



Vol. 1. N°. 1
Junio - Noviembre 2024

ISSN L 3072-9696

Facultad de Informática, Electrónica y Comunicación

Más TIC

Revista Especializada en Informática, Electrónica y Comunicación

Más TIC

Revista sobre Ciencia y Tecnología

Publicación Bianual

Facultad de Informática, Electrónica y Comunicación

Universidad de Panamá

Junio – Noviembre 2024

ISSN L 3072-9696

Más TIC es una publicación bianual en línea de la Facultad de Informática, Electrónica y Comunicación de la Universidad de Panamá. Nuestra política editorial e instrucciones para los contribuyentes se encuentran en el portal web.

© Todos los derechos reservados.



**Información de contacto: Facultad de Informática, Electrónica y Comunicación, Campus Octavio Méndez Pereira, Universidad de Panamá.
Tel 523- 6002. Correo electrónico: revista.mastic@up.ac.pa**

AUTORIDADES DE LA UNIVERSIDAD DE PANAMÁ

Eduardo Flores Castro

Rector

José Emilio Moreno

Vicerrector Académico

Jaime Javier Gutiérrez

Vicerrector de Investigación y Postgrado

Mayanín Rodríguez

Vicerrector de Asuntos Estudiantiles

Ricardo Him Chi

Vicerrector de Extensión

Arnold Muñoz

Vicerrector Administrativo

José Luis Solís

Director de Centros Regionales

Ricardo Parker

Secretario General

Javier Fernández

Decano de la Facultad de Informática, Electrónica y Comunicación

Isis De Los Ríos

Vicedecana de la Facultad de Informática, Electrónica y Comunicación

Consejo Editorial

Coordinador responsable

Mgter. Gustavo Díaz, Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación, Panamá

<https://orcid.org/0000-0001-7420-7862>

gustavo.diaz@up.ac.pa

Editor jefe

Comité Editorial

Dr. Iván Montes-Iturrizaga, Universidad María Auxiliadora, Perú

<https://orcid.org/0000-0002-9411-4716>

imontesi@pucp.edu.pe

Ámbar Martínez, Universidad de Panamá, Centro Regional Universitario de San Miguelito, Panamá

<https://orcid.org/0000-0002-5003-8520>

ambar.martinezm@up.ac.pa

José Manuel Gómez Pulido, UAH Universidad Alcalá de Henares, España

<https://orcid.org/0000-0002-6897-8262>

jose.gomez@uah.es

Jesús Escobar Bentué, UAH Universidad Alcalá de Henares, España

<https://orcid.org/0000-0002-7837-8973>

jesus.escobar@uah.es

Mgter. Yarien Moreno, Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación, Panamá

<https://orcid.org/0000-0002-6646-8162>

yarien.moreno@up.ac.pa

Mgter. Carmen Rovira, Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación, Panamá

<https://orcid.org/0000-0003-4277-5691>

carmen.rovira@up.ac.pa

Dr. Jean Francois Duhé, Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación, Panamá

<https://orcid.org/0009-0006-6961-1637>

jean-f.duhe-p@up.ac.pa

José Inácio Maurlio Universidade Estadual de Montes Claros, Brasil

<https://orcid.org/0000-0003-0744-0845>

maurilio.inacio@unimontes.br

Marlon Cristian Toledo Universidade Estadual de Montes Claros, Brasil

<https://orcid.org/0000-0003-1691-0466>

marlon.pereira@unimontes.br

Comité Técnico

Dr. Saúl Ardines, Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación, Panamá

<https://orcid.org/0000-0001-7221-0304>

saul.ardines@up.ac.pa

Mgter. Angélica Pierre, Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación, Panamá

<https://orcid.org/0000-0002-6854-7518>

angelica.pierre@up.ac.pa

Carlomagno Sancho Noriega, Universidad Nacional de Frontera, Perú

<https://orcid.org/0000-0002-6828-675X>

csancho@unf.edu.pe

Comité Científico

Allyson Steve Mota, Universidade Estadual de Montes Claros, Brasil

<https://orcid.org/0000-0002-1647-3916>

steve.lacerda@unimontes.br

Dra. Karel Llopiz Guerra, Universidad Central Marta Abreu de las Villas, Cuba

<https://orcid.org/0000-0002-1500-8000>

kllopiz@uclv.cu

INDICE

Editorial	ix
Análisis de competencias en el curso de programación II (estructuras de datos) en el turno nocturno de la FIEC Universidad de Panamá: Licenciatura en Informática Aplicada a la Enseñanza e Implementación de Tecnologías, año 2022. – Carlos Chávez	10
Uso y aplicación del aprendizaje automático para crear modelos en la toma de decisiones en el área de la salud – Denis Cedeño	23
Industria 4.0 en la Era del 5G: Oportunidades y Desafíos en la Automatización del Hogar mediante el Internet de las Cosas - César Delgado, Mariela Sánchez, Librada Velasco	35
Desarrollo de una Aplicación Móvil para Divulgación de la Producción Científica en Redes Sociales – José Murillo, Edgar Pérez-Rivera, Francisco Farnum	45
Consideraciones sobre el IoT en el Diseño, Construcción y Gestión del Mantenimiento de Edificios – Marjorie de Gómez, Cristóbal Gómez	57
Arquitectura de robot semiautónomo de Búsqueda y Rescate de Rápida Manufactura – Yenikarina Salazar, Iván Armuelles	64
Estudio de las llamaradas solares y su influencia en los canales de comunicación electrónica mediante la implementación de un sistema de monitoreo para la banda de frecuencia VLF – Axel Márquez, Angie Márquez, Fermín Póvaz	73

Algoritmos de Aprendizaje Automático en la Predicción del Rendimiento Académico 92
Universitario: una Revisión Sistemática – **Fabiola Montero, Nelson Montilla, Julio
Arcia**

IoT y la amenaza de Amazon Sidewalk: protegiendo tu hogar y tu privacidad – 120
Jenny Ríos

Uso de prototipo de generación de energía eólica; como método de 128
aprendizaje alternativo de las leyes de Lenz y Faraday **Javier Fernández –
Denis Rubin,**

Editorial

Con gran entusiasmo les damos la bienvenida al lanzamiento de la primera edición de la revista de investigación científica *MásTIC*, una publicación impulsada por la Facultad de Informática, Electrónica y Comunicación de la Universidad de Panamá.

Con la continua incorporación de avances tecnológicos en todos los ámbitos de nuestra vida, la revista *MásTIC* se establece como un espacio que promueve el intercambio de ideas y la creación de soluciones tecnológicas innovadoras, aplicables a distintos campos del conocimiento. Estamos convencidos de que las fronteras entre disciplinas están desapareciendo, y que la colaboración interdisciplinaria es clave para abordar los retos actuales y futuros. En ese sentido, la revista tiene como objetivo ser un punto de convergencia para la investigación constante en diversas áreas de las tecnologías digitales, abarcando tanto los ámbitos tradicionales, como la informática, la electrónica y las comunicaciones, así como tecnologías emergentes, tales como el Internet de las cosas (IoT), la ciencia de datos, la inteligencia artificial, la automatización, la ciberseguridad, entre otras.

