidhya.com/blog/2021/06/understanding-randomforest/>. Accedido 05-07-2022.

Torres, J. (2020). A gentle introduction to deep reinforcement learning. Obtenido de <https://towardsdatascience.com/drl-01-a-gentle-introduction-to-deep-reinforcement-learning-405b79866bf4>. Accedido 20-05-2021.

Torres, J. (2021). Introducción al aprendizaje por refuerzo profundo. Accedido 10-11-2021.

Trozze et al. (2022). Cryptocurrencies and future financial crime. *Crime Science*. <https://doi.org/10.1186/s40163-021-00163-8>.

Vadapalli, P. (2020). Bagging vs boosting in machine learning: Difference between bagging and boosting. Obtenido de <https://www.upgrad.com/blog/bagging-vs-boosting>. Accedido 05-07-2022.

Youngson, M. (2020). Introduction to reinforcement learning. Obtenido de <https://medium.com/swlh/introduction-to-reinforcement-learning63ff8923bd88>. Accedido 27-05-2021.

Zhang, A. (2021). How to design a reinforcement learning reward function for a lunar lander. Obtenido de <https://towardsdatascience.com/how-to-design-reinforcement-learning-reward-function-for-a-lunar-lander-562a24c393f6>. Accedido 2-12-2021.



## Revista Internacional de Investigación e Innovación Tecnológica

Página principal: [www.riit.com.mx](http://www.riit.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](mailto:rarevaloa0900@alumno.ipn.mx)\*; [mcedillo@ipn.mx](mailto:mcedillo@ipn.mx); [aramirezr0906@alumno.ipn.mx](mailto:aramirezr0906@alumno.ipn.mx); [mnakano@ipn.mx](mailto:mnakano@ipn.mx); [hmperez@ipn.mx](mailto: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 procesamientos 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 procesamientos 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:

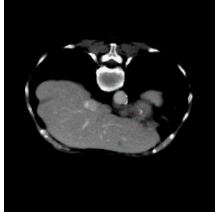
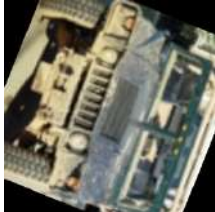


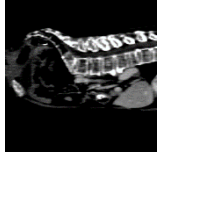
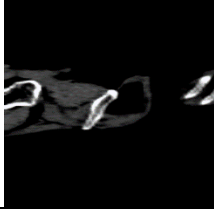




La base de imágenes utilizada consta de 812 imágenes naturales en el formato .jpeg y en el modelo de color Rojo-Verde-Azul (RGB) obtenida de KAGGLE [28] de tamaño 512 x 512 pixeles. Dicha base de datos está compuesta por 8 clases de imágenes naturales (aviones, carros, motocicletas, rostros de personas,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

### 4. Aumento de Datos:





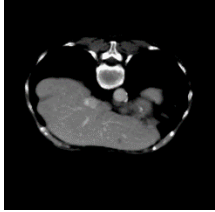



El aumento de imágenes se realiza para mejorar la detección de las características de cada imagen al entrenar la red neuronal, y evitar errores en la detección de la marca de agua al manipular la imagen, de esta manera se incrementa la eficiencia del sistema. Para realizar el aumento de imágenes se aplicaron 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 	Ecuación 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  $\mu_x, \mu_y$  son los valores promedio locales.  $\sigma_x, \sigma_y$  son las desviaciones estándar y  $\sigma_{xy}$  la varianza. Si  $a, \gamma$  y  $\beta$  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:

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

### 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.

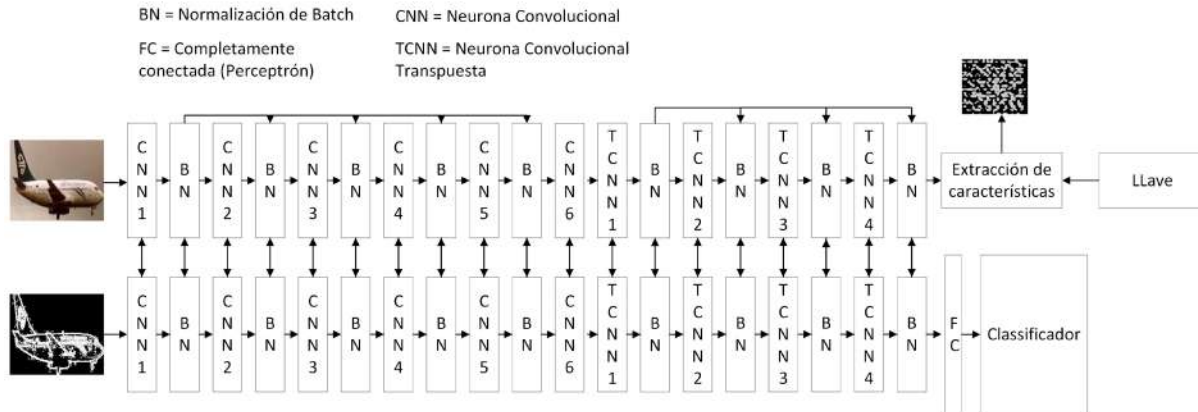
## **2. Red neuronal para la extracción de características de la imagen**

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  $15^\circ$  en un rango de  $5^\circ - 350^\circ$ , 4 imágenes por cada rotación efectuada cada  $15^\circ$  en un rango de  $5^\circ - 350^\circ$  y escaladas

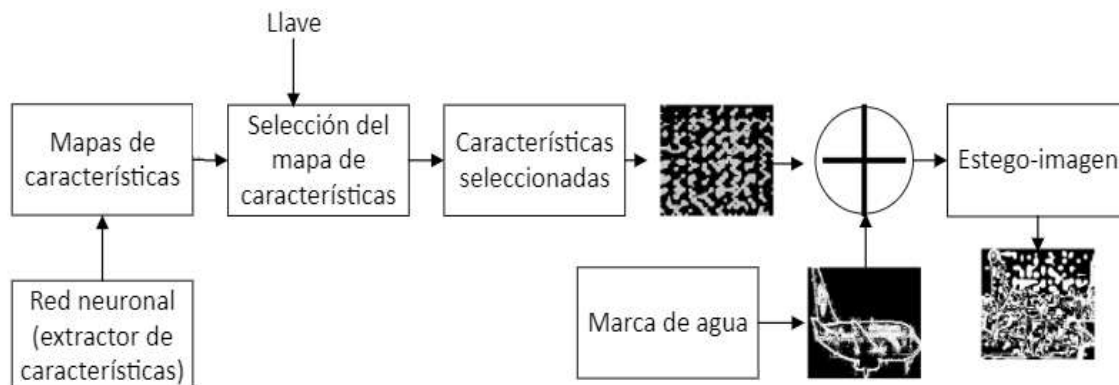
con un factor de 0.5, 4 imágenes trasladadas dentro de la misma imagen 150 píxeles en 'x' y 'y', 4 imágenes trasladadas dentro de la misma imagen 100 píxeles en 'x' y 'y', 4 imágenes trasladadas dentro de la misma imagen 50 píxeles en 'x' y 'y', 4 imágenes escaladas a  $256 \times 256$  píxeles, 4 imágenes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

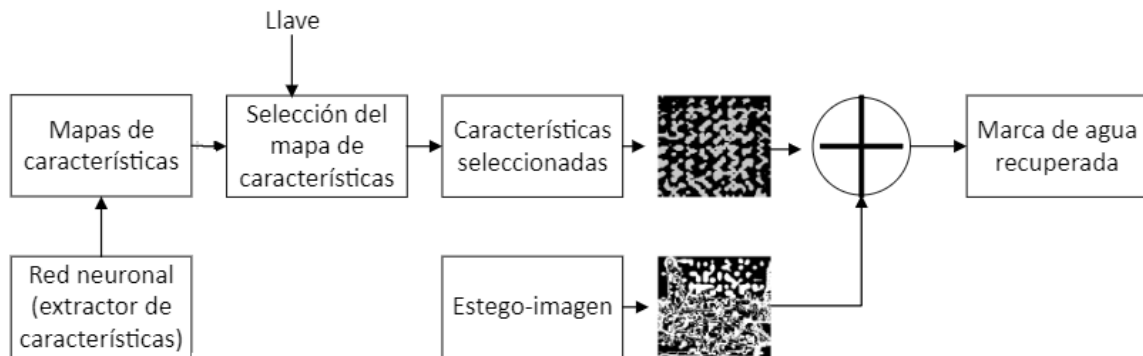


Figura 6. Recuperación de la marca de agua.

## 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.

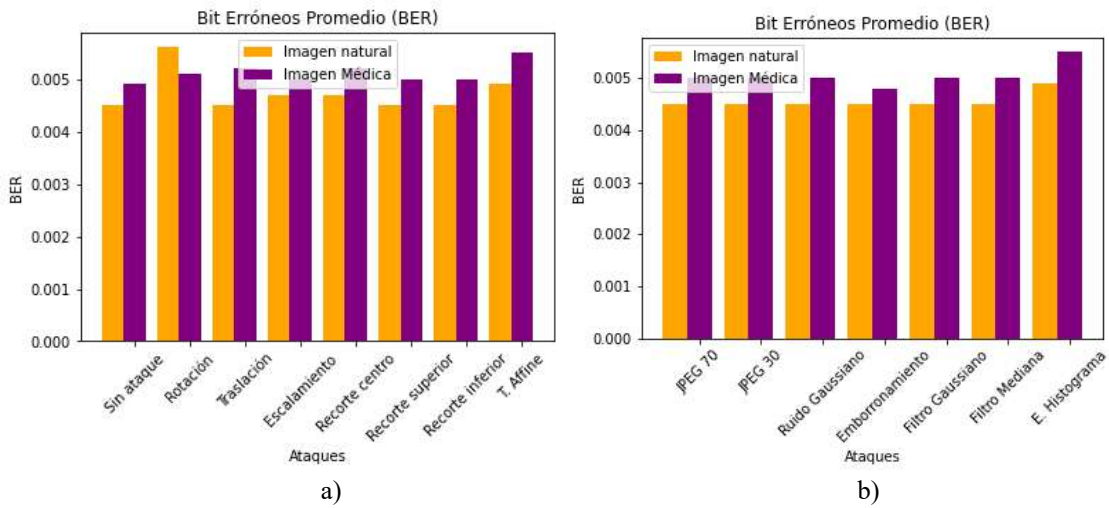


Figura 7. BER a) transformaciones geométricas, b) procesamiento de imágenes.

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.

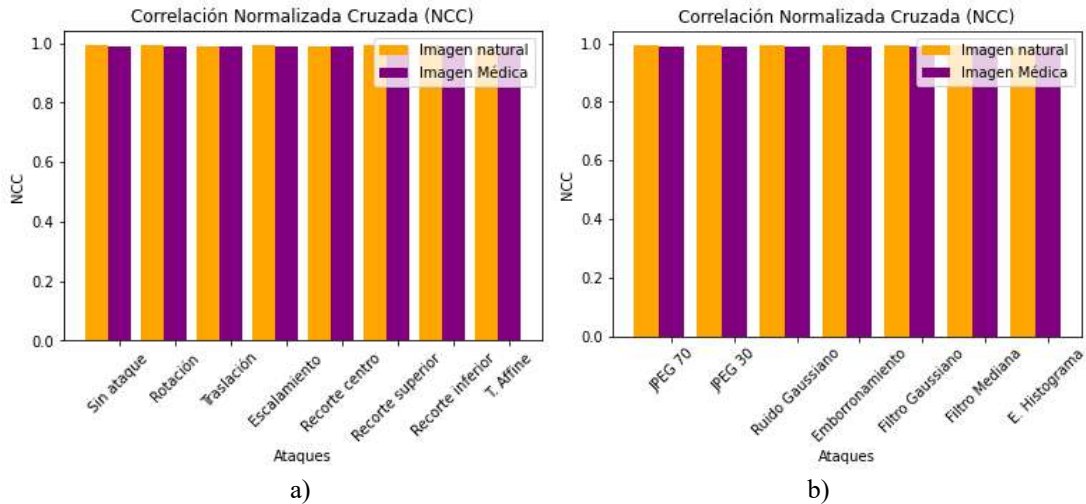


Figura 8. NCC a) transformaciones geométricas, b) procesamiento de imágenes.

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.

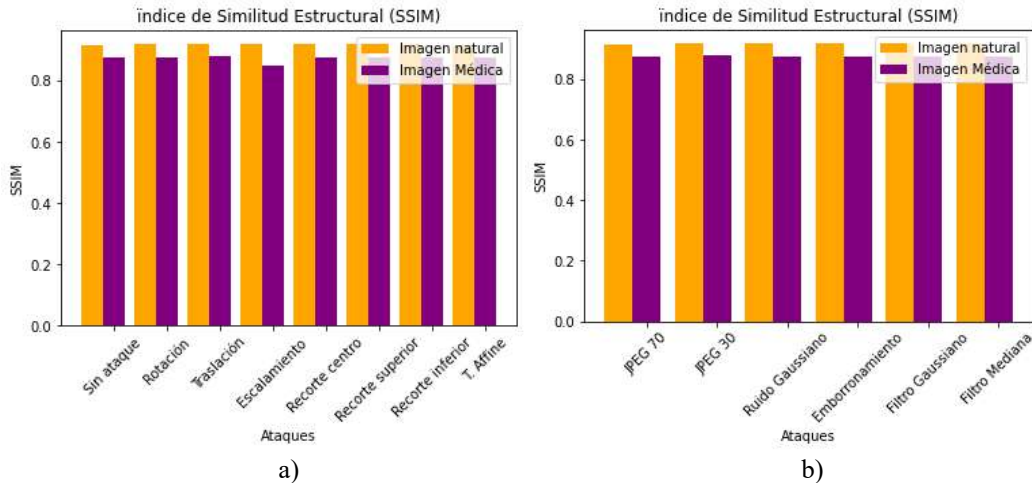


Figura 9. SSIM a) transformaciones geométricas, b) procesamiento de imágenes.

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.

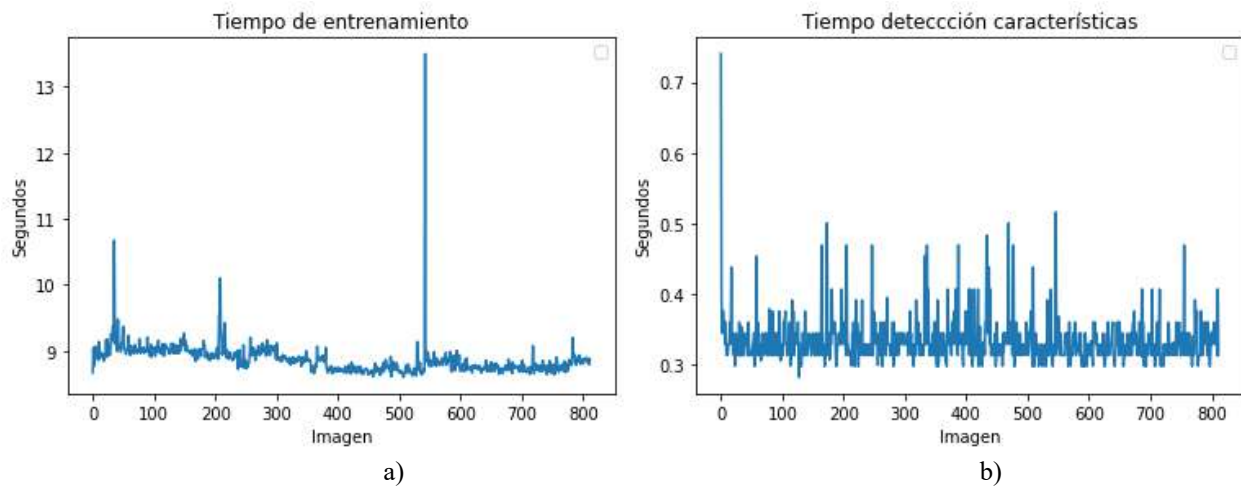
Tabla 4. Comparación de la marca de agua original y la marca de agua recuperada.

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				
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.

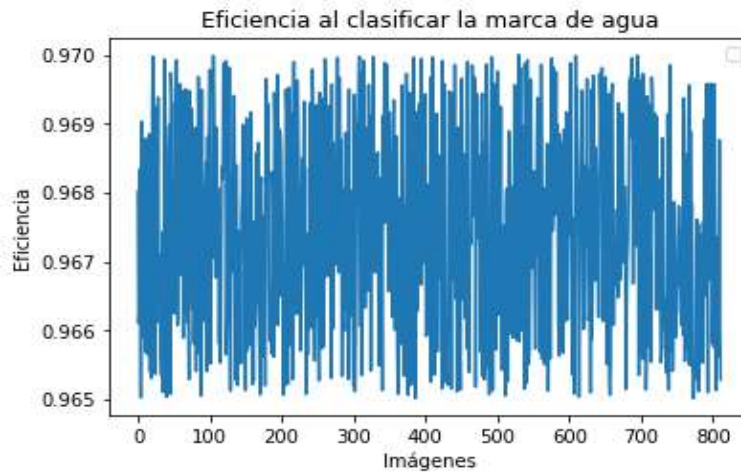


Figura 11. Eficiencia de la red neuronal al clasificar la marca de agua.

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 de 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 a 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 procesamientos 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. Guanghui 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>.



## Revista Internacional de Investigación e Innovación Tecnológica

Página principal: [www.riit.com.mx](http://www.riit.com.mx)

### Robot móvil interactivo para el aprendizaje de ángulos con alumnos de primaria

#### Interactive mobile robot for learning angles with elementary school students

Soria-López, A.<sup>a</sup>, Silva-Ochoa, H.<sup>b</sup>, Ojeda-Misses, M.A.<sup>c\*</sup>

<sup>a</sup> Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, Av. Instituto Politécnico Nacional 2508, San Pedro Zacatenco, Gustavo A. Madero, 07360 Ciudad de México, CDMX.

<sup>b</sup> Universidad Nacional Autónoma de México, Facultad de Filosofía y Letras, Colegio de Letras Modernas, Circuito Interior s/n, C.U., Coyoacán, 04510 Ciudad de México, CDMX.

<sup>c</sup> Universidad Autónoma del Estado de Hidalgo, Instituto de Ciencias Básicas e Ingeniería, Área Académica de Computación y Electrónica, Carretera Pachuca-Tulancingo Km. 4.5, Colonia Carboneras, Mineral de la Reforma, Hidalgo, C.P. 42184.

[soria@cinvestav.mx](mailto:soria@cinvestav.mx); [silva8a@unam.mx](mailto:silva8a@unam.mx); [manuel\\_ojeda@uaeh.edu.mx](mailto:manuel_ojeda@uaeh.edu.mx)\*

**Innovación tecnológica:** desarrollo de un robot móvil interactivo aplicado para el aprendizaje de ángulos con alumnos de primaria.

**Área de aplicación industrial:** aplicación educativa y robótica.

Recibido: 20 abril 2023

Aceptado: 01 febrero 2024

#### *Abstract*

This article presents a novel mobile robot for learning angles. The robot is developed and designed using the Educational Mathematics and Mobile Robotics to identify the kind of angles. The performance of the mobile robot is assessed by practicing elementary students. The mobile robot is easy to use with multimodal interface using the arm and the hand acquired by Kinect v2 in real-time. Also, the interface is described considering its elements and functions. This article includes results and topics studied during various practices in which the mobile robot was used during classes with elementary students using the nesting model of practices used in the Socio-epistemological Theory from Educational Mathematics.

**Keys words:** Educational robot, angles learning, mobile robot, multimodal interface, socio-epistemology, educational mathematics.

## **Resumen**

Este artículo presenta un novedoso robot móvil para el aprendizaje de ángulos. El robot está desarrollado y diseñado usando la Matemática Educativa y la Robótica Móvil para identificar el tipo de ángulos. El desempeño del robot móvil se evalúa mediante prácticas de estudiantes de primaria. El robot móvil es fácil de usar con interfaz multimodal usando el brazo y la mano adquiridos por Kinect v2 en tiempo real. Asimismo, se describe la interfaz considerando sus elementos y funciones. Este artículo incluye resultados y temas estudiados durante varias prácticas en las que se usó el robot móvil durante las clases con alumnos de primaria utilizando el modelo de anidamiento de prácticas utilizado en la Teoría Socio-epistemológica desde la Matemática Educativa.

**Palabras clave:** Robot educativo, aprendizaje de ángulos, robot móvil, interfaz multimodal, socioepistemología, matemática educativa.

## **1. Introducción**

Los robots móviles han tenido un auge importante con aplicaciones con robots guías [1,2], robots de apoyo a la rehabilitación [3-5], robots para la navegación y el mapeo simultáneo [6], robots multiagentes [7] y robots aplicados al aprendizaje [8-10]. En cuanto a la robótica aplicada al aprendizaje se han desarrollado diversos trabajos aplicados en la robótica educativa que permiten concebir, diseñar y desarrollar robots que apoyen el proceso de enseñanza/aprendizaje [11,12]. El objetivo es despertar el interés de los estudiantes mediante la implementación de nuevas herramientas tecnológicas que transformen las asignaturas tradicionales mediante dinámicas atractivas e integradoras destinadas a crear entornos de aprendizaje favorables y motivacionales.

En la literatura, se han presentado trabajos sobre aprendizaje y juego, entre los que destacan el trabajo [13], que realiza el análisis de una taxonomía basada en el uso de la gamificación y juegos serios. Sin embargo, en dicho trabajo no se exponen aplicaciones ni desarrollos experimentales de la clasificación propuesta, no obstante, este artículo se presenta como un área de

oportunidad. Entre las aplicaciones con juegos, destacan las siguientes: en [14] se desarrolla un juego interactivo para el aprendizaje de una segunda lengua. En [15] implementan un videojuego para el aprendizaje del idioma inglés mediante sonidos. Tras la revisión bibliográfica anteriormente expuesta, se puede apreciar el indiscutible interés por aplicar la tecnología en los procesos de enseñanza y de aprendizaje a través del juego. No obstante, los productos mencionados no suelen estar respaldados por una adecuada problematización de los aspectos didácticos, pedagógicos y lúdicos.

En cuanto a robots educativos, en [1];**Error! No se encuentra el origen de la referencia.** y en [10] se presentan distintos robots capaces de combinar la inteligencia artificial y los juegos a través de secuencias de interacción verbal entre dos agentes situados en un entorno dado. Por otro lado, el robot Nao [12] ha sido usado para el desarrollo de aplicaciones para el aprendizaje de lenguas. Otro ejemplo de ello es en [16], donde han sido empleados varios robots Nao para realizar juegos de fútbol sin la intervención del humano. Por otro lado, en [17] se presenta un robot móvil basado en una

interfaz interactiva para el aprendizaje lúdicos de las partes del cuerpo en francés.

Esto permite comprobar la diversificación y la existencia de una gran variedad de herramientas tecnológicas con el fin de facilitar la enseñanza y el aprendizaje. Este fenómeno representa hoy en día numerosos desafíos, entre ellos, el replanteamiento de las modalidades y los contenidos de la formación docente, una nueva visión del papel que deben desempeñar aprendientes y docentes, y una noción renovada y más compleja del proceso de aprendizaje, que incluye, por ejemplo, el reforzamiento de la literacidad mediática multimodal [18-20].

En suma, en el área de la Matemática Educativa, Cantoral *et al.* [21] consideran que la socioepistemología postula un cambio que busca acentuar el valor de uso del conocimiento matemático por parte del estudiante colocando a las prácticas sobre el objeto. Se subraya que reconocer las practicas que norman la construcción de conocimiento son necesarias para llevarlas a cabo en diversos escenarios con relación al uso del conocimiento que subyacen a ellos. Por lo tanto, se parte del análisis del quehacer humano en la interacción social y para ello se considera en este artículo el Modelo de Anidación de Practicas [22]. Lo anterior, fortalece el sentido de lo matemático mediante diversas situaciones de aprendizaje, es decir, introduciendo un robot en las aulas de matemáticas que ayudará a obtener una enseñanza y un aprendizaje más activo, realista y crítico que derive en aprendizaje significativo basado en la vida cotidiana del que aprende, lo que Cantoral y autores llaman un aula extendida.

Dado que el modelo de anidación de prácticas busca una acción sobre el objeto, es decir, en este trabajo se busca aprovechar el uso de recursos tecnológicos. En lo que atañe a una actividad sobre las acciones, se

busca que el estudiante interactúe con los medios y las herramientas. Finalmente, las practicas son aplicadas de manera que el estudiante pueda aprender mediante prácticas sociales, lo que conlleva a pensar en el desarrollo de una interfaz multimodal que permita la interacción entre el robot móvil y el estudiante.

Durante la revisión del estado del arte, se han identificado que diversos robots han podido ser aplicados para el aprendizaje, sin embargo, no existen propuestas aplicando la robótica para el aprendizaje de los tipos de ángulos en una clase de matemáticas. Solamente la propuesta en [23] cuyo objetivo es propiciar el acercamiento lúdico a las matemáticas de niños en edad preescolar. Por ende, ante la escasa aplicación y desarrollo de infraestructura se busca aprovechar el equipamiento de robots aplicados al área de Matemática tomando en cuenta las recomendaciones dadas en [24]. Donde se menciona que implementar aplicaciones y herramientas educativas es una de las alternativas para fomentar el aprendizaje y la enseñanza mediante el uso de los dispositivos móviles, las computadoras y las nuevas tecnologías.

Sin embargo, es posible crear un robot móvil para el aprendizaje de ángulos con alumnos de primaria aprovechando la robótica móvil y la teoría socio-epistemológica de la matemática educativa. Por ende, en este artículo se presenta el desarrollo de una infraestructura experimental mediante la construcción de un robot móvil interactivo para el aprendizaje de los tipos de ángulos en una clase de matemáticas, un tema muy común en los planes de estudio de las primarias y secundarias en México [25] que busca aprovechar la robótica móvil y la teoría socio-epistemológica de la matemática educativa. Considerando los trabajos aplicados en temas de ángulos, se encuentra [26], donde se recalca que la literatura

especializada ha presentado estudios donde las dificultades se dan tanto en los estudiantes como en los profesores. En los estudiantes se presentan en todos los niveles donde se aborda la trigonometría y/o temas relacionados a los ángulos. Tomando como referencia a [27], el concepto de ángulo es introducido por primera vez en cuarto grado de la educación primaria del sistema educativo mexicano. Donde un error muy común es cuando los alumnos dibujan diversas líneas con diferentes ángulos mediante el uso de las escuadras y del transportador y se tiene un gran conflicto con el uso del transportador al medir ángulos en una circunferencia, ya que es usado como regla para medir la longitud del arco [27, 28].

Así, este artículo está organizado de la siguiente manera: la sección 2 presenta el robot móvil. Y la interfaz. En la sección 3 se describen los resultados y las discusiones de los mismos. Finalmente, el artículo presenta las conclusiones y los trabajos futuros.

## 2. Desarrollo

### 2.1 Robot móvil

El robot móvil interactivo tiene una configuración diferencial basado en dos ruedas controladas por motores y una rueda unidireccional. La Figura 1 presenta al robot móvil que incluye una estructura mecánica (1), un sensor Kinect v2 (2), una computadora (3), un controlador de motores de corriente directa (CD) (4), una interfaz multimodal (5) basada en Matlab [29] y QuaRC [30] y Visual Studio (5) [31] capaz de procesar los datos de control en tiempo real, dos motores de corriente directa (6) con

encoders (7), una bocina (8) y una batería de litio (9).




Figura 1. Componentes del robot móvil.

El robot móvil emplea el Kinect v2 para la adquisición de datos del cuerpo en el sistema operativo Windows 10, a continuación, son enviados los datos en tiempo real mediante el protocolo de transmisión de datos a Matlab-Simulink y el núcleo en tiempo real QuaRC, que permiten realizar movimientos. En la Figura 2 son mostrados dos subsistemas que integran al robot, por un lado, la estructura física del robot y por otro, la interfaz multimodal.

En la computadora del robot móvil es desarrollada la aplicación para el aprendizaje de los ángulos mediante la posición del brazo y la mano derecha del estudiante. El punto de referencia  $O_K$  simboliza el vértice del ángulo y es mapeado en el marco de referencia de Kinect v2 para establecer la posición deseada en el marco de referencia del robot  $O_r$ . Una vez establecida dicha posición, se emplea el control no lineal basado en un control de seguimiento de trayectorias [32].

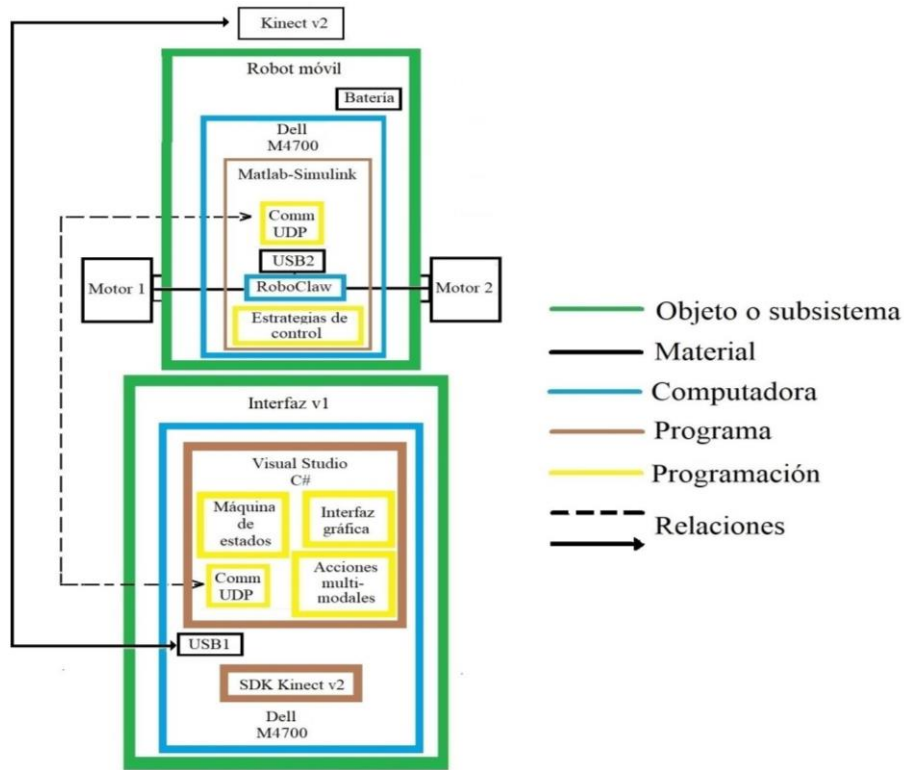


Figura 2. Relación de componentes del robot móvil.




Figura 3. Relación entre marcos de referencia del usuario y el robot móvil.

Las articulaciones detectadas por el sensor Kinect v2 se miden con respecto al origen  $O_K$  del marco de referencia del sensor Kinect. La posición del brazo y la mano derecha, correspondiente a  $O_K$  en el marco de referencia del sensor, es identificada dentro del marco de referencia del robot,

convirtiéndose en  $O_r$ . Es decir, es aplicada una rotación en el eje x,  $R_x = 90^\circ$ , y de esta manera, se obtiene el marco de referencia resultante para el robot, tal como se muestra en la Figura 3.

El punto  $P_K(x_K, y_K)$  se obtiene de la posición medida de la mano derecha y se mapea a un punto  $P_r(x_r, y_r)$  en el espacio de trabajo del robot, como se muestra en la Figura 4. Se emplea la distancia del brazo y antebrazo hasta la mano, para obtener  $P_K(x_K, y_K) = P_r(x_r, y_r)$  y así poder escalar la posición deseada del robot, mediante un factor  $z$  que representa la distancia entre el estudiante y el robot. Mientras que, el ángulo  $\theta$  es formado desde la recta horizontal del

eje  $X_K$  hasta el ángulo de apertura del estudiante considerado en el rango de  $0^\circ \leq \theta \leq 360^\circ$ , siempre y cuando, el centro de la curva de la superficie articular del hombro no coincida necesariamente con el centro de rotación, ya que, además de la forma de la superficie, intervienen el juego mecánico de la articulación, la tensión de los ligamentos y la contracción de los músculos [33].




Figura 4. Mapeo del espacio de detección del estudiante al espacio de trabajo del robot móvil.

## 2.2 Interfaz interactiva humano-robot móvil

En la literatura se han desarrollado diversos tipos de interfaces que han permitido obtener variables de interés (relativas al entorno, al usuario y al robot). Algunos dispositivos comúnmente usados son palancas de mando o joysticks [34], dispositivos hápticos [35], cámaras con alta calidad [36], teléfonos inteligentes [37], relojes inteligentes [38] y diversos casos, el Kinect v2.

En cuanto a las interfaces humano-robot implementadas con Kinect v2 resultan

pertinentes las siguientes: el sistema de reconocimiento de gestos desarrollado en [39] para mover un brazo robótico; la interfaz creada en [40] para reconocer posturas estáticas del cuerpo humano; la interfaz diseñada en [41] para el reconocimiento de gestos gracias a un robot tipo Lego que identifica las acciones ejecutadas por un grupo de niños mientras bailan; las librerías de desarrollo de software para el Kinect v2 (SDK) elegidas en [42] para controlar a un robot manipulador de siete grados de libertad y finalmente, la

interfaz generada en [43] para mover un robot industrial.

Por su parte, la interfaz se caracteriza por ser interactiva, multifuncional y de fácil manejo. Gracias al Kinect v2, es posible la interacción entre el usuario y el robot móvil mediante sonidos, imágenes, movimientos y gestos. Brindando así un interesante potencial para captar la atención de los estudiantes y promover una participación más activa e integral.

La interfaz es multifuncional (ver Figura 5), ya que el usuario puede seleccionar varios estados; se activa sólo un estado a la vez, pero es posible entrar y salir cuantas veces se desee. Finalmente, su manejo es fácil, pues el usuario controla al robot mediante la posición de la mano y el ángulo con el brazo y los estados de las manos (abierta/cerrada) (ver Figura 6).




Figura 5. Interfaz gráfica del robot móvil.



Figura 6. Usuario empleando la interfaz.