La revista *MásTIC* invita a investigadores, profesionales y estudiantes de diversas áreas de estudio a compartir sus trabajos donde la tecnología y la innovación puedan ser aplicadas a múltiples contextos. Nuestra visión es ser una plataforma para la difusión de investigaciones de alto impacto, abarcando desde las ingenierías y las ciencias exactas, hasta las ciencias sociales, la medicina y la educación, fortaleciendo el diálogo entre disciplinas.

Agradecemos a la Facultad de Informática, Electrónica y Comunicación de la Universidad de Panamá por el apoyo y la visión que ha hecho posible este proyecto. Además, extendemos nuestro reconocimiento a los autores que han confiado en *MásTIC* como plataforma para publicar sus investigaciones, y a los lectores que hacen parte de esta creciente comunidad científica.

Con esta edición inaugural, abrimos un espacio para expandir el conocimiento tecnológico, y en el que cada publicación futura aportará al desarrollo de un futuro más prometedor mediante la ciencia y la innovación.

¡Bienvenidos a *MásTIC*!

El Comité Editorial

Facultad de Informática, Electrónica y Comunicación

Universidad de Panamá

Análisis de competencias en el curso de programación II (estructuras de datos) en el turno nocturno de la FIEC, Universidad de Panamá: Licenciatura en Informática Aplicada a la enseñanza e implementación de tecnologías, año 2022.

Competency analysis in the programming II course (data structures) in the night shift of the FIEC, University of Panama: Bachelor's degree in computer science applied to the teaching and implementation of technologies, year 2022.

Carlos E. Chávez-González

Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación
carlos.chavezg@up.ac.pa <https://orcid.org/0000-0003-0776-9341>

Recibido: 31-1-2023, Aceptado: 8-5-2023

DOI <https://doi.org/10.48204/3072-9696.6337>

RESUMEN

El objetivo del presente estudio es analizar la habilidad para el desarrollo del curso de Programación II (Estructuras de Datos) del turno nocturno de la Facultad de Informática, Electrónica y Comunicación (FIEC) de la Universidad de Panamá: Licenciatura en Informática aplicada a la Enseñanza e Implementación de Tecnologías año 2022, considerando la gran importancia que tiene para los estudiantes y profesores que reciben el curso y lo dictan, respectivamente; por lo cual será de gran utilidad para que la FIEC, la carrera de Licenciatura en Informática aplicada a la Enseñanza e Implementación de Tecnologías, los docentes cuenten con información valiosa para diseñar las estrategias didácticas más convenientes para dictar esta asignatura.

La investigación que se ha desarrollado es de tipo cuantitativa, la población que se estudió son los estudiantes de Licenciatura en Informática aplicada a la Enseñanza e Implementación de Tecnología, grupo nocturno año 2022, realizado con una muestra de 16 estudiantes. Como técnica principal se utilizó la encuesta y como instrumento el cuestionario de formularios de Google, el cual explica la diferencia entre las habilidades y conocimientos previos de los estudiantes respecto a las competencias requeridas. Para medir el grado de asociación entre las variables se utilizó el promedio porcentual.

Se obtuvo como valor medio estadístico un porcentaje de 25%, lo que lleva a concluir que las habilidades y conocimientos previos de los estudiantes es baja. Es decir, que el valor predictivo para las habilidades es muy escaso, y que habría otros factores que están influyendo en los conocimientos de los estudiantes.

PALABRAS CLAVES:

Algoritmo, Estructura lineal, Estructura dinámica, Lista, Pila, Cola, Árbol binario.

ABSTRACT

The objective of this study is to analyze the ability to develop the programming II course (data structures) of the night shift of Facultad de Informática, Electrónica y comunicación (FIEC) of the University of Panama: The research will be very useful for the FIEC, the bachelor's degree in computer science applied to the teaching and implementation of technologies year 2022, considering the great importance it has for students and teachers who receive the course and dictate it respectively; therefore, it will be very useful for the FIEC, the bachelor's degree in computer science applied to the teaching and implementation of technologies, teachers, to have valuable information to design the most appropriate teaching strategies to dictate this subject.

The research that has been developed is of quantitative type, the population that was studied are the students of bachelor's degree in computer science applied to the teaching and implementation of technology, night group year 2022, carried out with a sample of 16 students. The survey was used as the main technique and the Google forms questionnaire was used as an instrument, which explains the difference between the skills and previous knowledge of the students with respect to the required competencies. To measure the degree of association between the variables, the percentage average was used.

A percentage of 25% was obtained as the mean statistical value, which leads to the conclusion that the students' skills and prior knowledge is low. That is, the predictive value for skills is very low, and that there would be other factors that are influencing the students' knowledge.

KEYWORDS:

Algorithm, Linear structure, Dynamic structure, List, Stack, Queue, Binary tree.

INTRODUCCIÓN

Según Cairo. (2006). Estructura de datos, el estudio de las estructuras de datos constituye una de las principales actividades para llegar al desarrollo de grandes sistemas de software.

Es por esto por lo que esta investigación se centra en analizar la habilidad, de los estudiantes, para el desarrollo del curso de Programación II (Estructuras de Datos) del turno nocturno de la Facultad de Informática, Electrónica y Comunicación (FIEC) de la Universidad de Panamá: Licenciatura en Informática aplicada a la Enseñanza e Implementación de Tecnologías año 2022.

Las estructuras de datos se pueden entender como un tipo de dato compuesto (no complejo). Las estructuras de datos permiten almacenar de manera ordenada una serie de valores dados en una misma variable. Las estructuras de

datos más comunes son los arrays, que pueden ser unidimensionales (de una dimensión), también conocidos como vectores o multidimensionales (de varias dimensiones), también conocidos como matrices, aunque hay otras un poco más diferentes como son struct, las enumeraciones y los punteros, listas, pilas, colas y árboles.

El primer problema que se suele presentar al estudiante de estructura de datos que, probablemente, procederá de un curso de nivel básico, medio o avanzado de introducción o fundamentos de programación o bien de iniciación en algoritmos, es precisamente el modo de afrontar información compleja desde el principio.

El objetivo general de esta investigación fue:

Analizar la habilidad para el desarrollo del curso de programación II (estructuras de datos) del turno nocturno de la Facultad de Informática, Electrónica y Comunicación de la Universidad de Panamá: licenciatura en Informática aplicada a la Enseñanza e Implementación de Tecnologías año 2022.

Dicho esto, se plantea el siguiente problema:

Los estudiantes del tercer semestre del curso de Programación II (estructuras de datos) de la facultad de Informática, Electrónica y Comunicación-Licenciatura en Informática Aplicada a la Enseñanza e Implementación a la Tecnología, no muestran un desempeño en competencias y habilidades necesarias para: analizar, desarrollar y diseñar algoritmos que luego deben llevar a la codificación y culminarlos en un programa que represente las operaciones básicas de las estructuras lineales y no lineales dinámicas.

Esta investigación servirá a futuro, de apoyo a los docentes de la Facultad de Informática, Electrónica y Comunicación, que dicten este curso para que pongan en práctica las conclusiones y recomendaciones que surjan de la misma, principalmente a los profesores noveles que les toque dictar esta asignatura por primera vez.