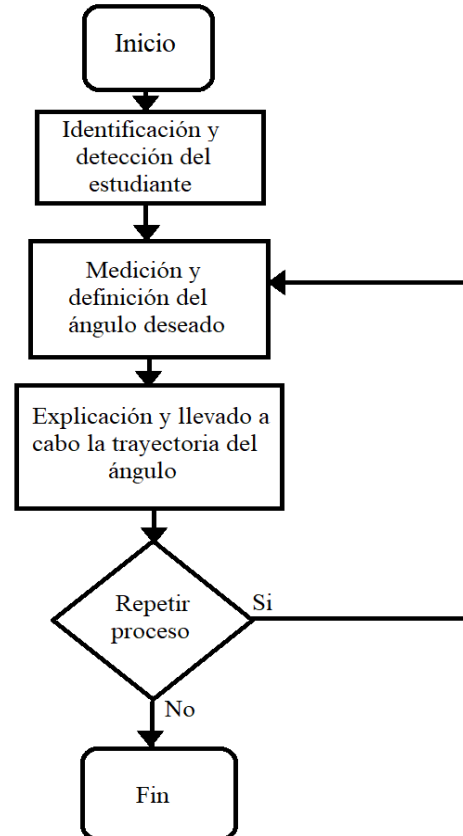
La interfaz gráfica incluye el menú de estados, la ventana de movimiento, la ventana con los datos de control, la ventana con el ángulo trazado, el estado de detección del robot móvil y, finalmente, el nivel de carga de la batería.

1. El menú de estados muestra en la parte superior la aplicación usada con el robot móvil.

2. La ventana de movimiento, donde es mostrada la animación del estudiante mediante la adquisición de Kinect v2, es capaz de detectar hasta 26 articulaciones mediante las librerías del sensor, tales como la distancia entre el estudiante y el robot móvil, la posición del brazo derecho, la posición de la mano derecha y el ángulo trazado con el brazo derecho medido en grados.

3. La ventana con los datos de control del robot presenta los datos adquiridos con Kinect: la posición de la mano derecha, la distancia entre el usuario y el robot, el estado de las manos y el ángulo del brazo derecho; y la gráfica que muestra el desplazamiento del robot en el plano. Finalmente, se presentan avisos importantes como si la batería está baja y si existe algún problema técnico con el robot.

4. La ventana con el ángulo trazado con el brazo y la mano del estudiante, aquí es desplegado la imagen del ángulo ejemplificando el tipo de ángulo y sirve para asociar el ángulo que el alumno ha trazado con anterioridad. En esta área, el robot móvil interactivo es capaz de ejemplificar el ángulo, asimismo, se presenta una breve definición del ángulo con base en los siguientes pasos, ejemplificados en el diagrama de flujo de la Figura 7.



**Figura 7.** Diagrama de flujo de funcionamiento del robot móvil.

La interfaz es capaz de identificar los siguientes tipos de ángulos con su respectivo ejemplo:

Ángulo nulo: es un ángulo igual a  $0^\circ$ , esta clase de ángulo puede ser ejemplificado por una línea horizontal.

Ángulo agudo: es un ángulo mayor a  $0^\circ$  y menor a  $90^\circ$ , lo puedes encontrar, por ejemplo, en una rebanada de pastel.

Ángulo recto: es un ángulo que mide exactamente  $90^\circ$ , este ángulo se puede encontrar en una triangulo rectángulo, en la esquina de dos paredes o la esquina de una mesa.

Ángulo obtuso: este tipo de ángulo es mayor de  $90^\circ$  y menor de  $180^\circ$ , dicho ángulo puede ser encontrado en un abanico, una laptop abierta o una silla reclinable.

Ángulo llano: es un ángulo con medida de exactamente  $180^\circ$ , y puede

encontrarse en una superficie plana, el piso, un plano.

Ángulo cóncavo: es un ángulo mayor a  $180^\circ$  y menor a  $270^\circ$ , lo puedes encontrar, por ejemplo, en el techo de una casa.

Ángulo completo: es un tipo de ángulo que mide exactamente  $360^\circ$ , y puede encontrarse en un pastel completo o la luna.

5. El estado de detección para el robot móvil dado por el Kinect v2 es representado mediante un conjunto de caracteres. Son definidos dos estados: el primero, un estado activo representado por un emoticón con una cara sonriendo que muestra que el Kinect v2

está detectando al estudiante; y el segundo, un estado inactivo mediante un emoticón dado con una cara triste la cual representa que Kinect no está detectando al estudiante.

6. El nivel de carga de la batería, es representado mediante barras que indican el estado de la batería.

Por otro lado, el resultado de la trayectoria en el plano (x,y) a nivel control es mostrada en la Figura 8, donde el ángulo de orientación inicial es  $\theta_0 = 90^\circ$ .

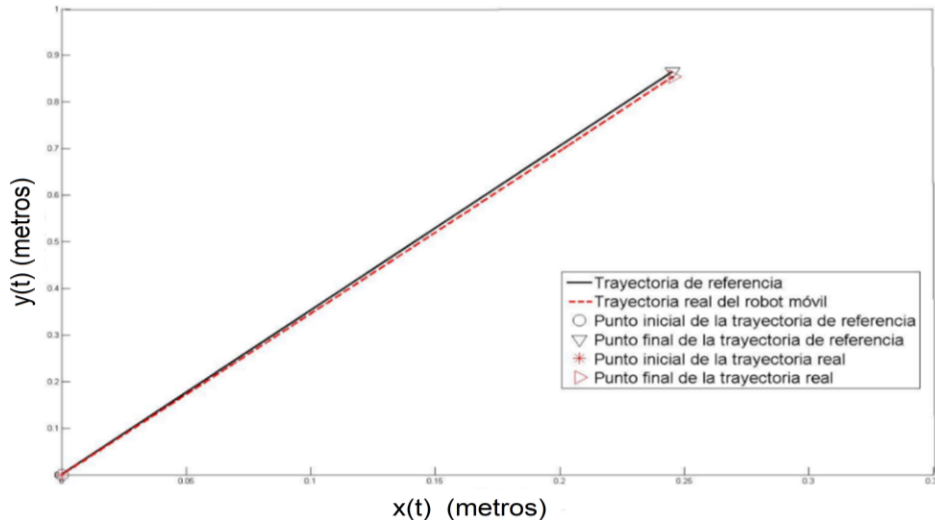


Figura 8. Trayectoria en el plano (x,y) del robot móvil en tiempo real.

### 3. Resultados

Los resultados obtenidos son consecuencia del uso del robot durante periodos escolares con estudiantes de primaria de 5to y 6to grado en municipio de Acolman en el Estado de México, México. Cuyo objetivo es brindar un robot para el aprendizaje de los tipos de ángulos mediante el uso del robot móvil interactivo durante diez sesiones de 5 horas cada una, considerando el modelo de anidación de prácticas que consta de cinco pasos, donde cada nivel antecede y acompaña al siguiente, dicha anidación permite la construcción del conocimiento social mediante la interacción.

En este trabajo se fructifica mediante el uso de la Teoría Socioepistemológica de la Matemática Educativa que considera que la matemática tiene una naturaleza social, donde el componente social conlleva al contexto y a las características de la matemática [26-28]. De esta manera, se considera que para cada matemática existen características que la hacen única, un claro ejemplo es la resignificación realizada en [26], donde se lleva a cabo el análisis transversal de una anidación de prácticas y el reconocimiento de los usos del conocimiento matemático. Donde se identificó que los estudiantes actúan matemáticamente en

forma distinta, responden con herramientas que van más allá de los procesos memorísticos y evocan alguna noción relacionada. Aunado a ello, se reconoce que los modelos de las tareas de trigonometría permiten un ir y venir entre el objeto simulado, el análisis del modelo y el cálculo numérico. Por tal motivo, en el presente artículo se introduce evidencia de que es posible la construcción de significados, representaciones y usos [26-[28] mediante el uso de un robot móvil interactivo considerando una herramienta tecnológica empleada en los nuevos aportes de la educación del siglo XXI y la literacidad mediática multimodal de los alumnos [19, [20].

Dado lo anterior, se propone usar el modelo de anidación de prácticas (ver Figura 9) únicamente los niveles pragmáticos (acciones-actividades-actividad socialmente compartida) y la práctica de referencia mediante el uso de la robótica, y no los últimos dos niveles; debido a que se presenta un caso de estudio, mientras que para el reconocimiento de una práctica social se necesita hacer un meta-análisis que permita ratificar las prácticas de la construcción social de determinada noción matemática permanecen en diferente escenarios en tanto las características que permiten diferenciarla de otras nociones.



**Figura 9.** Modelo de anidación de prácticas [21].

Para obtener la construcción del conocimiento se emplea el robot móvil, debido a que permite desde el punto de vista constructivista el aprendizaje. El cual es definido como un proceso de construcción interno, activo e individual cuyo mecanismo básico de aprendizaje de conocimientos consiste en un proceso en el que nuevas informaciones se incorporan a los esquemas o estructuras preexistentes en la mente de las personas, que se modifican, adaptan y reorganizan según un mecanismo de asimilación y acomodación facilitado por la actividad del alumno.

El saber es considerando la acción, directa del sujeto (individual, colectivo o histórico) ante el medio en tres acepciones: material y entorno mediante el uso de herramientas tecnológicas, en caso específico, mediante el robot móvil interactivo que busca la interacción para obtener la acepción organizacional, es decir, busca el contexto de aprendizaje de los tipos de ángulos fomentando la práctica social (normativo) dada como una actividad humana situada socioculturalmente, para perfilar una práctica (iteración deliberada del sujeto y regulada por el contexto); dicha práctica tiene como objetivo la regulación de una práctica de referencia que es la expresión material e ideológica de un paradigma (ideológico, disciplinar y cultural), la que a la vez es normada mediante cuatro funciones por la práctica social (normativa, identitaria, pragmática y discursiva-reflexiva) [21]. Las pruebas fueron realizadas desde un salón de clases durante el periodo de noviembre a diciembre de 2022.

Asimismo, en la fase de evaluación los estudiantes fueron evaluados respecto al aprendizaje obtenido en el tema de ángulos sin el uso del robot y una segunda evaluación mediante la enseñanza obtenida utilizando el robot desarrollado. Con base en

la información recabada, se pudo concluir que la herramienta tecnológica ayuda y contribuye en el aprendizaje de los tipos de ángulo. Finalmente, respecto a la segunda evaluación pedimos a los estudiantes que evaluaran su grado general de satisfacción con los aspectos teóricos y prácticos brindados durante la práctica. Para llevar a

cabo la prueba con el robot móvil se consideró realizar los experimentos en la escuela primaria Wenceslao Sánchez de la Barquera en Tepexpan, Acolman, Estado de México. Se invitó a participar a los grupos de 5to grado y 2 grupos de 6 grado, contando con un total de 48 alumnos y 33 alumnas entre 10 y 12 años (ver Figura 10).




**Figura 10.** Robot móvil usado en escuela primaria.


Se realizaron dos evaluaciones, la primera respecto a el conocimiento adquirido sobre el tema de ángulos y la segunda evaluación, sobre el uso y el manejo del robot móvil como herramienta para el aprendizaje de ángulos, obteniendo los siguientes resultados. La primera evaluación (ver Figura 11) fue basada en el conocimiento adquirido: 1. ¿qué es un ángulo?, 2. ¿Cuáles son los tipos de ángulos que miden menos de 90 grados, más de 90 grados y exactamente 90 grados?, 3. ¿cuál es el instrumento que se usa para medir ángulos?, 4. ¿qué tipo de ángulo encuentras en un cono de helado y en la separación de los dedos (señal de amor y paz)?, 5. ¿Cómo se clasifican los ángulos?, 6. Un ángulo agudo mide menos de 100 grados. 7. Un ángulo recto lo encuentras en una escuadra, 8. Un ángulo obtuso mide más de 90 grados y menos de 180 grados, 9. ¿Qué tipo de ángulo mide 270 grados? y 10. ¿Cuánto mide un ángulo agudo? Mientras

que la segunda evaluación (ver Figura 12) fue realizada con base en el uso del robot móvil: ¿fue fácil el manejo del robot?, ¿consideran que el uso del robot en una clase de matemáticas es atractivo? ¿Aprendiste los tipos de ángulos trazándolos con tu brazo? ¿Fue útil la información dada sobre los ángulos por el robot?

Los experimentados presentados permitieron identificar pistas para tener un robot móvil interactivo que aporte y contribuya en el aprendizaje de los tipos de ángulos. Dicho robot fue llevado a cabo para el pilotaje en situaciones formales de aprendizaje con alumnos de 5to y 6to grado de primaria, donde el tema de los ángulos es fundamental para su formación en el área de matemáticas. Además, mediante de que se ejemplifican los ángulos con objetos reales, que permiten asociar los ángulos en el mundo real.



**Figura 11.** Gráfica de la evaluación del conocimiento adquirido sobre el tema de ángulos.



**Figura 12.** Gráfica de la evaluación del uso del robot móvil.

Mediante el robot móvil se logran obtener resultados cuantificables usando el método científico [45] en los cursos de Matemáticas y dar este enfoque en nuevas propuestas de prácticas. Donde los estudiantes construyen nuevas ideas a través de sus experiencias pasadas y nuevos conocimientos. Además, dicho robot móvil puede servir como una herramienta complementaria para los

profesores combinando la teoría con la práctica utilizando este robot móvil para ayudar a explicar conceptos teóricos y estimular el aprendizaje práctico en un salón de clases.

Del resultado de la Figura 11 y la Figura 12 puede identificarse que la evaluación basada en el conocimiento adquirido el 92% de los

estudiantes reflejaron en su cuestionario de evaluación haber contestado correctamente a las preguntas. Por otro lado, respecto a la evaluación realizada con base en el uso del robot móvil los estudiantes evaluaron favorables los aspectos y la ayuda brindada por el robot obteniendo el 94.44% de aceptación de los 81 alumnos encuestados (véase Figura 12).

Por lo que, el salón de clases es uno de los elementos más importantes del proceso educativo formal. En efecto, el aula suele ser el lugar donde el estudiante pasa la mayor parte del tiempo dedicado al aprendizaje. El salón de clases es dado como un sistema, cuyos componentes son el maestro, los compañeros de clase, los materiales, las actividades, las herramientas complementarias y los métodos de aprendizaje, conocido como robótica ludoeducativa [9, 46]. Todos ellos funcionan como fuentes de actitudes y motivaciones que impactan positiva o negativamente tanto en la adquisición como en el aprendizaje.

#### 4. Conclusiones

En este artículo se ha presentado un novedoso robot basada en un robot móvil interactivo, permitiendo realizar simulaciones y experimentos en tiempo real para el aprendizaje de los tipos de ángulos con alumnos de primaria en México.

La implementación del robot móvil ha generado respuestas favorables por parte de los estudiantes reflejados en los resultados obtenidos en las evaluaciones, además, se logró identificar que para los alumnos es mucho más sencillo aprender los ángulos con base en objetos.

Es considerada como una propuesta que permite la intervención didáctica alternativa para el campo particular de las matemáticas escolares basadas en la Matemática

Educativa considerando: el aula extendida, el saber en tanto conocimiento en uso y una visión crítica, solidaria y humanista de la sociedad del conocimiento.

En el caso de la enseñanza/aprendizaje de los tipos de ángulos, los componentes del salón de clases pueden generar actitudes positivas hacia la situación de aprendizaje y pueden hacer surgir una motivación intrínseca que beneficiará el desempeño del estudiante.

En el aula se pretende que el profesor en conjunto con el robot móvil promueva en el alumno la motivación intrínseca y la motivación integrativa. Con ese fin, el profesor puede implementar actividades propicias al aprendizaje mediante recursos auténticos, que presenten aspectos llamativos, nuevos e innovadores.

Cabe señalar que fue necesario, fundamental e indispensable realizar la evaluación para identificar oportunidades y mejoras en el uso de herramientas tecnológicas para que los docentes puedan complementar sus clases mediante juegos articulados que permitan favorecer el conocimiento matemático y disciplinar, situación que por lo general no se da en actividades escolares.

En conclusión, es posible afirmar que se precisa para cada uno de estos tres aspectos de la consideración integral tomando en cuenta a las matemáticas, como parte de la cultura, se construyen a partir de vivencias cotidianas de los individuos a través de prácticas socialmente compartidas [21].

El desarrollo de una manera matemática de pensar entre la población permite el aprendizaje mediante herramientas tecnológicas y de la incorporación de las prácticas que le acompañan. Finalmente, la dualidad del individuo (colectividad) se supera con la anidación de prácticas que

parten de la acción del individuo sobre el medio, se constituye mediante las actividades humanas que, reiteradas con intencionalidad, devienen en prácticas socialmente compartidas en el contexto de grandes prácticas de referencia.

Finalmente, las pruebas fueron efectuadas en un lugar cerrado, cuyos niveles de iluminación no afectaron de manera significativa el reconocimiento y la adquisición de datos; sin embargo, en lugares abiertos con mucha iluminación como la solar afectan el procesamiento y adquisición de datos.

El robot móvil funciona de manera óptima sobre un piso cuya superficie es regular, pues las pruebas en superficies irregulares dieron lugar a perturbaciones tanto en el seguimiento de trayectorias del robot en el proceso de reconocimiento y de adquisición de datos. En proyectos futuros, será necesario evaluar la movilidad del robot en superficies irregulares o restringir el uso del robot móvil a espacios que reúnan condiciones óptimas.

Las pistas para mejorar el desempeño técnico, lúdico y socioepistemológico del robot serán tomadas en cuenta para futuras pruebas.