Tendrán un marco de referencia y podrán diseñar actividades didácticas de aprendizajes y de refuerzos, que les asegure la mejor comprensión de los temas, a los estudiantes los cuales podrán afrontar con éxito el análisis, comprensión y posterior puesta en práctica mediante la codificación en programas, de los diferentes tipos de algoritmos y operaciones de las estructuras lineales y no lineales que se presentan durante el desarrollo de la asignatura de Programación II (estructuras de datos).

MATERIALES Y MÉTODOS

Esta investigación se apoyada en el estudio de Essi Lahtinen, Kirsti Alamutka y Hannu Matti Järvinen titulado “A Study of the Difficulties of Novice Programmers” (2005), con la excepción que solo se compararán opiniones de estudiantes.

Esta metodología, va a determinar el rumbo de esta investigación dicho esto, la metodología que se utilizará para el desarrollo de la investigación tendrá un enfoque basado en la metodología cuantitativa.

La metodología cuantitativa según Tamayo (2007) consiste en juntar las teorías existentes a partir del conjunto de hipótesis de resultado necesarias para

obtener muestras aleatorias o identificadas, pero con representación de la población o fenómeno que se investiga.

La metodología cuantitativa, los métodos de recopilación de datos incluyen encuestas en papel o en línea, encuestas móviles, entrevistas personales o telefónicas, entre otras, en nuestro caso utilizaremos la encuesta en línea.

La metodología que se utilizará consiste en lo siguiente: primero se aplicarán encuestas a estudiantes que forman parte de esta investigación. Este tipo de muestreo es no probabilístico, ya que la población meta es un grupo en específico de estudiantes al cual se tendrá acceso.

Luego se analizarán los resultados obtenidos y representados en las gráficas de pastel y de barra de esta encuesta y se podrá confirmar o no la hipótesis planteada al igual que se sacarán las conclusiones, también se podrán hacer las recomendaciones necesarias que ayudarán a contribuir con la resolución del problema.

Este tipo de metodología me ayudará a poder cumplir con las metas y los objetivos planteados en esta investigación, ya que aplicando esta metodología se busca medir y evaluar, como lo mencioné en el párrafo anterior, la veracidad o no de la hipótesis planteada.

El instrumento de investigación que se utilizará será la encuesta, la cual es una técnica de recolección de datos y da lugar a establecer contacto con las unidades de observación por medio de cuestionarios previamente establecidos.

El instrumento más utilizado es el cuestionario, el cual está compuesto por un conjunto de preguntas con respecto a las variables que están sujetas a medición, y es elaborado teniendo en cuenta los objetivos de la investigación.

En este proceso se escogerá un número de 14 preguntas, este cuestionario se dividirá en tres secciones diferentes:

- Generales del estudiante, para conocer el sexo, edad y ubicación geográfica.
- Conocimientos previos y básico de los cursos de informática básica y Programación I, para conocer el nivel de conocimientos, habilidades y competencias previas requeridas para el curso de Programación II.
- Habilidades, competencias y materiales para el desarrollo del curso de Programación II (estructuras de datos).

La población que se estudiará son los estudiantes de licenciatura en informática aplicada a la enseñanza e implementación de tecnología, grupo nocturno año 2022, de la Facultad de Informática, Electrónica y Comunicación con sede en el Campus central de la Universidad de Panamá, la Ciudad Universitaria Octavio Méndez Pereira.

Se encuestará por lo menos al 70% de esta población de 24 estudiantes. La encuesta se aplicó en el primer semestre del año 2022, para que un estudiante pueda estar en el curso de programación II, como prerrequisitos deben haber culminado satisfactoriamente el curso de programación I.

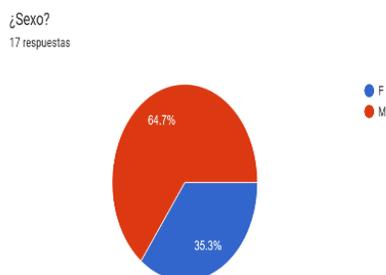
Este muestreo se realizará utilizando la herramienta de formularios de Google, según el sitio de Wikipedia, Formularios de Google (2022). Esta herramienta formularios de Google (en inglés, Google Forms) es un software de administración de encuestas que se incluye como parte del conjunto gratuito Google Docs Editors basado en la web que ofrece Google.

El servicio de formularios de Google ha sufrido varias actualizaciones a lo largo de los años. Las funciones incluyen, entre otras: búsqueda de menú, selección aleatoria de preguntas para un orden aleatorio, limitación de respuestas a una vez por persona, enlaces más cortos, temas personalizados, 2 generación automática de sugerencias de respuestas al crear formularios, 3 y un «Subir archivo» para los usuarios que responden preguntas que requieren que compartan contenido o archivos desde su computadora o Google Drive.

RESULTADOS

Figura 1.

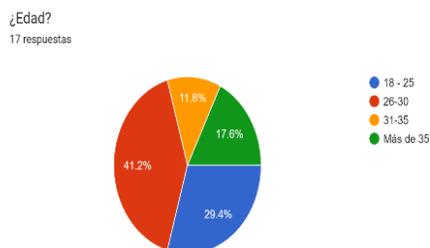
Sexo de los estudiantes.



Se consultó a los estudiantes mediante encuesta virtual. El sexo, esto con la intención de medir cuántos estudiantes son de sexo femenino y masculino, de los cuales pudimos obtener que: El 64.7% son masculinos y el 35.3% son femeninos.

Figura 2

Edad de los estudiantes.



En esta pregunta se buscaba identificar las edades de los estudiantes de la cuales se obtuvo el siguiente resultado:

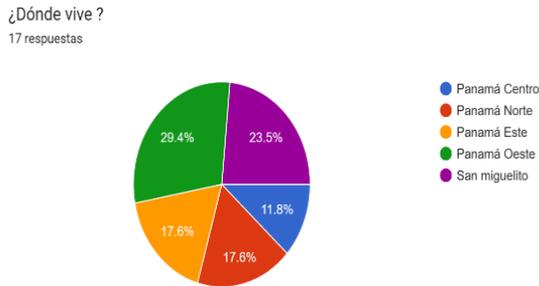
Un 29% está entre las edades de 18-25 años.

Un 41.2% está entre las edades de 26-30 años.

Un 11.8% está entre las edades de 31-35 años.
17.6% está entre las edades de más de 35 años.

Se puede observar en la Figura 2 que la mayoría de los estudiantes están entre las edades de 26 a 30 años, luego le sigue el grupo de edades entre 18 a 25 años. Este rango de edad es donde las personas inician su vida universitaria una vez terminan el nivel secundario.

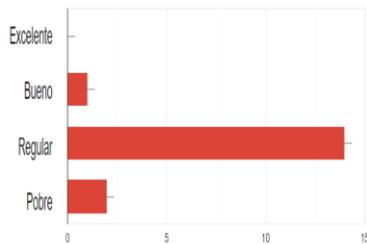
Figura 3
Lugar de residencia de los estudiantes



Esta pregunta se formuló con la intención de saber en dónde viven los estudiantes, de esta forma se tiene una idea de la ubicación geográfica de sus viviendas. Se pudo evidenciar que la mayoría de los estudiantes viven en las áreas de Panamá oeste 29.4% y Panamá centro con un 23.5%.