## Referencias

- [1] Burgard, W., Cremers, A. B., Fox, D., Hähnel, D., Lakemeyer, G., Schulz, D., Steiner, W. & Thrun, S. (1999). Experiences with an interactive museum tour guide robot, *Artificial Intelligence*, vol. 1-2, núm. 114, pp. 3-55. DOI. 10.1016/S0004-3702(99)00070-3.
- [2] Thrun, S., Bennewitz, M., Burgard, W., Cremers, A., Dellaert, F., Fox, D., Hähnel, D., Rosenberg, D., Roy, N., Schulte, J. & Schulz, D. (1999). *Minerva: a second generation museum tour guide robot*, *IEEE Int. Conf. on Robotics and Automation*, Detroit, MI, USA, vol. 3, pp. 1999-2005. DOI. 10.1109/ROBOT.1999.770401.
- [3] Hansen, S. T., Bak, T. & Risager, C. (2012). An adaptive game algorithm for an autonomous, mobile robot. A real world study with elderly users, *Int. Symp. on Robot and Human Interactive Communication*, pp.125-130. DOI. 10.1109/ROMAN.2012.6343864.
- [4] Hansen, S. T., Rasmussen, D. M. & Bak, T. (2012). Field study of a physical game for older adults based on an autonomous mobile robot, *Int. Conf. on Collaboration Technologies and Systems*, pp. 125-130. DOI. 10.1109/CTS.2012.6261038.
- [5] Calderita, L. V., Bustos, P., Suárez Mejías, C., Fernández, F., Viciano, R. & Bandera, A. (2015). Asistente robótico socialmente interactivo para terapias de rehabilitación motriz con pacientes de pediatría, *Revista Iberoamericana de Automática e Informática Industrial*, vol. 12, núm. 1, pp. 99-110. DOI. 10.1016/j.riai.2014.09.007.
- [6] Yu, W., Zamora, E. & Soria, A. (2015). Ellipsoid SLAM: a novel set membership method for simultaneous localization and mapping, *Autonomous Robots*, vol. 39, núm. 3, pp. 125-137. DOI. 10.1007/s10514-015-9447-y.
- [7] García Cena, C., Saltarén, R., López Blázquez, J. & Aracil, R. (2010). Desarrollo de una interfaz de usuario para el sistema robótico multiagente SMART, *Revista Iberoamericana de Automática e Informática Industrial*, vol. 7, núm. 4, 2010, pp. 17-27. DOI. 10.1016/S1697-7912(10)70056-X.

- [8] López, D., Gómez-Bravo, F., Cuesta, F., & Ollero, A. (2010). Planificación de Trayectorias con el Algoritmo RRT. Aplicación a Robots No Holónomos. *Revista Iberoamericana De Automática E Informática Industrial*, 3(3), 56–67. Recuperado a partir de <https://polipapers.upv.es/index.php/RIA/article/view/8144>
- [9] Misses, M. A. (2022). La robótica ludoeducativa como una disciplina multidisciplinaria. *Revista Lengua y Cultura*, 4(7), 122-132. <https://doi.org/10.29057/lc.v4i7.9691>
- [10] Su, K. L., Shiau, S. V., Guo, J. H. & Shiau, C. W. (2009). Mobile robot based chinese chess game, *IEEE 4th Int. Conf. on Innovative Computing, Information and Control*, pp. 528-531. DOI: 10.1109/ICICIC.2009.261.
- [11] Steinkuehler, C., Squire, K. & Barab, S. (2012). *Games, Learning and Society: Learning and Meaning in the Digital Age*, Cambridge University Press, New York.
- [12] Stevens, A. & Shield, L. (2009). Étude sur l'impact des technologiques de l'information et de la communication et des nouveaux médias sur l'apprentissage des langues. Rapport final, Commission Européenne, Strasbourg.
- [13] Yanes N. & Bououd, I. (2019). Using Gamification and Serious Games for English Language Learning, *International Conference on Computer and Information Sciences (ICCIS)*, vol. 3, pp. 7301-7312.
- [14] Wu, J., Lv, C., Zhao, L., Li, R. & Wang, G. (2017). Design and Implementation of an Omnidirectional Mobile Robot Platform with Unified I/O Interfaces, *International Conference on Mechatronics and Automation*, vol. 3, pp. 410-415.
- [15] Kitichaiwat P., Thongsuk, M. & Ngamsuriyaroj, S. (2014). Melody Touch: A Game for Learning English from Songs, *IEEE Third ICT International Student Project Conference*, pp. 13-16. DOI: 10.1109/ICT-ISPC.2014.6923207
- [16] Veloso, M. & Stone, P. (2012). Video: RoboCup Robot Soccer History 1997-2011, *Proc. International Conference on Intelligent Robots and Systems*, pp. 5452-5453. DOI: 10.1109/IROS.2012.6386302
- [17] Ojeda-Misses M. A., Silva-Ochoa H. & Soria-López A. (2021). Ludibot: Interfaz humano-robot móvil para el aprendizaje lúdico de idiomas. *Ingeniería Investigación y Tecnología*, 22 (03), 1-10. <https://doi.org/10.22201/fi.25940732e.2021.22.3.021>
- [18] Müller, J. (2000). L'intermédialité, une nouvelle approche interdisciplinaire: perspectives théoriques et pratiques à l'exemple de la vision de la télévision, *Cinémas. Revue d'études cinématographiques*, vol. 10, núm. 2-3, pp. 105-134.
- [19] World Economic Forum, *New Vision for Education: Fostering Social and Emotional Learning through Technology*, World Economic Forum, Boston, 2016.
- [20] World Economic Forum, *New Vision for Education Unlocking the Potential of*

- Technology, World Economic Forum, Boston, 2015.
- [21] Cantoral, R., Montiel, G. & Reyes-Gasperini, D. (2015). El programa socioepistemológico de investigación en Matemática Educativa: el caso de Latinoamérica. *Revista Latinoamericana de Investigación en Matemática Educativa*, 18(1), 5-17. <http://dx.doi.org/10.12802/relime.13.1810>
- [22] Cantoral, Reyes Gazperini. D. & Montiel Espinosa, G. (2014). Socioepistemología, Matemáticas y Realidad, *Revista Latinoamericana de Etnomatemática Perspectivas Socioculturales de la Educación Matemática*, Núm. 7, Vol. 3, 91-116.
- [23] Fernández, R. & Von Lüken, C. (2015). Using the Kinect sensor with open source tools for the development of educational games for kids in pre-school age, *Latin American Computing Conference*, pp. 1-12. DOI. 10.1109/CLEI.2015.7360041.
- [24] O. de las Naciones Unidas para la Educación la Ciencia y la Cultura. (2021). Revisión regional 2020, Educación superior para todas las personas. <https://www.iesalc.unesco.org/2020/04/02/el-coronavirus-covid-19-y-la-educacion-superior-impacto-y-recomendaciones/> Accessed: December-2021.
- [25] Secretaria de Educación Pública, (2021). Plan y Planes de Estudios <https://www.planysprogramasdestudio.sep.gob.mx> Accessed: December-2021.
- [26] Torres-Corrales, D. & Montiel-Espinosa, G. (2021b). Resignificación de la razón trigonométrica en Ingeniería. *Revista Educación Matemática*, 33(3), 202-232.
- [27] Rotaache-Guerrero, R. A. & Montiel-Espinosa, G. (2017). Aprendizaje del concepto escolar de ángulo en estudiantes mexicanos de nivel secundaria. *Educación matemática*, 29(1), 171-200.
- [28] Torres-Corrales, D. & Montiel, G. (2021a). La desarticulación matemática en Ingeniería. Una alternativa para su estudio y atención, desde la Matemática Educativa. *Nóesis. Revista de Ciencias Sociales*, 29(58-1), 24-55. <https://doi.org/10.20983/noesis.2020.3.2>
- [29] The Math Works, Matlab-Simulink / versión 8.0 (R2012b), Natick, MA, USA, 2012. [www.mathworks.com](http://www.mathworks.com)
- [30] Quanser Consulting, QuarC / versión 2.3.603, Markham, Ontario, CA, 2011. [www.quanser.com](http://www.quanser.com)
- [31] Microsoft Corporation, Visual Studio / versión 12. Redmond, WA, USA, 2013. [www.microsoft.com](http://www.microsoft.com)
- [32] Canudas de Wit, C., Khenouf, H., Samson, C. & Sordalen, O. J. (1994). Nonlinear Control Design for Mobile Robots”, en Y. F. Zheng, *Recent Trends in Mobile Robots / World Scientific Series in Robotics and Intelligent Systems*, núm. 11, pp. 121-156. DOI. 10.1142/9789814354301\_0005.
- [33] Kapandji, A. (2006). Fisiología articular. Tomo 1. Hombro, codo, pronosupinación, muñeca, mano. Sexta Edición. MALOINE.
- [34] Kružić, S., Musić, J. & Stančić, I. (2017). Influence of human computer interface elements on performance of teleoperated mobile robot. *40th Int.*

- Conv. on Information and Communication Technology, Electronics and Microelectronics, (1015-1020).
- [35] Xiaolei, H., Pengfei, F. & Yaohong, G. (2017). Dynamic kinesthetic boundary for haptic teleoperation of unicycle type ground mobile robots. Chinese Control Conf., (6246-6251). Recuperado de <http://10.23919/ChiCC.2017.8028350>
- [36] Wu, J., Lv, C., Zhao, L., Li, R. & Wang, G. (2017). Design and implementation of an omnidirectional mobile robot platform with unified I/O interfaces. IEEE Int. Conf. on Mechatronics and Automation, (410-415). Takamatsu, Japón. Recuperado de <https://doi.org/10.1109/ICMA.2017.8015852>
- [37] Waldherr, S., Romero, R. & Thrun, S. (2000). A gesture based interface for human-robot interaction. Autonomous Robots, 151-173.
- [38] Villani, V., Sabattini, L., Riggio, G., Levratti, A., Secchi, C. & Fantuzzi, C. (2017). Interacting with a mobile robot with a natural infrastructure-less interface. 20th IFAC World Congress, (12753-12758).
- [39] Baron, G., Czekalski, P., Golenia, M. & Tokarz, K. (2013). Gesture and voice driven tribot mobile robot using Kinect sensor, Int. Symp. on Electrodynamics and Mechatronic Systems, pp. 33-34. DOI. 10.1109/SELM.2013.6562966.
- [40] Cicirelli, G., Attolico, C., Guaragnella, C. & D'Orazio, T. (2015). A Kinect-based gesture recognition approach for natural human robot interface, International Journal of Advanced Robotic Systems, vol. 12, núm. 3, pp. 1-11. DOI. 10.5772/59974.
- [41] Maraj, D., Maraj, A. & Hajzeraj, A. (2016). Application interface for gesture recognition with Kinect sensor, IEEE Int. Conf. on Knowledge Engineering and Applications, pp. 98-102. DOI. 10.1109/ICKEA.2016.7803000
- [42] Cueva, W. F., Torres, S. H. M. & Kern, M. J. (2017). 7 DOF Industrial Robot Controlled by Hand Gestures using Kinect v2, IEEE 3rd Colombian Conference on Automatic Control, , pp. 1-6. DOI. 10.1109/CCAC.2017.8276455.
- [43] Ben Abdallah, I., Bouteraa, Y., Boucetta, R. & Rekik, C. (2015). Kinect-based computed torque control for lynxmotion robotic arm, Int. Conf. on Modeling Identification and Control, pp. 1-6. DOI. 10.1109/ICMIC.2015.7409416.
- [44] Modelo basado en Competencias. (2022). Tecnológico Nacional de México. <http://teshuixquilucan.edomex.gob.mx/im>, Accessed: December-2022.
- [45] Miller, J. P. (2007). The Holistic Curriculum, Second Edition, OISE Press.
- [46] Ojeda-Misses, M. A. (2023). Development of an Interactive Mobile Robot for Playful Learning and Language Teaching, in IEEE Revista Iberoamericana de Tecnologías del Aprendizaje, vol. 18, no. 1, pp. 114-122, DOI: 10.1109/RITA.2023.3250582.



## Revista Internacional de Investigación e Innovación Tecnológica

Página principal: [www.riit.com.mx](http://www.riit.com.mx)

### A versatile educational tool to detect adulterated honey with Arduino and Python-OpenCv

### Una herramienta educativa versátil para detectar Miel adulterada con Arduino y Python-OpenCv

Sifuentes-Gallardo, C.<sup>a</sup>, Hernández-Ortiz, M.<sup>a</sup>, Ortega-Sigala, J.<sup>a</sup>, Rodríguez-González, B.<sup>a</sup>, Cardoso-Pérez, M.<sup>a</sup>, Esquivel-Félix, R.<sup>b</sup>, Guirette-Barbosa, O.<sup>c</sup>, Cruz-Domínguez, O.<sup>c\*</sup>, Durán-Muñoz, H.<sup>a\*</sup>

<sup>a</sup> Universidad Autónoma de Zacatecas, Jardín Juárez 147, Zacatecas Centro, 98000.

<sup>b</sup> Universidad Tecnológica del Estado de Zacatecas, Ejido, Cieneguitas, Zac.

<sup>c</sup> Universidad Politécnica de Zacatecas, Plan de Pardillo, 99059 Fresnillo, México.

[clausifuen@uaz.edu.mx](mailto:clausifuen@uaz.edu.mx); [mar\\_h2o@hotmail.com](mailto:mar_h2o@hotmail.com); [jjosila@fisica.uaz.edu.mx](mailto:jjosila@fisica.uaz.edu.mx); [brodriguez@upz.edu.mx](mailto:brodriguez@upz.edu.mx);  
[mcardoso\\_63p@yahoo.com.mx](mailto:mcardoso_63p@yahoo.com.mx); [resquivel@utzac.edu.mx](mailto:resquivel@utzac.edu.mx); [omarguirette@hotmail.com](mailto:omarguirette@hotmail.com); [ocruz@upz.edu.mx](mailto:ocruz@upz.edu.mx)\*;  
[hectorduranm@hotmail.com](mailto:hectorduranm@hotmail.com)\*

**Technological innovation:** Development of a low-cost system to detect adulterated honey.

**Industrial application area:** Identification of adulterated honey samples.

Received: may 11th, 2023

Accepted: february 13th, 2024

### Resumen

La miel adulterada es un grave problema mundial, y detectarla en las zonas rurales es aún más complicado. Debido a falta de disponibilidad de equipo de laboratorio para analizar la miel adulterada. Además, las pruebas de laboratorio son muy costosas y las personas de las regiones rurales no pueden pagar sus altos costos. Para solucionar este problema, el objetivo de este trabajo fue implementar dos herramientas prácticas para detectar miel adulterada mediante el uso de un dispositivo electrónico de bajo costo basado en Arduino y mediante Python-OpenCv. Este trabajo se enfoca en hacer que ambas herramientas sean de fácil acceso para los productores de miel, quienes son mayormente afectados ante este grave problema. La novedad de este trabajo es mostrar una metodología amigable para implementar ambas herramientas, la cual puede ser fácilmente reproducida por pobladores de regiones rurales sin conocimientos profundos en electrónica y programación. En este trabajo se encontró evidencia de adulteración de miel. Finalmente, el costo de ambas herramientas es 10 veces menor que los equipos comerciales para el análisis de muestras de miel adulterada.

**Palabras clave:** Regiones rurales, OpenCv, Python, Arduino.

## Abstract

Detecting adulterated honey poses a significant global challenge, especially in rural areas where access to laboratory equipment is limited. The expense associated with laboratory tests further compounds the issue, rendering them unaffordable for many rural inhabitants. In response, this study aims to introduce two practical tools for detecting adulterated honey using a low-cost electronic device based on Arduino and Python-OpenCV. The primary objective is to make these tools accessible to honey producers, who bear the brunt of this problem. The innovation lies in the user-friendly methodology employed, designed to be easily replicated by individuals in rural areas with minimal expertise in electronics and programming. The study revealed evidence of honey adulteration, underscoring the urgency of such solutions. Importantly, both tools are ten times cheaper than commercial equipment typically used for honey analysis, promising a cost-effective approach to addressing this pressing issue.

**Keywords:** Rural regions, OpenCv, Python, Arduino.

## 1 Introduction

Honey is derived from the carbohydrate-rich secretions of plants, primarily nectar and honeydew. Nectar, sourced from plant lymph, contrasts with honeydew, a secretion produced by parasitic insects using plant lymph [1]. Essentially, honey represents a naturally occurring, supersaturated solution of sugars, with fructose and glucose being the predominant monosaccharides. It is further categorized into mono-floral and multi-floral varieties [2]. Mono-floral honey, comprising pollen grains from a single plant species, offers distinctive biological properties appealing to consumers [3]. In contrast, multi-floral honey originates from diverse plant sources, lacking a predominant floral origin [4].

Honey serves as a valuable food resource, finding its way into countless culinary creations and boasting a plethora of applications [5]. Its versatility extends beyond the kitchen, as honey has been employed in the treatment of skin wounds and gastrointestinal ailments [6]. This therapeutic efficacy is attributed to its inherent antibacterial and anti-inflammatory properties, stemming from its high

osmolarity, acidity, and rich content of hydrogen peroxide and non-peroxide components [7]. Moreover, the bioactivity of honey finds utilization in both traditional and contemporary apitherapy practices, highlighting its significance beyond mere sustenance.

However, a concerning trend has emerged with the proliferation of adulterated honey globally, spurred by decreased production and consequent elevated prices. This economic landscape renders honey adulteration increasingly appealing to illicit producers, thereby compromising its quality [8]. Such nefarious practices not only diminish the nutritional value of honey by depleting its vitamin and enzyme content but also present a growing challenge in detection. As adulteration techniques evolve in complexity and sophistication, distinguishing adulterated honey from its authentic counterpart becomes progressively arduous. Adulteration can be categorized into two main groups: direct, involving the addition of substances to honey, and indirect, where bees are fed adulterated substances [9].