Figura 4
Dominio de flujogramas y algoritmos

2. ¿Qué grado de dominio tiene usted en análisis y diseño de flujogramas y algoritmos ?
17 respuestas

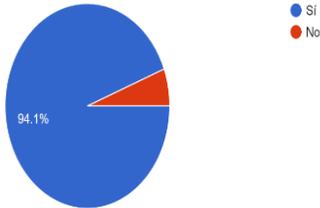


Esta pregunta busca evaluar si los estudiantes, después de completar el curso de Informática Básica, dominan las competencias esenciales, como el análisis y diseño de flujogramas y algoritmos. Se observa que la mayoría no domina completamente estas habilidades, con un dominio que va de regular a pobre. Este nivel insuficiente de conocimiento podría dificultar el éxito en el curso de Programación II, subrayando la necesidad de mejorar la enseñanza y el aprendizaje de las habilidades fundamentales.

Figura 5

Evaluación del curso de programación I

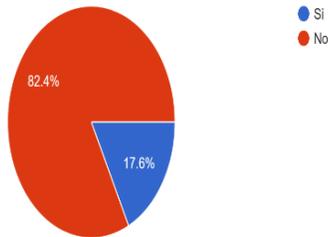
3. ¿En el curso de Programación I se cumplió con el plan de estudios. ?
17 respuestas



La encuesta reveló que el 94.1% de los estudiantes comprobó el plan de estudios del curso de Programación I, mientras que el 5.9% no lo hizo. Esta información es crucial para determinar si los estudiantes están preparados para el curso de Programación II (Estructuras de Datos), ya que Programación I es un prerrequisito que implica dominar aspectos fundamentales de la programación, como la lógica, sentencias condicionales, tipos de datos, funciones, arreglos y punteros. A pesar de completar el plan de estudios, no se garantiza que todos los estudiantes hayan adquirido plenamente estas competencias, lo que subraya la importancia de evaluar continuamente el aprendizaje y la preparación para cursos posteriores.

Figura 6
Manejo de datos en C/C++

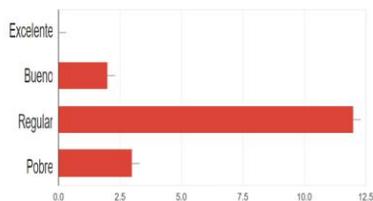
4. ¿Conoce usted a profundidad los diferentes tipos de datos en C/C++?
17 respuestas



Esta pregunta busca evaluar si los estudiantes, después de completar el curso de Programación I, dominan las competencias esenciales. Resulta que un 82.4% de los estudiantes no domina completamente las habilidades enseñadas, incluyendo el manejo de diferentes tipos de datos en C y C++, con solo un 17.6% demostrando un dominio sólido. Este nivel de conocimiento insuficiente podría dificultar el éxito en el curso de Programación II, subrayando la necesidad de mejorar la enseñanza y el aprendizaje de las habilidades fundamentales.

Figura 7
Dominio de sentencias fundamentales

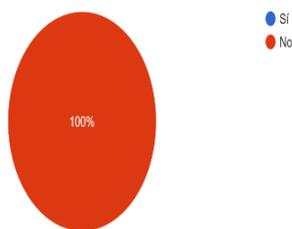
5. ¿Qué grado de dominio tiene usted en sentencias en C/C++ de: Selección - if y else, selección - switch, Cíclica - while. Cíclica - do while. Cíclica - for?
 17 respuestas



La mayoría de los estudiantes muestran un dominio regular o pobre de sentencias fundamentales como if-else, switch while, do- while y for, lo cual es preocupante ya que estas son esenciales para evaluar las habilidades de programación. La falta de dominio en estas sentencias puede dificultar el progreso en el curso de Programación II (Estructuras de Datos), donde su comprensión es crucial para abordar los problemas presentados.

Figura 8
Dominio de Funciones en C/C++

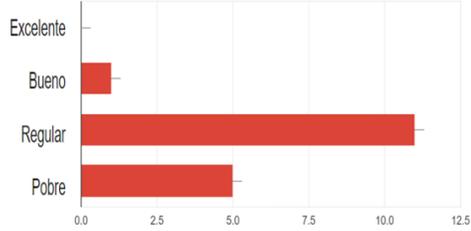
6. ¿Domina usted a profundidad, trabajar con funciones en C/C++?
 17 respuestas



El 100% de los estudiantes respondió que no domina trabajar con funciones. Este resultado es crítico, ya que, si un estudiante no domina trabajar con funciones al programar, significa que no sabe programar, y si no sabe programar las posibilidades que tenga éxito en el curso de Programación II son mínimas.

Figura 9
Dominio de Estructuras en C/C++

7. ¿Qué grado de dominio tiene usted con el tipo de dato estructura en C/C++?
17 respuestas

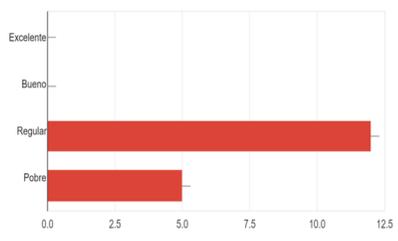


En esta pregunta, la respuesta de la gran mayoría de los estudiantes, el grado de dominio del tipo de datos estructuras, es regular y pobre. Son muy pocos los que indicaron que su grado de dominio es bueno.

Este resultado de esta pregunta es preocupante, ya que el dominio de los tipos de datos estructuras son una de las bases principales que confirman si un estudiante tiene buenas habilidades de programación.

Figura 10
Dominio de punteros

8. ¿Qué grado de dominio tiene usted punteros.?
17 respuestas

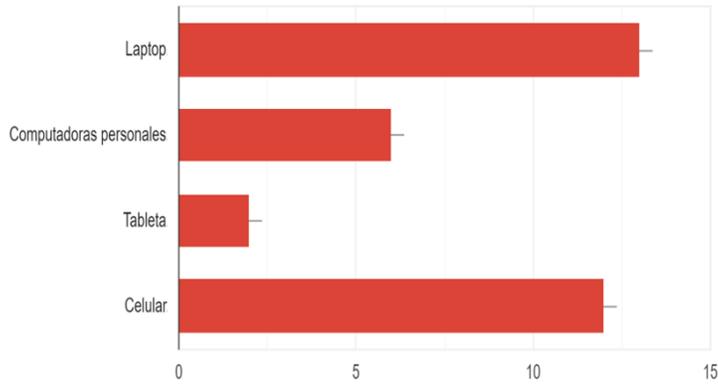


La mayoría de los estudiantes muestran un dominio regular o pobre de los punteros, lo cual es preocupante dado que el manejo de los punteros es crucial para la gestión de la memoria en la computadora. Esta habilidad es esencial en el curso de Programación II (Estructuras de Datos), donde se aplican técnicas como listas, colas, árboles y pilas, lo que indica que los estudiantes que no dominan los punteros enfrentarán desafíos significativos en este curso.

Figura 11
Equipos tecnológicos en casa

9. ¿Cuenta usted con alguno de estos equipos tecnológicos en casa?