Direct adulteration involves the addition of substances directly to honey and can be categorized into four main aspects: sugar addition, water content, processing, and origin. Indirect adulteration occurs when bees are fed adulterated substances [8, 9]. However, the most prevalent methods of honey adulteration include the addition of sucrose or the overfeeding of bees with sugar and other sucrose types [10]. Consequently, there is an urgent need to develop effective techniques for detecting honey adulteration [11].

The issue of honey adulteration is particularly acute in rural regions, where the bulk of honey production occurs globally. In these areas, honey is frequently adulterated with industrial sugar, chemicals, and water, either directly or indirectly [12]. Compounding this challenge, laboratory tests for honey adulteration are prohibitively expensive for rural inhabitants, further exacerbating the problem.

Various methodologies have been proposed in literature to detect honey adulteration. For instance, in an effort to mitigate fraudulent practices, the Codex stipulates that honey should not contain any food ingredients or additives, nor should other substances be added [13]. However, this criterion may not always be entirely reliable due to the inherent variability in honey composition, influenced by factors such as botanical origin, bee species, geographical location, season, and storage conditions [14]. Consequently, a myriad of strategies and techniques have been developed to characterize and authenticate honey, reflecting its complex nature [15]. These methods encompass a range of approaches including physicochemical analysis, microscopy, chromatography, immunoassays, thixotropy, DNA metabarcoding, carbon isotope analysis, sensor technologies, and spectroscopy.

Specifically, assessing the water content in honey, a crucial determinant of its quality, can be achieved through refractive index (RI) measurements using an Abbe-type refractometer. Fiber optic detection has emerged as a successful method for identifying adulterated honey [16]. Additionally, devices such as the Hanna Honey Color 221 colorimeter enable the determination of honey concentration based on its color. However, the high cost of such equipment renders it inaccessible to rural populations [17]. Furthermore, in the event of equipment breakdown, repair or compliance with ISO standards becomes challenging in rural areas. Consequently, these techniques and devices remain impractical for implementation in regions lacking adequate laboratory infrastructure for honey analysis.


Thus, this study proposes the implementation of two tools for rapid and straightforward detection of adulterated honey. The first tool utilizes OpenCV-Python for computational analysis, while the second tool is built upon the Arduino data acquisition board, known for its efficacy in developing low-cost laboratory equipment [18, 19]. The innovation lies in creating two reproducible tools accessible to rural residents, offering a cost-effective alternative to commercial equipment. This work introduces a user-friendly methodology to facilitate the replication of both tools by individuals in rural areas. Crucially, the focus extends beyond mere accessibility, aiming to make these tools readily available to honey producers and institutions invested in ensuring product quality within rural regions.

## 2 Materials and methods

This section outlines a methodology for rapidly assessing the purity of honey samples using two cost-effective tools. These tools are designed to be accessible to users with limited expertise in electronics and programming. The first tool is an Arduino-based electronic device, while the second utilizes Python-OpenCV for image processing. Notably, calibration of both tools does not require additional chemical elements and can be performed using honey samples from the same region. This regional calibration is particularly beneficial in rural areas where access to sophisticated analysis tools and standardized color references may be limited. As such, the methodology emphasizes practical, simple sample preparation using locally sourced honey samples to ensure accurate results across diverse honey varieties and geographical regions.

### 2.1 Preparation of honey samples

The sample preparation process began with the acquisition of multiflora honey directly from a honeycomb sourced from a rural region. Subsequently, five samples were meticulously prepared in 3 ml cuvettes. These samples were calibrated to varying concentrations to facilitate the calibration process of the electronic device. The concentrations used for calibration were categorized as follows: c1) 0% Honey-100% H<sub>2</sub>O; c2) 25% Honey-75% H<sub>2</sub>O; c3) 50% Honey-50% H<sub>2</sub>O; c4) 75% Honey-25% H<sub>2</sub>O; c5) 100% Honey-0% H<sub>2</sub>O. Following the calibration, a distinct sample of honey labeled "sa" was extracted from the same region to ascertain its purity. The honey samples spanning different concentrations, alongside the sample collected from the region, are depicted in Figure 1.



**Figure 1.** Honey samples with concentrations of: c1) 0% Honey-100 % H<sub>2</sub>O; c2) 25% Honey-75% H<sub>2</sub>O; c3) 50% Honey-50% H<sub>2</sub>O; c4) 75% Honey-25% H<sub>2</sub>O; c5) 100% Honey-0% H<sub>2</sub>O. Sample honey labeled "sa".


### 2.2 Arduino based electronic device

The device illustrated in Figure 2 is designed to electronically assess the integrity of a honey sample for potential adulteration. The process initiates with the activation of the RGB LED (Figure 2-g), emitting light at a specific wavelength (Figure 2-p). This

emitted light passes through the cuvette containing the honey sample (Figure 2-m-n). Subsequently, any absorption of the light by the honey (Figure 2-q) is swiftly detected by the photoresistor (Figure 2-f). The ensuing electrical signal undergoes amplification through the LM324 circuit (Figure 2-i) and is

then processed by the Atmega-328P microcontroller (Figure 2-c), often referred to as the device's "brain." This microcontroller meticulously analyzes the signals from the RGB LED and computes the concentration of the honey sample (represented as "sa"). The


calculated concentration is promptly showcased on the LCD screen (Figure 2-b). Moreover, the acquired data can be conveniently stored on the SD card (Figure 2-a) for subsequent retrieval and in-depth analysis on a computer.



**Figure 2.** Electronic device configuration. a) MicroSD memory module, b) LCD screen, c) Atmega328P microcontroller, d) Precision resistance, e) Voltage controller, f) Photo-resistance, g) RGB LED, h) Capacitor, i) LM324 circuit, j) Push-button, k) 16MHz quartz crystal, l) 22pF ceramic capacitor, p) Wavelength emitted by the RGB Led, m) Cuvette, n) honey, q) resulting wavelength.

Figure 3 provides a comprehensive electronic diagram of the device, catering to residents of rural areas lacking extensive expertise in electronics and programming, facilitating easy replication of the electronic setup. Positioned between the RGB LED (Figure 3-

g) and the photoresistor (Figure 3-f) lies the cuvette containing honey. Notably, the electronic device incorporates an MC7805 voltage controller (Figure 3-e) to regulate voltage levels effectively.



**Figure 3.** Electronic diagram of the device. a) MicroSD memory module, b) LCD screen, c) Atmega328P Microcontroller, d) Precision resistance, e) MC7805 Voltage Controller, f) Photo resistance, g) RGB LED, i) LM324 circuit, l) 22pF ceramic capacitor, k) 16MHz quartz crystal, r3-r1) Resistance 270 ohms, r5) 10k ohms, r6) 20k ohms, r4) 820 ohms.

The programming code used in the Atmega-328P microcontroller is shown in Figure 4.

Each programming line has a description of the function it performs.

<pre>#include &lt;LiquidCrystal.h&gt; // Liquid crystal display library #include &lt;SPI.h&gt;           // SPI interface LIBRARY #include &lt;SD.h&gt;           // SD card library #define SSpin 10         // Slave select digital pin 10 int redPin= 5;          //RGB connections int greenPin = 6; int bluePin = 9; int i=1;               // Counter for data organization in sd memory int valor;             // Variables for voltage conversion float voltaje; const int rs = 2, en = 3, d4 = 0, d5 = 1, d6 = 4, d7 = 7; // LCD connections LiquidCrystal lcd(rs, en, d4, d5, d6, d7); File archivo; // Object of type file void setup() {   pinMode(redPin, OUTPUT);   pinMode(greenPin, OUTPUT);   pinMode(bluePin, OUTPUT);   lcd.begin(16, 2);          //LDC (16x2) is initialized   if (!SD.begin(SSpin)) {   // Sd memory is checked     return; }   archivo = SD.open("prueba.txt", FILE_WRITE); // Open for reading/writing prueba.txt file   archivo.close(); } void loop() { if(SD.exists("prueba.txt")){   // Verify that the file "prueba.txt" exists   while(1){      // Samples are taken for an infinite time     archivo = SD.open("prueba.txt", FILE_WRITE); // Open for reading/writing prueba.txt file</pre>	<pre>if (archivo){   // The label "Muestra 'i'" is saved in the .txt file   archivo.println(" ");   archivo.print("Muestra: ");   archivo.println(i);   archivo.close(); }   setColor(0, 0, 255); // The wavelength to be sampled is set   lcd.clear();          // LCD messages   lcd.setCursor(0,0);   lcd.print("LECTURA VOLTAJE:");   lcd.setCursor(0,1);   lcd.print("AZUL: ");   delay(1500);   valor = analogRead(A5); // Analog voltage reading   voltaje = valor*(5.0/1023.0); // Voltage conversion   lcd.print(voltaje); // Voltage value is printed on LCD   archivo = SD.open("prueba.txt", FILE_WRITE); // Open for reading / writing test.txt file   if (archivo){     archivo.print("Voltaje color azul: "); // The label "Voltaje color azul" is saved in the .txt file     archivo.println(voltaje); // voltage value saved in the .txt file     archivo.close();   }   delay(7000);   i=i+1; //Counter is incremented to indicate the next sample }}} void setColor(int redValue, int greenValue, int blueValue) { //Function for changing wavelength of light   analogWrite(redPin, redValue);   analogWrite(greenPin, greenValue);   analogWrite(bluePin, blueValue);</pre>
--	--

**Figure 4.** Programming code used in the Atmega-328P microcontroller.

The cost of commercially available honey adulteration testing devices is prohibitively high. Conversely, the electronic device proposed in this study presents a solution at a mere fraction of the cost, approximately one-

tenth that of commercial equipment. Table 1 outlines the electronic components utilized in the device, supplemented with the cost of each component for clarity and transparency.

**Table 1.** Total cost of the device and each electronic component.

Component	Cost [Dollars]
16MHz quartz crystal, (2) 22pF ceramic capacitor, (3) 270Ω resistance, 10kΩ precision potentiometer, L7805 voltage regulator, Photoresist, RGB LED.	\$ 5.00
16x2 LCD Display	\$ 3.00
LM324 circuit	\$ 4.00
ATmega328P Microcontroller	\$ 3.00
MicroSD memory module	\$ 3.00
Total Cost	\$ 18.00

The qualitative analysis of honey samples in this study relies on the fundamental principle of Beer-Lambert's law. This principle, established by the pioneering work of August Beer and Johann Lambert, elucidates that the intensity of light exiting a medium (I) diminishes exponentially in relation to either

concentration (Beer) or path length (Lambert), compared to the intensity of light entering the medium ( $I_0$ ). Often amalgamated, Beer's and Lambert's relationships are typically expressed in a unified logarithmic equation, as demonstrated by equation 1 [11].

$$A = \epsilon b C = -\log T = -\log\left(\frac{I}{I_0}\right) = -\log\left(\frac{V_{\text{sample}} - V_{\text{dark}}}{V_{\text{water}} - V_{\text{dark}}}\right) \quad (\text{Eq. 1})$$

In this context, the ratio of I to  $I_0$  represents the transmittance (T), while A denotes the absorbance of the medium. Initially, a measurement of the "dark" voltage ( $V_{\text{dark}}$ ) was obtained with the LED unlit, serving as a baseline. Subsequently, a voltage measurement corresponding to essentially 100% transmittance ( $V_{\text{water}}$ ) was recorded with the LED activated. Finally, the voltage across each varying honey concentration was meticulously documented upon the addition of colored test solution ( $V_{\text{sample}}$ ).

### 2.3 Computational tool based on Python-OpenCv

The characterization of honey samples based on their concentration was conducted using a computational tool built upon Python-OpenCv. This tool operates on the principle of image processing and has been developed using Python, leveraging OpenCv libraries for image manipulation, Numpy for efficient

handling of matrices, and Matplotlib for generating graphs and histograms. The Python program, essential for this analysis, is freely downloadable from the official Python website:

<https://www.python.org/downloads/>. To install OpenCv, simply execute the command "pip install opencv-python" in the command console (Figure 5-a). Subsequently, the honey samples were analyzed based on the histograms generated from each honey cuvette. To enable this functionality, the Matplotlib package must be installed using the command "pip install matplotlib" (Figure 5-b). Alternatively, Windows Notepad or text files (with .txt extension) can be utilized to create and store Python programs. These programs should be saved with a .py extension. To execute the program for sample characterization, navigate to the command console, select the folder containing the program, and enter the program's name followed by the .py extension (Figure 5-c).

```
a) C:\Users\Héctor Duran>pip install opencv-python
```

```
b) C:\>pip install matplotlib
```

```
c) C:\Users\fermi\Desktop\python>python eje4.py
```

**Figure 5.** a) OpenCV-Python installation. b) Matplotlib installation. c) Running a program from the command console.

A photograph was captured for each honey sample, which was subsequently associated with a histogram using Python-OpenCv. To derive the histograms for each honey sample, the program depicted in Figure 6-a was executed. Each line of code in the program is accompanied by a comment explaining its functionality. Following the determination of histograms for each sample (c1, c2, c3, c4, c5,

and sa), a correlation matrix is generated. This matrix enables the identification of the honey sample with the highest correlation to the reference sample "sa." Once the sample with the strongest correlation is identified, its concentration level can be determined, facilitating the detection of adulteration if present. The program utilized to generate the correlation matrix is illustrated in Figure 6-b.

a)	b)
<pre>import cv2 #Import OpenCv library for first histogram shape import numpy as np #Numpy library import for array management from matplotlib import pyplot as plt #Matplot library import for second histogram shape def run():     #Image reading     img = cv2.imread("sample1.jpg", cv2.IMREAD_GRAYSCALE)     cv2.imshow('Original Image', img)     #alcHist command to create histogram and save it to a variable     hist = cv2.calcHist([img], [0], None, [256], [0, 256])     #Creation of figure to display images on screen.     #ax is for the location of the image within the figure     fig, ax = plt.subplots(2, 2)     ax[0, 0].imshow(img, cmap='gray')     ax[0, 0].set_title('Imagen')     ax[0, 0].axis('off')     ax[0, 1].plot(hist, color='gray')     ax[1, 0].imshow(img, cmap='gray')     ax[1, 0].set_title('Imagen')     ax[1, 0].axis('off')     #Sample and histogram creation with Matplot library     ax[1, 1].hist(img.ravel(), 256, [0, 256])     plt.show() #Show figure     cv2.waitKey(0) #Time function to not close the window. if __name__ == '__main__':     run()</pre>	<pre>import pandas as pd import matplotlib.pyplot as plt %matplotlib inline import numpy as np import seaborn as sns contamina=pd.read_csv('data2.csv') contamina_corr=contamina.corr(method='spearman') contamina_corr</pre>

**Figure 6.** a) Program to find the histograms of each sample with different concentrations of honey. b) Programming code to generate the correlation matrix.

### 3 Results and Discussion

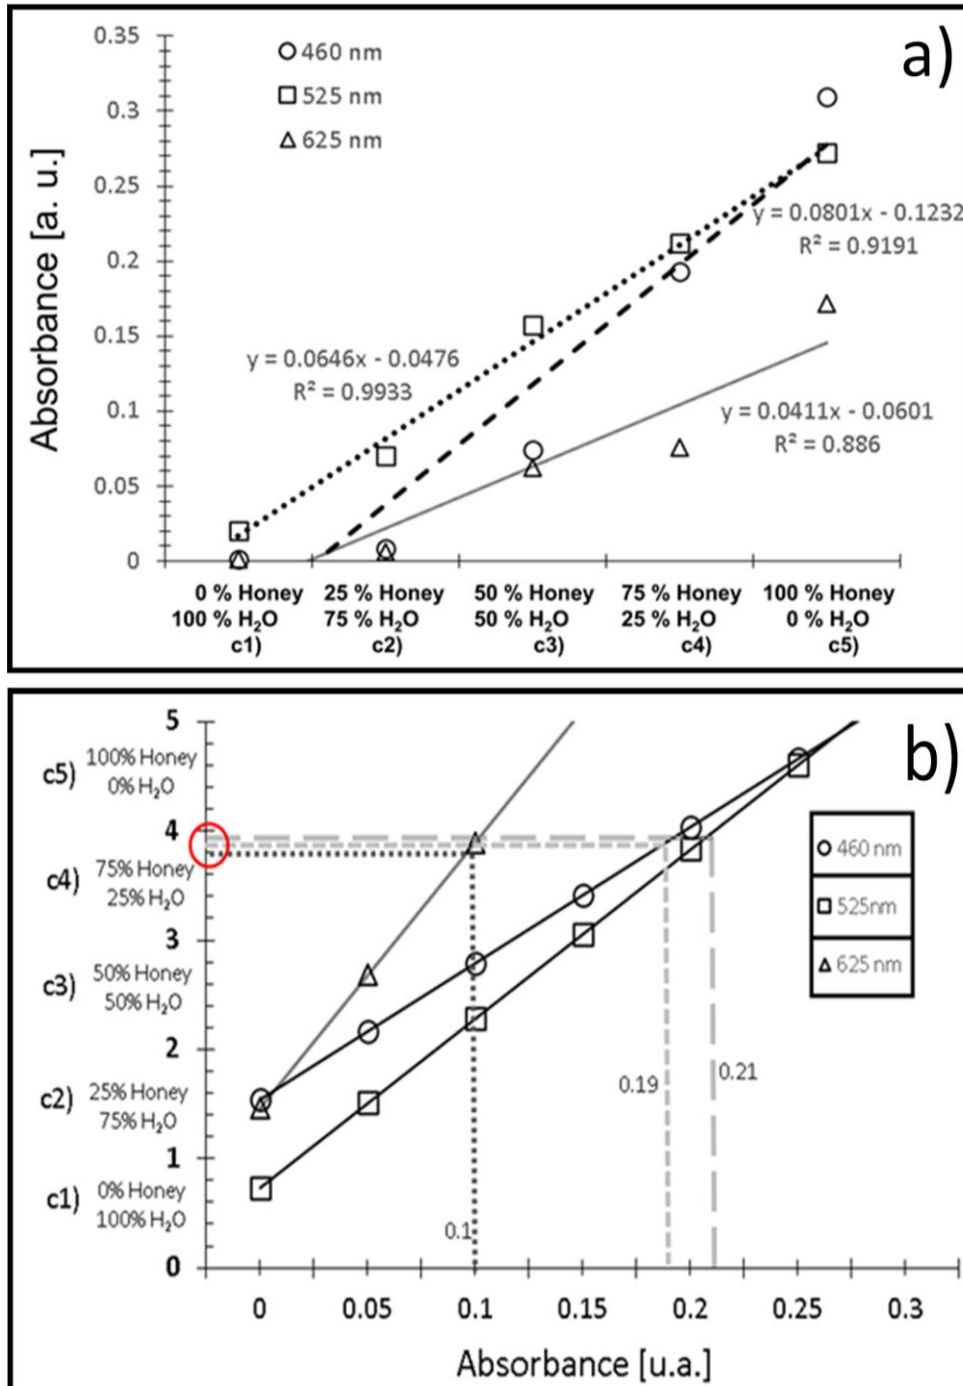
#### 3.1 Sample characterization using Arduino

For calibrating the Arduino-based electronic device, five samples comprising various

concentrations of honey and H<sub>2</sub>O were synthesized. These samples were then subjected to optical stimulation using an RGB LED, with maximum luminescent peaks at

460 nm, 525 nm, and 625 nm. Each sample underwent three tests to assess the device's margin of error and ascertain its reliability. Figure 7-a illustrates the absorbance results of the five samples with concentrations as follows: c1: 0% Honey-100% H<sub>2</sub>O; c2: 25%

Honey-75% H<sub>2</sub>O; c3: 50% Honey-50% H<sub>2</sub>O; c4: 75% Honey-25% H<sub>2</sub>O; c5: 100% Honey-0% H<sub>2</sub>O. Notably, Figure 7-a demonstrates that the coefficient R<sup>2</sup> approaches unity, indicating high correlation and reliability in the device's performance.