17 respuestas



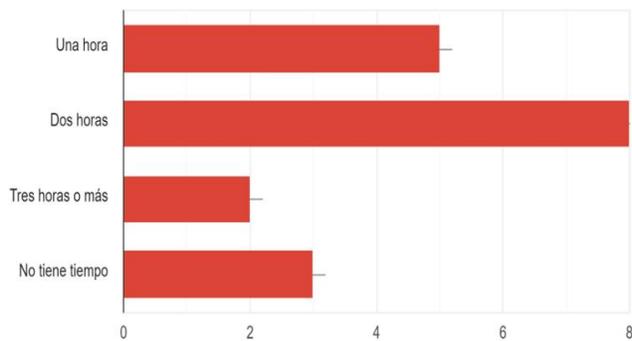
La pregunta intentaba determinar los equipos tecnológicos que poseen los estudiantes, especialmente relevantes para el curso de Programación II (Estructuras de Datos), que se llevó a cabo de manera virtual e incluye tanto teoría como laboratorios. Se descubrió que la mayoría de los estudiantes cuentan con teléfonos móviles, laptops y computadoras personales. Sin embargo, el uso de teléfonos móviles podría ser una desventaja, ya que estos dispositivos pueden tener limitaciones en comparación con laptops y computadoras, lo que podría afectar la realización de tareas.

Figura 12

Tiempo de dedicación al curso de Programación II

¿Qué tiempo de estudio, por semana, le dedica al curso de Programación II (Estructura de Datos).?

17 respuestas



El curso de Programación II (Estructuras de Datos) es crucial para el éxito académico, demandando al menos 8 horas semanales de estudio debido a su complejidad. La dedicación insuficiente a este curso disminuye las posibilidades de éxito, ya que comprender y aplicar conceptos avanzados, como el desarrollo de listas enlazadas, requiere una inversión significativa de tiempo. La práctica de estos conceptos en programas simulados enfatiza la necesidad de dedicar suficiente tiempo para garantizar un aprendizaje efectivo y exitoso.

DISCUSIÓN

La investigación científica es crucial para asegurar una ventaja competitiva en diversos sectores, facilitando la resolución de problemas, diseño y construcción de nuevos sistemas, servicios y productos. Utilizando el método científico, se refinó y estructuró la idea de la investigación para ser objeto de un estudio formal. La definición clara de los objetivos, su delimitación y justificación proporcionarán un enfoque adecuado para el desarrollo y logro de los resultados. Los marcos conceptuales y teóricos fueron fundamentales para la recopilación, organización y presentación de conceptos básicos, apoyando la investigación, describiendo características favorables, permitiendo el análisis de la literatura existente y haciendo referencia a temas de investigación para garantizar su calidad.

Una metodología de investigación es esencial para promover y fomentar las mejores formas de resolución de problemas, desarrollando fases específicas para seleccionar técnicas adecuadas. En la etapa metodológica, se recolectaron, seleccionaron, ordenaron y analizaron los datos para un estudio cuantitativo. Se encontró que la mayoría de los estudiantes encuestados eran masculinos (64,7%) y estaban en el rango de edad de 26 a 30 años. La mayoría vivía en Panamá Oeste (29,4%) o Panamá Centro (23,5%).

La mayoría de los estudiantes habían completado el plan de estudios del curso básico de informática (94,1%), pero muchos no dominaban completamente las habilidades enseñadas, especialmente en análisis y diseño de diagramas de flujo y algoritmos. Asimismo, la mayoría no dominaba completamente las habilidades del curso de Programación I (82,4%). Además, la mayoría tenía un dominio moderado a bajo en sentencias de programación y no sabían trabajar con funciones, lo cual es crítico para la programación.

Los estudiantes también mostraron dificultades con los tipos de datos de estructuras básicas y el trabajo con punteros. A pesar de la importancia del curso de Programación II (Estructuras de Datos), muchos estudiantes no dedicaban suficiente tiempo para estudiarlo, y la mayoría prefería usar teléfonos móviles para conectarse a clases virtuales, lo que podría limitar su capacidad para aprender de manera efectiva. A pesar de su compromiso con sus estudios, muchos estudiantes no estaban dedicando suficiente tiempo para estudiar, especialmente durante los turnos nocturnos.

En resumen, la investigación científica es fundamental para el avance y la competitividad en diversos sectores. La metodología de investigación y los marcos conceptuales teóricos son herramientas esenciales para el desarrollo de estudios cuantitativos. Sin embargo, los resultados de la encuesta sugieren que, aunque los estudiantes están comprometidos con sus estudios, enfrentan desafíos significativos en la adquisición de habilidades clave en informática, lo que subraya la necesidad de mejorar los métodos de enseñanza y la dedicación de tiempo para garantizar un aprendizaje efectivo

REFERENCIAS BIBLIOGRÁFICAS

- Abelson, H., Sussman, G., & Sussman, J. (1996). **Structure and Interpretation of Computer Programs** (2nd ed.). Cambridge, MA: MIT Press.
- Barnes, T., Richter, H., Powell, E., Chaffin, A., & Godwin, A. (2007). *Game2Learn: building CS1 learning games for retention*. SIGCSE.
- Basawapatna, A. (2016). *Alexander Meets Michotte: A Simulation Tool Based on Pattern Programming and Phenomenology*. ResearchGate, 15.
- Berland, M., & Lee, V. R. (2012). Collaborative strategic board games as a site for distributed computational thinking. *Developments in Current Game-Based Learning Design and Deployment*, 285.
- Carpinteri, A. (2002). **Structural Mechanics: A Unified Approach**. CRC Press.
- Cairo, O. (2006). **Estructuras de datos**. MC Graw Hill-Interamericana Editores, S.A.
- CODDII y AENUI. (2015). Por la inclusión de asignaturas específicas de ciencia y tecnología informática en los estudios básicos de la enseñanza secundaria y bachillerato. Recuperado de <http://coddii.org/wp>.
- Coppo, R., Iparraguirre, J., Feres, G., Ursua, G., Cavallo, A. (2011). Sistema didáctico para la enseñanza de la programación con metodologías de aprendizaje basado en problemas. Conferencia presentada en el XIII Workshop de Investigadores en Ciencias de la Computación, 824-827.
- Diccionario de Arte I. (2003). Barcelona: Biblioteca de Consulta Larousse. Editorial SL (RBA), 210. ISBN 84-8332-390-7
- Diehl, S. (2007). **Software visualization: visualizing the structure, behavior, and evolution of software**. Berlin: Springer, 38-47.
- Derus, R. (2012). Difficulties in learning programming: Views of students. 1st International Conference on Current Issues in Education, ICCIE2012, At Yogyakarta, Indonesia. doi: 10.13140/2.1.1055.7441.

Estructuras de datos: listas enlazadas, pilas y colas. (n.d.). Estructuras de Datos: Listas Enlazadas, Pilas y Colas.; calcifer.org. Retrieved July 30, 2022, from <https://calcifer.org/documentos/librognome/glib-lists-queues.html>

G Suite Updates. (2014, September 2). G Suite Updates (en inglés). Consultado el 12 de diciembre de 2016.

García, B. Á., Martínez, R., Jaén, J., & Santiago, T. A. (2006). La autoevaluación como actividad docente en entornos. *Revista de Educación a Distancia*, 2-14. Recuperado el 3 de 11 de 2016, de <http://revistas.um.es/red/article/view/24281/23621>

Hu, C. (2004). Rethinking of teaching objects-first. *Education and Information Technologies*, 9(3), 209–218.

Israel, M., Pearson, J., & Tapia, T. (2015). Supporting all learners in school-wide computational thinking: A cross-case qualitative analysis. *Computers & Education* 82, 263-279.

Korhonen, A., & Malmi, L. (2000). Algorithm simulation with automatic assessment. In *Proceedings of the 5th annual ITiCSE conference*, pages 160–163.

Marrugo, D. V. D. (2018). Diseño e implementación de objetos virtuales de aprendizaje para apoyar el proceso de enseñanza en la asignatura de estructura de datos repositorio.unicartagena.edu.co.

Muñoz, R., Barría, M., Noël, R., Providel, E., Quiroz, P. (2012). Determinando las Dificultades en el Aprendizaje de la Primera Asignatura de Programación en Estudiantes de Ingeniería Civil Informática. Conferencia presentada en Congreso Internacional de Informática Educativa, XVII, 1-7. doi: 10.13140/2.1.2000.7206.

Santimateo, D. (2014). Factores que inciden en el rendimiento académico de estudiantes en los cursos iniciales de programación de computadoras. Panamá: Universidad de Panamá.

Uso y aplicación del aprendizaje automático para crear modelos en la toma de decisiones en el área de la salud

Use and application of machine learning to create models in decision making in the health area.

Denis Cedeño

Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación
denis.cedeno@up.ac.pa <https://orcid.org/0000-0002-9640-1284>

Recibido: 31-1-2023, Aceptado: 8-5-2023

DOI <https://doi.org/10.48204/3072-9696.6355>

RESUMEN

La inteligencia artificial (IA) es la disciplina que intenta replicar y desarrollar la inteligencia y sus procesos implícitos a través de computadoras. La IA sintetiza y automatiza tareas que en principio son intelectuales y es, por lo tanto, potencialmente relevante para cualquier ámbito de la actividad intelectual humana, abarca en la actualidad una gran variedad de subcampos, como procesamiento de lenguaje natural (PLN), aprendizaje automático (ML), robótica. Con la IA se están realizando proyectos de análisis de datos trabajando con ML, sin embargo, este tipo de soluciones son muy escasas sobre todo en el área médica de nuestro país. Usar tecnologías innovadoras como la IA aplicada a áreas tan sensitivas como la salud cada día va en aumento. Los nuevos modelos basados en ML en la actualidad están siendo más utilizados, sin embargo, en nuestros países son pocos los estudios relacionados al tema. Por lo tanto sin embargo, en nuestros países son pocos los estudios relacionados al tema, esta investigación tiene como objetivo utilizar diversas técnicas de ML y determinar cómo estos modelos nos pueden ayudar a la solución de problemas en la salud.

PALABRAS CLAVES

cesárea, aprendizaje automático, algoritmos de clasificación, extracción de información.

ABSTRACT

Artificial intelligence (AI) is the discipline that tries to replicate and develop intelligence and its implicit processes through computers. AI synthesizes and automates tasks that are intellectual in principle and is therefore potentially relevant to any field of human intellectual activity, currently encompassing a wide variety of subfields, such as natural language processing (NLP), machine learning (ML), robotics. With AI, data analysis projects are being carried out working with ML, however, these types of solutions are very scarce, especially in the medical area of our country. Using innovative technologies such as AI applied to areas as sensitive as health is increasing every day. The new models based on ML are currently being used more, however, in our countries there are few studies related to the subject. Therefore, this research aims to use various ML techniques and determine how these models can help us solve health problems.

KEYWORDS

cesarean, machine learning, classification algorithms, information extraction.

INTRODUCCIÓN

La información por sí misma está considerada un bien patrimonial. De esta forma, si una organización tiene una pérdida total o parcial de información esto provoca muchos perjuicios. Es evidente que la información debe ser protegida, pero también explotada. La información asociada a un contexto y a una experiencia como son los procesos médicos se convierte en conocimiento siendo un recurso intangible que aporta verdadero valor a la organización. En Panamá, los sistemas informáticos han ido en constante avance. Una gran parte de la información generada por estos sistemas de información de salud o eHealth es almacenada electrónicamente. Cada día este volumen de información crece. Es tanto el volumen de información de pacientes que actualmente se almacena en diferentes medios o repositorios como las bases de datos, las cuales cada día deben ser más potentes para almacenar dicha información (Cedeno-Moreno & Vargas-lombardo, 2016).

Común es hoy día para un especialista de salud registrar los datos del paciente por vía electrónica, esto incluye no solo la información general del paciente, sino también lo relacionado con el diagnóstico de su enfermedad, los resultados analíticos, pruebas funcionales y la medicación entre otros (Maldonado et al., 2012). Con tantos pacientes en los hospitales del país es enorme también el crecimiento de información digital, lo que hace implementar sistemas innovadores que procesen, analicen y exploten dicha información. Muchas veces el tratamiento de esta información requiere tareas de extracción, filtrado y clasificación (Fadly et al., 2007) tareas propias de la IA. La aplicación de la Tecnología de la Información y la Comunicación (TIC) en temas que afectan la atención de la salud está aumentando ya que proporciona considerables ventajas en términos de información, incluida la obtención de diagnósticos alternativos y un control eficiente de los pacientes (Maier,

2007). En la actualidad se genera un gran volumen de documentos y datos por lo cual es importante contar con herramientas tecnológicas que permitan a las personas obtener, procesar y discernir información convertida en conocimiento y que sea útil para ayudar a la toma de decisiones. La extracción de nuevo conocimiento a partir de grandes volúmenes de texto demanda utilizar novedosos mecanismos en el tratamiento de la información como la aplicación de técnicas de IA (Wyner & Peters, 2010). Con esta enorme cantidad de datos que son generados, se pueden realizar modelos predictivos basados en IA.

Les presentamos este trabajo investigativo que tiene como objetivo utilizar diversas técnicas o algoritmos de ML para obtener un modelo y determinar cómo este nos ayuda a predecir la forma de parto de una mujer embarazada dependiendo de ciertas características que esta presenta (Sebastiani, 2001).

El resto del documento está estructurado de la siguiente manera: Sección 2 presenta los referentes teóricos. Sección 3 los materiales y métodos. Sección 4 los resultados. Sección 5 se describe la discusión y finalmente en la sección 6 las conclusiones y trabajo futuro.

Referentes Teóricos.

La IA es una rama de las ciencias computacionales encargada de estudiar modelos de cómputo capaces de realizar actividades propias de los seres humanos en base a dos de sus características primordiales: **el razonamiento y la conducta** (Ordoñez-Salinas & Gelbukh, 2010). La IA ha evolucionado hasta el punto de presentar diferentes metodologías de ML aplicadas a innumerables áreas del saber (Akusok et al., 2015). El ML tiene por objetivo desarrollar técnicas que permitan que las computadoras aprendan, de forma más concreta, se trata de crear programas o modelos capaces de generalizar comportamientos a partir de una información suministrada en forma de ejemplos (McCallum et al., 1999). El término ML se definió originalmente como "**generación artificial de conocimiento a partir de la experiencia**". Fue entonces que se realizaron los primeros estudios y se diseñaron los primeros juegos. Las técnicas de ML están experimentando un auge sin precedentes en varios campos, tanto en el mundo académico, empresarial, salud y demás, constituyendo una herramienta de transformación relevante, es una de las áreas de la IA de más rápido crecimiento y se puede considerar una intersección de la informática y las estadísticas, está estrechamente relacionado con la ciencia de datos y el descubrimiento de conocimiento.