**Figure 7.** a) Absorbance of samples with different concentrations of Honey-H<sub>2</sub>O. b) Graph to determine the concentration range of honey.

Therefore, the fit model used has an acceptable approximation to the variability of the device response. It was found that the fitting equations to find the absorbance of the sample "sa" are as follows:

$$460 \text{ nm} \rightarrow \text{absorbance} = 0.0801 \text{ concen} - 0.1232 \quad (\text{Eq. 3.1})$$

$$525 \text{ nm} \rightarrow \text{absorbance} = 0.0646 \text{ concen} - 0.0476 \quad (\text{Eq. 3.2})$$

$$625 \text{ nm} \rightarrow \text{absorbance} = 0.0411 \text{ concen} - 0.0601 \quad (\text{Eq. 3.3})$$

In this study, it was observed that the device exhibits a superior absorbance response at a wavelength of 460 nm. Furthermore, by determining the absorbance value through equations 3.1 - 3.3, the concentration level of the sample "sa" can be determined. Additionally, equations 3.4 - 3.6 enable the determination of the concentration level of a sample from the region based on the absorbance coefficient obtained by the electronic device proposed in this study.

$$460 \text{ nm} \rightarrow \text{concen} = (\text{absorbance} + 0.1232) / (.0801) \quad (\text{Eq. 3.4})$$

$$525 \text{ nm} \rightarrow \text{concen} = (\text{absorbance} + 0.0476) / (0.064) \quad (\text{Eq. 3.5})$$

$$625 \text{ nm} \rightarrow \text{concen} = (\text{absorbance} + 0.0601) / (0.041) \quad (\text{Eq. 3.6})$$

After calibrating the electronic device, we determined the absorbance values of a sample labeled as 'sa' using wavelengths of 460 nm, 525 nm, and 625 nm. The obtained absorbance values were 0.19, 0.21, and 0.1, respectively, for each wavelength. These values were then used in equations 3.4-3.6 to establish the honey concentration range of the sample 'sa.' Figure 7-b illustrates that the honey concentration range is 75% Honey – 25% H<sub>2</sub>O. Interestingly, all three different wavelengths yield the same concentration range in honey (indicated by the red circle). The absorbance values obtained from the sample 'sa' at these three wavelengths are summarized in Table 2.


**Table 2.** Absorbance values of the sample "sa".

Wavelength	Absorbance	Honey Concentration Range value	Honey Concentration Range
460 nm	0.19	3.91	75% Honey - 25% H <sub>2</sub> O
525 nm	0.21	3.98	75% Honey - 25% H <sub>2</sub> O
625 nm	0.1	3.89	75% Honey - 25% H <sub>2</sub> O

### 3.2 Characterization of the samples using the computational tool

The histograms associated with each sample (c1, c2, c3, c4, c5, and "sa") are presented in

Figure 8. The purpose of this method is to compare the histogram of the sample "sa" with each histogram of the samples c1, c2, c3, c4, c5, this through the correlation matrix.



**Figure 8.** Histograms associated with each sample c1, c2, c3, c4, c5 and "sa".

Once it has been identified with which histogram has the greatest correlation, the range of concentration in honey can be associated. The correlation matrix is shown in Table 3. Sample "sa" has a higher correlation with sample c4, with a value of 0.89. Therefore, the honey concentration range of the "sa" sample is 75 % honey-25 % H<sub>2</sub>O, and it is possible to say that the sample is adulterated.

**Table 3.** Correlation matrix of samples c1, c2, c3, c4, c5 and sa.

	C1	C2	C3	C4	C5	sa
C1	1	0.85	0.81	0.82	0.79	0.67
C2	0.85	1	0.97	0.94	0.81	0.82
C3	0.81	0.97	1	0.96	0.82	0.86
C4	0.82	0.94	0.96	1	0.87	0.89
C5	0.79	0.81	0.82	0.87	1	0.8
sa	0.67	0.82	0.86	0.89	0.8	1

Through the electronic device based on Arduino and the Python-OpenCv computational tool, it was found that the

sample from the rural region has a percentage of 75% Honey - 25 H<sub>2</sub>O, that is, it has a certain degree of adulteration.

#### 4 Conclusions

The Arduino-based electronic device paired with the Python-Open computational tool emerges as an optimal solution for addressing adulteration concerns in rural areas due to its speed, affordability, and user-friendly nature. In regions lacking standardized methods for detecting honey adulteration, these tools offer a promising initial step towards resolution. Notably, our investigation identified "sa" samples from rural locales as exhibiting notable adulteration. Contrastingly, metropolitan areas face escalating challenges with increasingly intricate honey adulteration techniques, rendering conventional detection methods insufficient. The pivotal contribution of this study lies in the development of two cost-effective, user-friendly tools tailored for rural honey

characterization. Such tools fill a critical gap in regions devoid of sophisticated laboratory facilities and financial means for conventional analyses. Moreover, our methodology offers straightforward replication potential for rural residents. Remarkably, the combined cost of these tools is a mere fraction of traditional commercial equipment, underscoring their accessibility and practicality for widespread implementation.

### Acknowledgment

A deep gratitude is made to Bricia Alvarado-Acosta and Halia López-Álvarez for the technical support to carry out this work.

### 5 References

1. Frew, R., McComb, K., Croud, L., Clark, D. and Van, H. (2013). "Modified sugar adulteration test applied to New Zealand honey". *Food Chemistry* 141, 4127–4131. <http://dx.doi.org/10.1016/j.foodchem.2013.06.124>
2. Elke A (1998). "A review of the analytical methods to determine the geographical and botanical origin of honey". *Food Chemistry* 63, 549-562. [https://doi.org/10.1016/S0308-8146\(98\)00057-0](https://doi.org/10.1016/S0308-8146(98)00057-0)
3. Batista, J., Leite, E., Marques, G., Toledo, M., Gullón, B., Pintadod, M. and Magnani, M. (2016). "Sugar profile, physicochemical and sensory aspects of monofloral honeys produced by different stingless bee species in Brazilian semi-arid region". *Food Science and Technology* 65, 645-651. <https://doi.org/10.1016/j.lwt.2015.08.058>
4. Soares, S., Amaral, J., Oliveira, M. and Mafra, I. (2017). "A Comprehensive Review on the Main Honey Authentication Issues: Production and Origin". *Comprehensive Reviews in Food Science and Food Safety*. <https://doi.org/10.1111/1541-4337.12278>
5. Blasa, M., Candiracci, M., Accorsi, A., Piera, M. and Millefiori, R. (2006). "Honey is packed full of antioxidants". *Food Chemistry* 97, 217–222. <https://doi.org/10.1016/j.foodchem.2013.06.124>
6. Postmes, T. and Van Den, B. (1993). "Honey for wounds, ulcers, and skin graft preservation". *Letters to the Editor*. 341, 756-757. [https://doi.org/10.1016/0140-6736\(93\)90527-N](https://doi.org/10.1016/0140-6736(93)90527-N)
7. Weston, R. (2000). "The contribution of catalase and other natural products to the antibacterial activity of honey: a review". *Food Chemistry* 71, 235-239. [https://doi.org/10.1016/S0308-8146\(00\)00162-X](https://doi.org/10.1016/S0308-8146(00)00162-X)
8. Zábrowská, B. and Vorlová, L. (2014). "Adulteration of honey and available methods for detection – a review". *Acta Vet. Brno* 83 85-102. <https://doi.org/10.2754/avb201483S10S85>
9. Bogdanov, S., Ruoff, K. and Persano, L. (2004). "Physico-chemical methods for the characterization of unifloral honeys: a review". *Apidologie* 35, <https://doi.org/10.1051/apido:2004047>
10. Guler, A., Bakan, C., Nisbet, O. (2007). "Determination of important biochemical properties of honey to discriminate pure and adulterated honey with sucrose (*Saccharum officinarum* L.) syrup". *Food Chemistry* 105, 1119-1125. <https://doi.org/10.1016/j.foodchem.2007.02.024>

11. Bertelli, D., Lolli, M., Papotti, G., Bortolotti, L., Serra, G. and Plessi, M. (2010). "Detection of Honey Adulteration by Sugar Syrups Using One-Dimensional and Two-Dimensional High-Resolution Nuclear Magnetic Resonance". *J. Agric. Food Chem* 58, 8495–8501. <https://doi.org/10.1021/jf101460t>
12. Naila, A., Flint, S., Sulaiman, A., Ajit, A. and Weed, Z. (2018). "Classical and novel approaches to the analysis of honey and detection of adulterants". 90, 152-165. <https://doi.org/10.1016/j.foodcont.2018.02.027>
13. Codex Alimentarius. (2001). Codex standard for honey CODEX STAN 12-1981 (pp. 8). Rome, Italy: Codex Alimentarius Commission FAO/WHO.
14. Doner, W. and White, W. (1977). "Carbon-13/Carbon-12 ratio is relatively uniform among honeys". *Science* 197, 891-892. <https://doi.org/10.1126/science.197.4306.891>
15. Kaskoniene, V. (2010). "Floral Markers in Honey of Various Botanical and Geographic Origins: A Review". *Comprehensive Reviews in Food Science and Food Safety* 9, 620-634. <https://doi.org/10.1111/j.1541-4337.2010.00130.x>
16. Hida, N., Bidin, N., Abdullah, M., Yasin, M. (2013). "Fiber optic displacement sensor for honey purity detection in distilled water". *Optoelectronics and Advanced Materials – rapid communications* 7, 565 - 568.
17. Cruz-Domínguez, O., Guirette-Barbosa, O., Carrera-Escobedo, J., Duran-Muñoz, H., Guzman-Valdivia, C., Ruelas-Santoyo, E. (2021). "Use of partial quality function deployment to identify processes required for iso 9001". *The South African Journal of Industrial Engineering* 32. <https://doi.org/10.7166/32-2-2415>
18. Guzmán-Fernández, M., Zambrano de la Torre, M., Ortega-Sigala, J., Durán-Muñoz, H. (2021). "Arduino: a Novel Solution to the Problem of High-Cost Experimental Equipment in Higher Education". *Exp Tech* 45, 613–625. <https://doi.org/10.1007/s40799-021-00449-1>
19. Gordon, J. and Harman, S. (2002). "A Graduated Cylinder Colorimeter: An Investigation of Path Length and the Beer-Lambert Law". *J. Chem. Educ.* 79. <https://doi.org/10.1021/ed079p611>



## Revista Internacional de Investigación e Innovación Tecnológica

Página principal: [www.riit.com.mx](http://www.riit.com.mx)

### Toxicity essays and photoprotective effects of partitions of *Euphorbia tirucalli* L.

### Ensayos de toxicidad y efecto fotoprotector de particiones de *Euphorbia tirucalli* L.

García-Hernández, D.G.<sup>a</sup>, Cabanillas-Lomeli, M.L.<sup>b</sup>, Tijerina-Sáenz, A.<sup>b</sup>, Vargas Pérez, M.P.<sup>a</sup>, González Luna, A.R.<sup>a</sup>, Heya, M.S.<sup>b\*</sup>

<sup>a</sup> Universidad Autónoma de Nuevo León, Facultad de Ciencias Biológicas. CP. 66455. San Nicolás de los Garza, Nuevo León, México. <https://orcid.org/0000-0001-8409-139X>; <https://orcid.org/0000-0002-3190-9378>; <https://orcid.org/0000-0002-1943-5181>.

<sup>b</sup> Universidad Autónoma de Nuevo León, Faculty of Public Health and Nutrition. Ave. Pedro de Alba S/ N & Ave. Manuel L. Barragán, San Nicolas de los Garza 66451, Nuevo León, México. Orcid: <https://orcid.org/0000-0002-3154-2633>; <https://orcid.org/0000-0002-6886-4724>.  
[david.garciahrz@uanl.edu.mx](mailto:david.garciahrz@uanl.edu.mx); [manuel.lopezc@uanl.mx](mailto:manuel.lopezc@uanl.mx); [alexandra.tijerinasn@uanl.edu.mx](mailto:alexandra.tijerinasn@uanl.edu.mx);  
[mpvargas05@gmail.com](mailto:mpvargas05@gmail.com); [agonzalezl@uanl.edu.mx](mailto:agonzalezl@uanl.edu.mx); [heyamichelstephane@yahoo.fr](mailto:heyamichelstephane@yahoo.fr)\*

**Technological innovation:** Pharmacological development of photoprotectors based on medicinal plants.

**Industry application area:** This research focuses on the pharmacological effects for the extracts from *E. tirucalli* L.

Received: June 26th, 2023

Accepted: February 12th, 2024

### Resumen

Desde la antigüedad, las plantas han sido utilizadas en la medicina tradicional por sus diversas propiedades terapéuticas; la producción de medicamentos a partir de ellas y su uso para la prevención, atenuación o curación de enfermedades dieron lugar a la fitoterapia, la cual sentó las bases de la farmacopea actual. El objetivo de este trabajo fue evaluar los efectos fotoprotector de extractos obtenidos de *E. tirucalli* L. así como, sus efectos tóxicos sobre eritrocitos humanos y *Artemia salina*, con el fin de proponer el uso de éstos como potenciales agentes dermoprotectores de origen botánico. Mediante el modelo de *Artemia salina*, se obtuvo que las particiones metanólicas y etanólicas eran moderadamente tóxicas, con una DL<sub>50</sub> de 144.77 y 189.54 µg mL<sup>-1</sup>, respectivamente. La prueba de toxicidad sobre eritrocitos (AAPH) reveló que son potencialmente citoprotectoras dosis-dependiente, alcanzando el 99% de inhibición de la hemólisis a 1000 µg mL<sup>-1</sup>.

<sup>1</sup>, lo cual se presume está relacionada con su contenido de polifenoles, respectivamente de 3.52 y 19.46  $\mu\text{g EAG mg}^{-1}$  con la partición metanólica y etanólica, respectivamente. La prueba de fotoprotección demostró que poseen este efecto frente a las radiaciones UV-B, alcanzando un FPS  $> 9$  y  $> 18$ , respectivamente. Como conclusión, la partición etanólica del extracto de *E. tirucalli* L., mostró la mayor actividad citoprotectora, de contenido fenólico y de fotoprotección, además de mostrar moderada toxicidad sobre organismos pluricelulares, por lo tanto, se sugiere continuar con otros ensayos de letalidad para su empleo como fotoprotectores biológicos de uso tópico.

**Palabras claves:** Antioxidante, Dermoprotector, Hemólisis; UV-B.

## Abstract

Plants have long been recognized in traditional medicine for their therapeutic properties, contributing significantly to the evolution of phytotherapy and modern pharmacopoeia. This study aimed to assess the photoprotective effects of *Euphorbia tirucalli* L. extracts and their toxicity on human erythrocytes and *Artemia salina*, with a view to proposing them as potential dermoprotective agents.

Using the *Artemia salina* model, both methanolic and ethanolic partitions exhibited moderate toxicity, with LD50 values of 144.77  $\mu\text{g mL}^{-1}$  and 189.54  $\mu\text{g mL}^{-1}$ , respectively. Subsequent erythrocyte toxicity tests (AAPH-) indicated dose-dependent cytoprotective effects, reaching 99% inhibition of hemolysis at 1000  $\mu\text{g mL}^{-1}$ , likely attributable to their polyphenol content: 3.52  $\mu\text{g EAG mg}^{-1}$  and 19.46  $\mu\text{g EAG mg}^{-1}$  for methanolic and ethanolic partitions, respectively.

Furthermore, the photoprotection test demonstrated significant efficacy against UV-B radiation, with calculated Sun Protection Factor (SPF) values exceeding 9 and 18 for methanolic and ethanolic partitions, respectively.

In conclusion, the ethanolic partition of *Euphorbia tirucalli* L. extract displayed the highest cytoprotective activity, phenolic content, and photoprotection. Despite moderate toxicity on multicellular organisms, further lethality testing is recommended to explore their potential as biological photoprotectors for topical use.

**Keywords:** Antioxidant, Dermoprotective, Hemolysis, UV-B

## 1. Introduction

Various vital functions in humans, such as vitamin D synthesis, vasodilation of the upper layers of vessels, epidermal layer thickness, and melanin secretion, are associated with sunlight exposure. However, excessive exposure to solar radiation poses significant risks, including sunburn, cancer, and the photoaging process.

The adverse effects of solar radiation stem from its ionizing effect within the ultraviolet (UV) spectrum, which comprises UV-C ( $< 280$  nm), UV-B (280-320 nm), and UV-A (320-400 nm). Despite UV-B radiation constituting only 5% of total solar radiation reaching the Earth's surface, studies have linked its exposure to neoplasias, mutations, photoaging, immunosuppression, cataracts, and photosensitivity.

Mexico, situated in a warm tropical zone with intense UV radiation, experiences UV indices ranging from 6 to 12 throughout the year, leading to sunburn, erythema, and desquamation. Consequently, the use of sunscreens becomes imperative.

Despite the increasing availability of sunscreen products containing compounds capable of filtering solar radiation (e.g., p-aminobenzoic acid, salicylates, benzophenones), skin cancer diagnoses persist, with fatalities attributed to malignant melanoma, particularly in sun-exposed areas such as the face, neck, head, and back of hands. The limited protective efficacy of these compounds and their potential to exacerbate dermatitis risk highlight the need for alternative solutions, including biological sunscreens with enhanced protection and compatibility with the body's natural defense mechanisms. Given antioxidants' ability to mitigate solar radiation's harmful effects, there is growing interest in developing botanical-based products with antioxidant properties.

Furthermore, synthetic photoprotectors degrade over prolonged sun exposure, diminishing their protective efficacy. Given that UV radiation induces free radical production, products capable of providing both photoprotection and cytoprotection are crucial to bolstering the body's natural defense mechanisms.

*Euphorbia tirucalli* L., a shrubby plant indigenous to Africa and colloquially known as pencil fingers, has a history of use in traditional medicine against tumors, excrescences, nodules, and abscesses. Studies have demonstrated its antimicrobial activity against various pathogens and its potential in promoting burn healing.

This study aims to evaluate the photoprotective effects of *E. tirucalli* L. extracts and their toxicity on human erythrocytes and *Artemia salina*, with the intention of proposing them as botanical dermoprotective agents.

## 2. Materials and methods

### *Obtaining plant material*

*Euphorbia tirucalli* L. specimens were collected from the northern region of San Nicolás de los Garza municipality, Nuevo León, Mexico. Taxonomic classification was conducted at the Department of Botany, Faculty of Biological Sciences, Universidad Autónoma de Nuevo León, and registered in the herbarium with folio number 029755. The plant material underwent thorough washing with distilled water and was subsequently dried at 40°C using a 150W white light lamp. Following drying, the material was ground using a manual grinder to facilitate the extraction process. The resulting ground material was stored at room temperature away from light until further use.

### *Preparation of Organic E. tirucalli L. Partitions*

The dried and ground plant material underwent extraction using various solvents (hexane, chloroform, ethanol, and methanol) in a Soxhlet apparatus. The partitions obtained from the extraction process were recovered, and solvents were removed under reduced pressure using a Yamato rotary evaporator (mod. RE200, Japan). The partitions were subsequently dried in an oven (Rios-Rocha, HS-33, Mexico) at temperatures not exceeding 40°C. Once solvent-free, the four partitions were stored at room temperature (20°C) until required for experimentation.

### *Human Erythrocyte Toxicity Test*

The toxicity of the partitions on human erythrocytes was evaluated following

protocols with modifications from Alvarez-Suárez et al. and Botta et al.,<sup>14</sup> In brief, stock solutions of the partitions were prepared by dissolving 50 mg of the partition in 1 mL of methanol and sonicating the mixture by sonication (Ney ULTRASONIK, 19H, USA).

#### *Erythrocyte Solution*

Human blood samples were acquired through venipuncture from willing donors and carefully collected in EDTA tubes to prevent coagulation. To maintain sample integrity, the collected blood was promptly stored at 4°C for a period of 24 hours. Following the storage period, the blood underwent centrifugation at 1000 rpm for 10 minutes to separate its components. The resultant cell pellet underwent a meticulous washing process utilizing a phosphate buffer solution. This solution, formulated with precise proportions, included 8 g NaCl, 0.2 g KCl, 1.15 g Na<sub>2</sub>HPO<sub>4</sub>, 0.20 g KH<sub>2</sub>PO<sub>4</sub>, 0.10 g CaCl<sub>2</sub>, and 0.10 g MgCl<sub>2</sub>•6H<sub>2</sub>O per 100 mL, adjusted to pH 7.4 (CTR Scientific, México). After three rounds of thorough washing, the cell pellet was retrieved via centrifugation (CLAY ADAMS, Sero-Fuge 2001, USA). Subsequently, two separate solutions were prepared utilizing the recovered cell pellet. The first solution comprised a 5% suspension of erythrocytes in phosphate buffer solution (PBS), intended for the hemolysis test. The second solution, a 10% suspension, was designated for the cytoprotection test. Notably, both suspensions were freshly prepared immediately prior to each test. By adhering to this meticulously standardized procedure, the integrity and suitability of the blood samples were preserved, ensuring reliable outcomes in subsequent laboratory analyses.

#### *Hemolysis Test*

Samples were prepared from the stock solution of the partition under analysis (50 mg mL<sup>-1</sup>) by pipetting volumes of 25, 20, 15, 10,

5, and 2.5 µL into 1.5 mL conical tubes. To each tube, the appropriate volume of phosphate-buffered saline (PBS) was added to achieve a final volume of 1 mL. Subsequently, 250 µL of the 5% erythrocyte suspension (ERS 5%) was added to each tube, resulting in final partition concentrations of 1000, 800, 600, 400, 200, and 100 µg mL<sup>-1</sup>, respectively. Each assay was performed in triplicate.

Blanks were prepared by mixing the corresponding partition with PBS solution without the addition of ERS 5%. Furthermore, solvent inactivation checks were conducted by replacing partition volumes with equivalent solvent volumes and adjusting with PBS to a final volume of 1250 µL. Distilled water was employed as a positive control, while PBS served as the negative control.

Following preparation, each system mixture was incubated at room temperature for 30 minutes and then centrifuged at 13,500 rpm for 5 minutes at 4 °C (Select spin, 17T, USA). Subsequently, 200 µL of the supernatant from each system was transferred to a 96-well microplate, and absorbance was measured at λ = 550 nm using a TS Absorbance Reader (Biotek elx800, USA). Hemolysis percentage (%H) was determined using the formula 1<sup>14</sup>:

$$\%H = \frac{[Abs(x) - Abs(-)]}{[Abs(+) - Abs(-)]} * 100$$

**Formula 1.** Percentage of hemolysis (%H).

Abs (x): individual absorbance of the sample, obtained at 540 nm.

Abs (-): absorbance of the blank at 540 nm.

Abs (+): absorbance of the positive control at 540 nm.

#### *Toxicity test on Artemia salina*

The bioassay was conducted following the protocol outlined by Leos-Rivas et al<sup>13</sup>.

Initially, 10 nauplii (larval stage of *Artemia salina*) were introduced into each well of a 96-well microplate containing 100  $\mu\text{L}$  of saline solution (Costar, Corning, USA). To evaluate the toxicity of the partitions under study (methanolic and ethanolic), 100  $\mu\text{L}$  of the partition at an initial concentration of 1900 ppm was added, followed by serial dilutions to achieve concentrations ranging from 475 to 0.232 ppm, with each dilution performed in triplicate. Following a 24-hour exposure period to the partitions, deceased nauplii were enumerated using a stereoscope (Lieder, MC-720X, USA). Statistical determination of the Lethal Dose 50 (LD50) was conducted via linear regression analysis using the PROBIT method, facilitated by the SPSS V 20® software (IBM, USA).

#### *Cytoprotection test*

The antihemolytic activity of the ethanolic and methanolic partitions extracted from *Euphorbia tirucalli* L. was assessed using the AAPH• assay, following the methodology described by Botta et al<sup>14</sup>. Similar to the hemolysis test, mixing systems were prepared with volumes adjusted accordingly. The 10% erythrocyte suspension (ERS) was exposed to the AAPH• radical (CTR Scientific, México) in the presence of varying concentrations of the partition under evaluation. The mixture was then incubated at 37°C for 150 minutes with constant agitation (Luzeren, THZ 100, México).

Following incubation, the mixture underwent centrifugation at 13,500 rpm for 5 minutes at 4°C, and the resulting supernatant (200  $\mu\text{L}$ ) was transferred to a 96-well microplate. Absorbance was measured at 540 nm using a Bio-Tek ELx800 spectrophotometer (USA). A positive control comprising a mixture of 10% ERS, PBS, and AAPH• was utilized, while a negative control consisted of a mixture of PBS and 10% ERS.

Given that the partitions were dissolved in methanol, an additional test was conducted by exposing erythrocytes to the AAPH• reagent in the presence of methanol volumes proportional to the partition concentrations. Blanks with extracts were prepared using a mixture of PBS and the respective partition, yielding final concentrations ranging from 100 to 1000  $\mu\text{g mL}^{-1}$ . Each assay was carried out in triplicate.

The percentage of cytoprotection was calculated using the following formula<sup>14</sup>:

$$\%C = \left[ 1 - \frac{[Abs(x) - Abs(-)]}{[Abs(+) - Abs(-)]} \right] * 100$$

**Formula 2.** Percentage of cytoprotection.

Abs (x): individual absorbance of the sample, obtained at 540 nm.

Abs (-): absorbance of the blank at 540 nm.

Abs (+): absorbance of the positive control at 540 nm.

#### *Sun Protection Factor of crude partitions of E. tirucalli L.*

The Sun Protection Factor (SPF) was determined following the method outlined by Mansur et al<sup>19</sup>. Initially, stock solutions of each partition (methanolic and ethanolic) were prepared at a concentration of 1 mg mL<sup>-1</sup>. Subsequently, dilutions were made to achieve concentrations of 0.25, 0.2, 0.15, 0.1, and 0.05 mg mL<sup>-1</sup>. The absorbance of each system was measured within the UV-B wavelength range of 290 to 320 nm using a scanning spectrophotometer (UNICO, SQ-2800), with 5 nm increments. Methanol served as the blank, while benzophenone (Sigma-Aldrich) was utilized as the positive control. All assays were conducted in triplicate to ensure accuracy and reproducibility. The SPF was then calculated using the following formula:

$$FPS = CF \sum_{290}^{320} EE(\lambda) * I(\lambda) * Abs(\lambda)$$

**Formula 3.** Sun Protection Factor.

Where, SPF= Sun Protection Factor, CF (correction factor) = 10, EE ( $\lambda$ )=

Erythemogenic effect of radiation of wavelength  $\lambda$ . I ( $\lambda$ ) = Intensity of the sun at wavelength  $\lambda$ ; Abs ( $\lambda$ )= Absorbance of the solution at wavelength  $\lambda$  (Table 1).

**Table 1.** EE ( $\lambda$ )\* I ( $\lambda$ ) constants defined by Mansur et al 19 for SPF calculation.

$\lambda$	290	295	300	305	310	315	320	Total
EE( $\lambda$ ) * I( $\lambda$ )	0.0150	0.0817	0.2875	0.3278	0.1864	0.0839	0.0180	1

**Table 2.** Phytochemical tests.

Compounds and functional groups	Test	Test development	Interpreting
Carboxyl group	NaHCO <sub>3</sub>	Add 100 $\mu$ L of sodium bicarbonate (10 %, w/w) to the solution*.	The test is positive if carbon dioxide bubbles are released.
Carbonyl group		Add 100 $\mu$ L of the reagent 2,4-DNFH (2,4-dinitrophenylhydrazine) to the solution*.	The test is positive if a yellow, red or orange precipitate is formed.
Tannins	FeCl <sub>3</sub>	Add 100 $\mu$ L of reagent (5% w/w in ethanol) to the solution*.	The test is positive if a dark green or black coloration is observed.
Sterols and terpenes	Liebermann-Burchard	100 $\mu$ L of Liebermann-Burchard reagent, consisting of a mixture of acetic anhydride (1 mL), chloroform (1 mL) and concentrated sulfuric acid (0.1 mL), was added to the solution*.	A red coloration indicates the presence of terpenes, while a blue coloration indicates the presence of sterols.
Carbohydrates	Antrona	Suspend the partition (1 mg) in water and add a few drops of an anthrone solution (0.2%, v/v) in concentrated sulfuric acid.	The test is positive if a blue-green or violet ring appears on the interface.
Flavonoids	Shinoda	Add 100 $\mu$ L of concentrated hydrochloric acid and one or two magnesium filings.	Appearance of deep red color: presence of flavonoids, while green/blue color: presence of flavonones, flavonones, flavonols, flavonols or xanthonones.
Alkaloids	Mayer	Add a few drops of hydrochloric acid to the solution*.	Blue coloration indicates the presence of alkaloids.
Sesquiterpenes	Baljet	Add a few drops of solution A and B to 3 mg of dissolved partition in 1 mL of solvent.	Orange or dark red coloration indicates the presence of sesquiterpenes.
Saponins	Foams	Dissolve each partition in 1mL of water and shake.	The appearance of persistent foams indicates the presence of saponins.

### **Phytochemical profile:** Verde-Star *et al*<sup>21</sup>

#### Total phenol content

The total phenolic content in the partitions was assessed following the protocol outlined by Shahidi and Naczki<sup>22</sup>. The experiments were conducted in triplicate using a macrodilution system. Initially, a calibration curve was constructed using gallic acid as the standard, covering a concentration range of 2 to 20  $\mu$ g mL<sup>-1</sup>. For the analysis of each partition, 250  $\mu$ L of a partition stock solution (0.2 mg/mL) was combined with 750  $\mu$ L of methanol to achieve a final concentration of 0.05 mg mL<sup>-1</sup>. To this mixture, 6 mL of

methanol (CTR Scientific, México) was added, followed by 500  $\mu$ L of Folin-Ciocalteu reagent (MERCK, Germany). The solution was incubated for 5 minutes in darkness. Subsequently, 1.5 mL of sodium carbonate solution (Na<sub>2</sub>CO<sub>3</sub>, 20%, CTR Scientific, México) was added to adjust the pH to 10. The resulting solution was transferred to a 10 mL volumetric flask and kept in darkness at room temperature. After 2 hours, the absorbance was measured at a wavelength of 760 nm using a Beckman Coulter DU®650 Spectrophotometer. A mixture of methanol, Folin-Ciocalteu reagent, and sodium carbonate served as the blank. The total

phenolic content was expressed in micrograms of gallic acid equivalents per gram of extract ( $\mu\text{g GAE mg}^{-1}\text{ E}$ ).

Quantification of total phenols was performed using a gallic acid calibration curve as a reference, which is cited below:

$$\text{Abs} = 0.0171\text{Con. gal. ac.} - 0.0042$$

**Formula 4.** Total phenol content.

Where, "Abs" is the absorbance and "Con.gal.ac" is the concentration of gallic acid.

#### *Statistics*


The data obtained were analyzed using the SPSS V 20® (IBM, USA) software, employing analysis of variance (ANOVA) and Tukey's test to assess significant differences between treatments and to compare means for treatment homogeneity, respectively. Each assay was conducted in triplicate. Treatment responses were deemed statistically significant at  $p \leq 0.05$ .

### **3. Results and discussions**

#### *Toxicity test on human erythrocytes*

The hemolysis assay involved exposing human erythrocytes to various partitions of *Euphorbia tirucalli* L. as illustrated in Figure 1, the hemolytic effect of these partitions exhibited a dose-dependent relationship. At

concentrations equal to or below  $100 \mu\text{g mL}^{-1}$ , minimal hemolytic effects were observed across all partitions. However, distinctions in hemolytic potency became more pronounced beyond  $600 \mu\text{g mL}^{-1}$ . For instance, at  $1000 \mu\text{g mL}^{-1}$ , the hexanolic partition demonstrated the highest hemolytic effect (~50%), followed by the chloroformic partition with a 10% effect; conversely, the methanolic and ethanolic partitions exhibited minimal hemolytic effects (<5%) at this concentration. Statistical analysis via ANOVA ( $\alpha \leq 0.05$ ) confirmed significant differences in hemolytic effects across varying concentrations. Furthermore, Tukey's test ( $p \leq 0.05$ ) indicated homogeneity among the effects of partitioning treatments (i.e., chloroformic, methanolic, and ethanolic) and controls (i.e., negative and methanol) at concentrations equal to or below  $600 \mu\text{g mL}^{-1}$ . This suggests that the beneficial biological effects of these partitions (i.e., ethanolic, methanolic, and chloroformic) could be harnessed in human applications without posing a significant risk. Notably, as per Sylwia Cyboran et al<sup>23</sup> and Lux et al<sup>24</sup>, the cytotoxicity test conducted on human erythrocytes provides valuable insights, indicating that damage to their cell membrane may correlate with susceptibility in more complex cells with a greater number of organelles.