Actualmente diferentes organizaciones, entre ellas en el área de la salud, han optado estas técnicas para evaluar escenarios con pacientes y diferentes enfermedades, para crear modelos que puedan ser implementados en el bienestar del ser humano. En este ámbito es la salud uno de los mayores desafíos. El ML es muy amplio y trata el problema de extraer características de los datos para resolver tareas predictivas, incluido el apoyo a la decisión, el pronóstico, la clasificación (por ejemplo, en el diagnóstico de cáncer), la detección de anomalías (por ejemplo, mutaciones de virus) o el análisis de sentimiento (Pedregosa et al., 2012). Nuestro

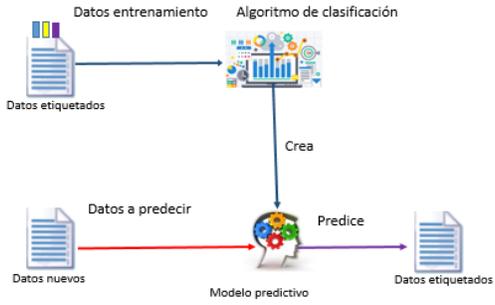
desafío es descubrir patrones estructurales relevantes o dicho de otra manera conocimiento en los datos, que a menudo están ocultos y no son accesibles para el experto humano. Uno de los mayores problemas es que la mayoría de los conjuntos de datos en el dominio médico están mal estructurado y no están estandarizados. En medicina el ML apenas se ha utilizado, en parte por razones culturales y filosóficas por las que se asume que una computadora nunca será tan capaz como un médico de evaluar una enfermedad mucho menos predecir un diagnóstico. También por el rechazo de algunos médicos a sentirse cuestionados, supervisados o aconsejados por una máquina o por un ingeniero (Verma et al., 2015). En muchos países desarrollados, se realizan proyectos de ciencias biológicas y genómicas que usan ya métodos computacionales avanzados de ML, mientras que los médicos tienen que lidiar con bases de datos cada vez más grandes y complejas recurriendo a métodos estadísticos tradicionales.

El objetivo principal del ML es el desarrollo de teorías, técnicas y algoritmos que permitan a un sistema modificar su comportamiento a través de la inferencia inductiva. Esta inferencia está basada en la observación de datos que representan información incompleta sobre un proceso o fenómeno estadístico. Para el ML existen 4 formas distintas de aprender o algoritmos: **aprendizaje supervisado, aprendizaje no supervisado, aprendizaje semi supervisado o aprendizaje por refuerzo**. En el caso particular de los 3 primeros tipos de algoritmos se diferencian en el conocimiento a priori que se tiene en cada uno. Los dos extremos son el supervisado, donde se tiene conocimiento a priori de los datos, y el no supervisado, caracterizado por la ausencia de conocimiento a priori.

- **Aprendizaje supervisado:** El objetivo de este tipo de algoritmo es que mediante unos datos de entrenamiento, deducir una función que haga lo mejor posible el mapeo entre unas entradas y una salida (Khairnar & Kinikar, 2013). Dentro de los algoritmos supervisados se pueden encontrar dos corrientes, los algoritmos de clasificación y los de regresión. Los algoritmos de clasificación se usan cuando el resultado deseado es una etiqueta discreta. Aquí tenemos clasificación binaria, solo se elige entre dos etiquetas y clasificación para múltiples etiquetas. La otra corriente son los algoritmos de regresión, los cuales son útiles para predecir valores que son continuos. Eso significa que la respuesta a su pregunta se representa mediante una cantidad que puede determinarse de manera flexible en función de las entradas del modelo en lugar de limitarse a un conjunto de posibles etiquetas. En la figura 1 se puede ver el modelo estándar del aprendizaje supervisado.

Figura 1.

Modelo general del aprendizaje supervisado.



- **Aprendizaje no supervisado:** Se organizan los datos de alguna manera que se pueda describir su estructura. El objetivo del aprendizaje no supervisado es lograr crear un modelo de la estructura o distribución de los datos para aprender más sobre ellos. Sirve tanto para entender como para resumir un conjunto de datos. En términos generales, pueden ser agrupados en algoritmos de clustering y algoritmos de asociación (Mcgregor et al., 2004).
- **Aprendizaje semisupervisado:** El aprendizaje semisupervisado se encuentra a medio camino entre el aprendizaje supervisado y el no supervisado. Ahora lo que tenemos son tantos datos etiquetados como datos no etiquetados, es decir, además de tener tuplas (X,Y), tenemos datos sólo de X de los que no sabemos su respuesta en Y.
- **Aprendizaje por refuerzo:** El objetivo en el aprendizaje por refuerzo es aprender a mapear situaciones de acciones para maximizar una cierta función de recompensa. En estos problemas un agente aprende por prueba y error en un ambiente dinámico e incierto.

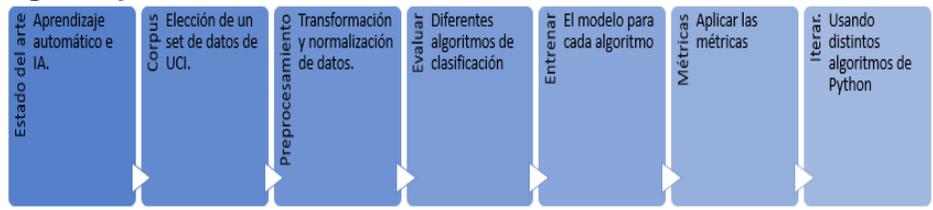
Elegir un algoritmo es un paso crítico en el proceso de ML, por lo que es importante que realmente se adapte al caso de uso del problema en cuestión.

MATERIALES Y MÉTODOS

Metodología: La metodología propuesta que se presenta en este artículo ha sido implementada como un caso de estudio en el siguiente orden como lo podemos apreciar en la figura 2.

Figura 2.

Metodología implementada.



Corpus o conjunto de datos: *Uno de los retos que se tienen al construir modelos de ML es la obtención de un corpus lo suficientemente confiable y estable. En nuestro caso el corpus utilizado para el estudio lo hemos obtenido del sitio web de UC Irvine Machine Learning Repository el cual detallo a continuación: (<https://archive.ics.uci.edu/ml/datasets/Caesarian+Section+Classification+Dataset>). Este conjunto de datos contiene información sobre los resultados de la cesárea de 80 mujeres embarazadas con las características más importantes de los problemas de parto en el campo médico. El corpus que hemos utilizado es un conjunto de datos para llevar a cabo los experimentos de clasificación, consta de varias variables de predicción médica y la variable objetivo, que es nuestra variable dependiente. En tabla 1, podemos observar la descripción de las variables.*

Tabla 1.
Descripción de las variables.

Atributo	Características
edad	numérico
partos	numérico
tiempo parto	numérico 0 = oportuno, 1 = prematuro, 2 = tardío
presión	numérico 0 = baja 1 = normal 2 = alta
problema cardiaco	numérico 0 = apto 1 = inepto
cesárea	numérico 0 = No 1 = Sí

Librerías de Python: Decidimos trabajar con la herramienta de programación Python ya que tiene una gran variedad de librerías para el desarrollo de aplicaciones de ML. El lenguaje de programación Python ofrece muchos beneficios para los que desean integrarse en el contexto del ML, ya que sus librerías facilitan las tareas (Ren, 2021). Entre ellas tenemos las que se muestran en la tabla 2.