**Figure 1.** Hemolytic effect of the partitions obtained from *E. tirucalli* L. as a function of concentration ( $n=3$ ).


#### Toxicity on *A. salina*

The regression analysis in PROBIT revealed that partitions containing methanol and ethanol were classified as "moderately toxic" according to CYTED 25, with LD50 values of 189.54 and 144.77  $\mu\text{g mL}^{-1}$ , respectively. This observation may be attributed to the absence of alkaloids in the extracts investigated in this study, which are often associated with the toxicity of plant extracts<sup>26</sup>. The moderate toxicity observed in the methanolic and ethanolic partitions towards *A. salina* suggests that their pharmacological potential could be harnessed for human therapeutic applications<sup>27</sup>, pending further comprehensive toxicological evaluations

#### Cytoprotection test

Following the observation of the methanolic and ethanolic partitions' low hemolytic percentages, their cytoprotective effects on human erythrocytes against AAPH• radical-induced hemolysis were subsequently assessed. The erythrocyte suspension (10%) was subjected to AAPH• exposure for 2 hours

and 30 minutes at 37°C under moderate agitation. As depicted in Figure 2, both partitions demonstrated an effective cytoprotective effect at concentrations  $\geq 200 \mu\text{g mL}^{-1}$ , completely preventing hemolysis. However, above 100  $\mu\text{g mL}^{-1}$ , a decline in cytoprotective efficacy was noted for both partitions, with values of 55% and 35% observed for the ethanolic and methanolic partitions, respectively. In contrast, the positive control (ERS + PBS + AAPH•) exhibited 100% hemolysis induced by AAPH•, while the negative control (ERS + PBS) showed no hemolysis. ANOVA analysis indicated a significant difference ( $\alpha \leq 0.05$ ) between treatments (i.e., partitions and controls), while Tukey's test revealed homogeneity in the effects of treatments from 200 to 1000  $\mu\text{g mL}^{-1}$  (cytoprotection  $> 95\%$ ). This cytoprotective effect could be attributed to the presence of tannins and flavonoids in the partitions, as previous studies have highlighted the antioxidant potential of polyphenols<sup>11,28-30</sup>. The observed lower cytoprotection at 100  $\mu\text{g mL}^{-1}$  may be attributed to the lower treatment concentration<sup>30</sup>.



**Figure 2.** Cytoprotective effect on human erythrocytes of ethanolic and methanolic partitions of *E. tirucalli* L. as a function of concentration ( $n=3$ ).

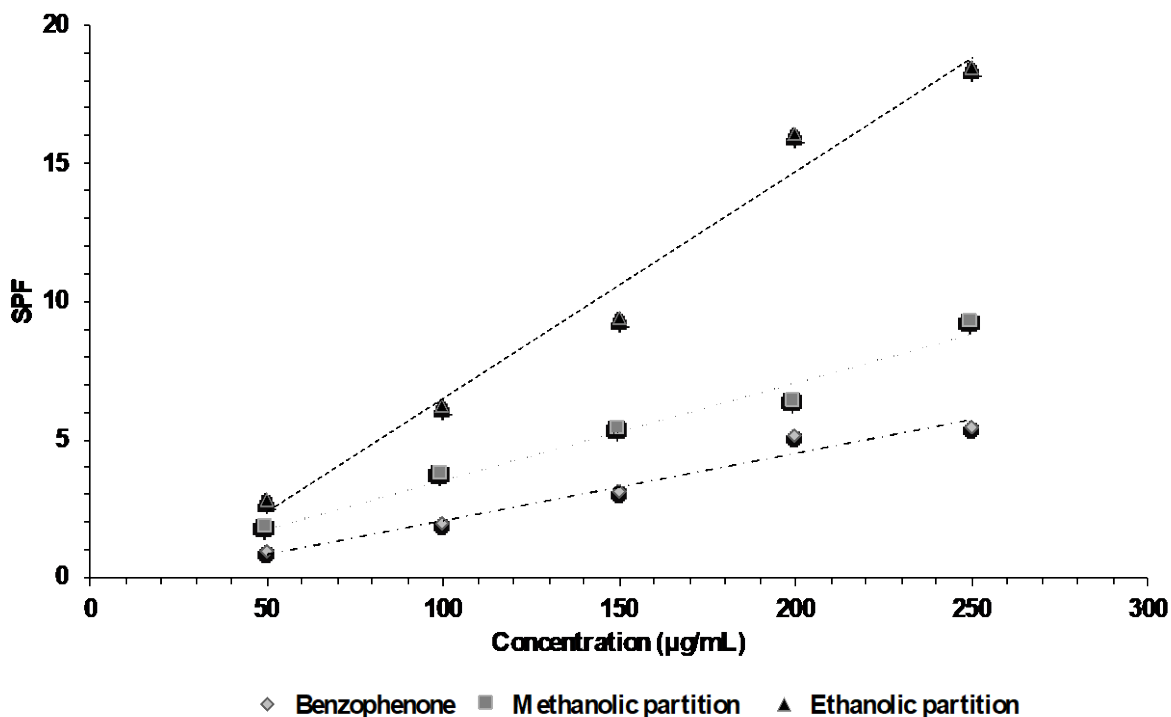
### Sun Protection Factor

Extrinsic factors like pollution and chemicals pose threats to skin health, but UV radiation stands out as the primary culprit behind skin cancer and cellular aging<sup>31</sup>. Solar radiation, particularly UV-B rays, induces mutagenesis, carcinogenesis, and cellular senescence by directly affecting cellular DNA<sup>32</sup>. Recognizing these risks, our study delved into the photoprotective potential of methanolic and ethanolic partitions extracted from *E. tirucalli* L. using the in vitro method outlined by Mansur<sup>19</sup>, with benzophenone from Sigma-Aldrich serving as the positive control.

As depicted in Figure 3, both partitions exhibited significant photoprotective effects against UV-B radiation at a concentration of 250 µg mL<sup>-1</sup>. The Sun Protection Factor (SPF) was calculated as 9.25 for the methanolic partition and an impressive 18.42

for the ethanolic partition, surpassing the SPF of 5.4 observed for benzophenone. ANOVA analysis confirmed significant differences among the three treatments at a significance level of  $\geq 95\%$ . Notably, the ethanolic extract demonstrated the highest SPF, offering over three times the protection compared to benzophenone (at concentrations ranging from 100 to 250 µg mL<sup>-1</sup>). Moreover, the methanolic extract exhibited a higher SPF compared to the positive control.

Ramos and Ivonne<sup>33</sup> suggested that the photoprotective potential of these extracts may stem from their polyphenol content, as evidenced in their phytochemical profile. The presence of these compounds likely contributes to the observed variations in SPF values between the ethanolic and methanolic partitions. Specifically, the ethanolic partition boasted a higher total polyphenol content (19.46 µg EAG mL<sup>-1</sup>) compared to the methanolic partition (3.52 µg EAG mL<sup>-1</sup>).



**Figure 3.** Sun protection factor (SPF) against UV-B radiation (290-320 nm) of the methanolic and ethanolic partitions, using benzophenone as a positive control at different concentrations (50-250 µg mL<sup>-1</sup>) with respect to the extracts ( $n=3$ ).

#### Phytochemical profile

The phytochemical analysis unveiled distinct compounds across the partitions: sterols and triterpenes in the hexane partition, tannins, flavonoids, sterols, and sesquiterpenolactones in the chloroformic partition, carboxyl groups, tannins, sterols, carbohydrates, flavonoids, and saponins in the ethanolic partition, and carboxyl groups, tannins, sterols, triterpenes, carbohydrates, flavonoids, sesquiterpenolactones, and saponins in the methanolic partition<sup>21</sup>. Previous studies have corroborated the presence of various compounds in the aerial parts of *E. tirucalli* L., including sterols (campesterol, stigmasterol, beta-sitosterol, isofucosterol, and cycloartenol), triterpenes (taraxerane and cycloeuphordenol), tannins (*tirucallin* A), polyphenols (*tirucallin* B, euphorbine A, euphorbine F), and sesquiterpenes (*tirucadalenone*)<sup>34</sup>.

#### Total phenols

The results revealed that the ethanolic partition exhibited a notably higher content of total polyphenols, quantified at 19.4588 µg EAG/mg of extract, compared to the methanolic partition, which yielded 3.52 µg EAG/mg of extract. This discrepancy may be attributed to the presence of tannins (specifically *tirucallin* A) and flavonoids in the ethanolic partition, whereas the methanolic partition contained only flavonoids, serving as a reference to polyphenols. These compounds are widely recognized for their antioxidant properties, capable of scavenging superoxide anions and hydroxyl radicals. Notably, as highlighted by Aisah et al<sup>17</sup>, the tannins identified in the ethanolic extract of *E. tirucalli* L. possess remarkable wound-healing potential, representing an additional positive biological effect of the partitions suitable for skin application.

#### 4. Conclusions

Tests conducted on human erythrocytes demonstrated that both the methanolic and ethanolic partitions exhibited non-hemolytic properties and displayed potential dose-dependent cytoprotective effects. Moreover, in terms of photoprotective activity, both partitions surpassed the sun protection factor of the positive control (Benzophenone). These combined biological activities suggest that the topical application of *E. tirucalli* L. partitions could potentially support the natural renewal system of the human body owing to their cytoprotective effects. These activities complement the previously reported benefits of *E. tirucalli* L. extracts, such as their antimicrobial properties and promotion of collagen synthesis. However, given the findings from the *A. salina* model, further toxicity testing is warranted to mitigate any potential adverse effects associated with topical application.

#### 5. Acknowledgments

Thanks to Dr. Eduardo Sánchez García for the technical facilities provided.

#### 6. References

1. Rhodes LE. Topical and systemic approaches for protection against solar radiation-induced skin damage. *Dermatol Clin.* 1998;16:75–82. [https://doi.org/10.1016/S0738-081X\(97\)00171-5](https://doi.org/10.1016/S0738-081X(97)00171-5)
2. Baliga MS, Katiyar KS. Chemoprevention of photocarcinogenesis by selected dietary botanicals. *Photochem Photobiol Sci.* 2006; 5, 243-253. doi: 10.1039/b505311k
3. Sklar LR, Almutawa F, H. W. Lim, Hamzavi I. Effects of ultraviolet radiation, visible light, and infrared radiation on erythema and pigmentation: a review. *Photochem Photobiol Sci.* 2013; 12, 54-64. doi: 10.1039/c2pp25152c
4. Koh HK, Geller AC, Miller DR, Grossbart TA, Lew RA. Prevention and early detection strategies for melanoma and skin cancer. *Arch Dermatol.* 1996;132:436-43.
5. Wikonkai NM, Brash DE. Ultraviolet radiation induced signature mutations in photocarcinogenesis. *J Invest Dermatol Symp Proc.* 1999;46-9.
6. Yaar M, Gilchrest BA. Aging and photoaging: postulated mechanisms and effectors. *J Invest Dermatol Symp Proc.* 1998;3:47-51.
7. Nishigori C, Yarosh DB, Donawho C, Kripke ML. The immune system in ultraviolet carcinogenesis. *J Invest Dermatol Symp Proc.* 1996;1:143-6.
8. Sliney DH. Epidemiological studies of sunlight and cataract: the critical factor of ultraviolet exposure geometry. *Ophthalmic Epidemiol.* 1994;1: 07-19.
9. Stevanato R, Bertelle M, Fabris S. Photoprotective characteristics of natural antioxidant polyphenols. *Regul Toxicol Pharmacol.* 2014; 69:71–77. doi: 10.1016/j.yrtph.2014.02.014
10. Secretaría del Medio Ambiente de la Ciudad de México (SEDEMA), «Índice de Radiación Ultravioleta,» [En línea]. Available: <http://186.96.0.232/aire/default.php?opc=%27ZaBhnmI=&dc=%27aA==>. [Último acceso: 10 Enero 2024].
11. Dutra EA, Oliveira DA, Kedor-Hackmann ER, Santoro MI. Determination of sun protection factor (SPF) of sunscreens by ultraviolet spectrophotometry. *Braz J Pharma Sci.* 2004, 40,381-5.

12. Reuter J, Merfort I, Schempp CM. Botanicals in dermatology: an evidence-based review. *Am J Clin Dermatol*. 2010; 247–267
13. Leos-Rivas C, Rivas-Morales C, García-Hernández D. Actividad antioxidante y toxicidad. Investigación en plantas de importancia médica. Barcelona, España: OmniaScience. 2016. 41-76.
14. Botta A, Martínez A, Balboa V, Conde E, Vinardell E, Pilar M. Toxicology in vitro erythrocytes and cell line-based assays to evaluate the cytoprotective activity of antioxidant components obtained from natural sources', toxicology in vitro. 2014. 28(1), pp. 120–124. doi: 10.1016/j.tiv.2013.10.004.
15. Yi QS, Wan Zarina ZA, Nurulhidayah CN, Mohamad Ezany Y, Azlina A, Suharni M. The Antibacterial Properties of *Euphorbia tirucalli* stem extracts against dental caries-related bacteria. 2017; 12(1): 34–41.
16. Gupta N, Vishnoi G, Wal A, Wal P. Medicinal Value of *Euphorbia tirucalli*. 2013; 4(1). doi: 10.4103/0975-8453.135843.
17. Upadhyay B, Singh KP, Kumar A, Ethno-medicinal, Phytochemical and Antimicrobial studies of *Euphorbia tirucalli* L. *Journal of Phytology* 2010; 2:65-77.
18. Aisah S, Utami PI, Genatrika E. The effectiveness of ointment of patah tulang stem's (*Euphorbia tirucalli*) ethanol extract for burn wound healing on white rats (*Rattus norvegicus*). 2018. doi: 10.1088/1757-899X/288/1/012055.
19. Mansur J, Breder M, Mansur M, Azulay R. Determinação do fator de proteção solar por espectrofotometria. *An. Bras. Dermatol*. 1986; 61 (1): 121-124
20. Sayre R, Desrochers D, Marlow E. Sunscreen testing methods: in vitro predictions of Effectiveness. *J. Soc. Cosmet. Chem*. 1980; 31 (1): 133-43
21. Verde-star MJ, García-gonzález S, Rivas Morales C. Metodología científica para el estudio de plantas medicinales. Investigación en plantas de importancia médica. Barcelona, España: OmniaScience. 2016; 1-40
22. Shahidi F, Naczk M. Methods of analysis and quantification of phenolic compounds. Technomic Publishing Company. 1995;287-293
23. Sylwia Cyboran, Jan Oszmiański, Halina Kleszczyńska. Interaction between plant polyphenols and the erythrocyte membrane. *Cell Mol Biol Lett*. 2012 Mar; 17(1): 77–88. 12. doi: 10.2478/s11658-011-0038-4
24. Lux Wttse. Red blood cell membrane disorders. *Br J Haematol*. 2005; 104:2–13. Available from: <https://doi.org/10.1111/j.1365-2141.1999.01130.x>
25. Gupta M. 270 plantas Medicinales Iberoamericanas. (Colombia: Convenio Andres Bello, CYTED).1995; p.p. 413-418.
26. Azzeme A, Adibah M, Zaman K. Plant toxins: alkaloids and their toxicities GSC Biological and Pharmaceutical Sciences Plant toxins: alkaloids and their toxicities. 2019. doi: 10.30574/gscbps.2019.6.2.0003.
27. McLaughlin JL, Lingling LR, Anderson JE. The use of biological assays to evaluate botanicals. *Drug Information J*. 1998; 32:513-524.
28. Chaudhuri S, Anwesha B, Kaushik B, Bidisa S, Pradeep KS. Interaction of

flavonoids with red blood cell membrane lipids and proteins: Antioxidant and antihemolytic effects. 2007. 41, 42–48. doi: 10.1016/j.ijbiomac.2006.12.003.

29. Martínez-Flórez S, González-Gallego J, Culebras M, Tuñón J. Los flavonoides: propiedades y acciones antioxidantes. Nutr. Hosp. 2002; pp. 271–278.

30. Zhang J, Xiang H, Hussain Ahmad, Hao Zhang, Lili Zhang, Tian Wang Assessment of free radicals scavenging activity of seven natural pigments and protective effects in AAPH-challenged chicken erythrocytes. Food Chemistry. Elsevier Ltd, 145. 2014; pp. 57–65. doi: 10.1016/j.foodchem.2013.08.025.

31. Amores CC, José P, Benavides H. Activos antioxidantes en la formulación de productos cosméticos antienvjecimiento Antioxidant actives in the formulation of antiaging cosmetic products. Ars Pharm. 2018; 59(2), pp. 77–84.

32. Chen L, Hu JY, Wang SQ. The role of antioxidants in photoprotection: a critical review. J Am Acad Dermatol. 2012; 67(5):1013–1024.

33. Ramos C, Ivonne G. Antioxidantes en dermatología Antioxidants in Dermatology. Dermatología CMQ.2010; 8(4), pp. 272–277.

34. Goutam M, Sadhan Kumar RJC. *Euphorbia tirucalli* L. a review on its potential pharmacological use in chronic diseases. International Journal of Scientific Research 2017;8: 241-245.