Tabla 2.

Librerías de Python.

Librería	Función
Sklearn	Incluye muchos algoritmos de ML, aquí, estamos usando algunos de sus módulos como <code>train_test_split</code> , <code>RandomForestClassifier</code> y <code>precision_score</code> .
NumPy	Librería con una variedad de módulos numéricos de Python que proporciona funciones matemáticas rápidas para los cálculos. Se utiliza para leer datos y llevarlos a arreglos y para poder manipularlos.
Pandas	Librería para leer y escribir en archivos. La manipulación de datos se puede hacer fácilmente con esta librería.

Preprocesar los datos: Antes de entrenar el modelo, tenemos que dividir el conjunto de datos en conjunto de datos utilizado en entrenamiento y prueba, esta tarea la realizamos utilizando el módulo de **Python** llamado **Scikit-Learn** específicamente el método **`train_test_split`**. En nuestro caso decidimos usar el método **80/20** es decir entrenamos con el 80% de los datos y el resto para la predicción (Zainuddin & Selamat, 2014). El primer conjunto es utilizado para que el algoritmo “aprenda” de las diversas características de los pacientes y el segundo conjunto sirve para evaluar el rendimiento del modelo obtenido. Dicho modelo, permite clasificar nuevos pacientes.

Entrenamiento de algoritmo: Se usaron técnicas de ML. En este paso se entrenaron los algoritmos de clasificación a través de sus características generados en el pre proceso. La idea es que los algoritmos puedan extraer información útil de los datos que le pasamos para luego poder hacer predicciones con datos nuevos. Aplicamos los algoritmos de **Naive Bayes**, **Máquina de Soporte de Vectores (SVM)**, también **Random Forest** y **KNearest Neighbour (Knn)**. En la tabla 3 se muestran las características de cada algoritmo usado.

Tabla 3.

Características de Algoritmos usados.

Algoritmo	Característica
Naive Bayes	Este clasificador usa el teorema de Bayes, con un supuesto de independencia entre los predictores. En términos simples, un clasificador Bayesiano asume que la presencia de una característica particular en una clase no está relacionada con la presencia de cualquier otra característica (Tanuja et al., 2011).

SVM	Es un algoritmo de aprendizaje automático supervisado que se puede utilizar tanto para tareas de clasificación como de regresión. SVM realiza la clasificación al encontrar el hiper plano que diferencia las clases que trazamos en el espacio n-dimensional (Li & Wu, 2010).
Random Forest	Es un algoritmo que mezcla una combinación de árboles predictores tal que cada árbol depende de los valores de un vector aleatorio probado independientemente y con la misma distribución para cada uno de estos (Nguyen et al., 2013).
K-nn	La idea básica de este algoritmo es que un nuevo caso que se vaya a clasificar estará en la clase más frecuente a la que pertenecen sus K vecinos más cercanos. El algoritmo es muy usado para tareas de clasificación ya que se fundamenta por tanto en una idea muy simple e intuitiva, además es fácil implementarlo (Trstenjak et al., 2014).

Según la metodología propuesta y los métodos utilizados encontramos buenos resultados que presentamos en el siguiente apartado.

RESULTADOS

En nuestra investigación por las características del conjunto de datos trabajados nos estamos enfrentamos a un problema donde lo mejor que se ajusta o requiere son los algoritmos de clasificación binaria supervisada clásica. Esto lo podemos deducir ya que, dado un número de elementos, todos con ciertas características, queremos construir un modelo de ML para identificar a las mujeres a las que se les practicará un procedimiento de cesárea. Específicamente para las tareas de clasificación usamos los algoritmos: **SVM, Naive Bayes, Random Forest y Knn**, estos algoritmos son de aprendizaje supervisado (Aha et al., 1991).

Pudimos medir el experimento con el módulo de **classification_report** que nos brindó información de las métricas comunes de precisión para cada etiqueta de Si será o No la cesárea con los datos del set de entrenamiento con los distintos algoritmos (Knn, Naive Bayes, Random Forest y SVM) (Sidorov et al., 2013).

En el experimento obtuvimos como resultados que los algoritmos de Random Forest y SVM presentan mejores resultados que los algoritmos de Naive Bayes y Knn. Esto en gran medida a que siempre ambos algoritmos son considerados mejores para la tarea de clasificación. En tabla 4, podemos observar los resultados de la precisión para datos de entrenamiento y prueba.

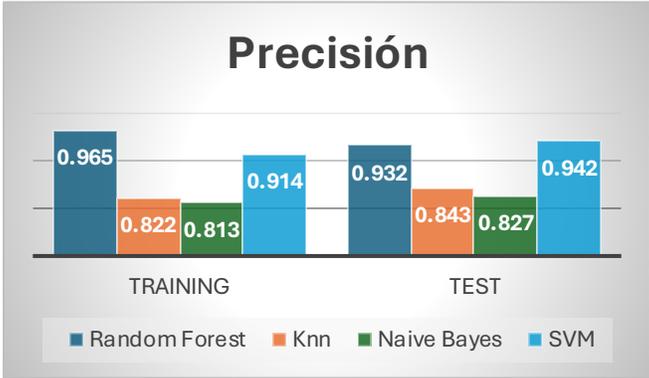
Tabla 4.

Precisión para Training y Test.

Algoritmo	Training	Test
Random Forest	0.965	0.972
Knn	0.822	0.843
Naive Bayes	0.813	0.827
SVM	0.914	0.932

En figura 3, podemos observar los resultados de la precisión para datos de entrenamiento y prueba.

Figura 3.
Reporte de clasificación.



En cuanto a la precisión del conjunto de datos de entrenamiento, los resultados del algoritmo de Random Forest presentan un 96% el mejor porcentaje obtenido de los cuatro. Y para los datos de prueba el mejor porcentaje es el algoritmo de SVM. Es bueno señalar que por encima del 90% se considera un resultado bueno. Esto se debe a que el aprendizaje automático es en realidad un conjunto de muchos métodos diferentes que son especialmente adecuados para responder a diversas preguntas sobre un contexto específico.

DISCUSIÓN

Después de realizar los experimentos sobre el conjunto de datos de mujeres embarazadas en donde aplicamos distintos algoritmos de ML para lograr obtener un modelo predictivo que nos ayudara a la tarea de clasificación del tipo de parto que pudiese tener (parto por cesárea o parto normal) dependiendo de sus características, las cuales fueron expuestas al inicio (edad, cantidad de partos, presión arterial, problemas cardiacos) consideramos que el rendimiento global obtenido es bastante positivo, ya que cada algoritmo mostró métricas superior al 80% en exactitud.

Hemos realizado una experimentación que se ha basado principalmente en el enfoque de ML, donde hemos combinado resultados de diferentes algoritmos de clasificación y también hemos podido utilizar métricas para ver su precisión. Aplicamos varios algoritmos de ML para clasificación, en conjunto los cuatro obtuvieron buenos resultados sin embargo para nuestro experimento nos resultó mejor el algoritmo de Random Forest, lo que marca un precedente para otros trabajos similares.

La precisión aún puede mejorarse, consideramos que haciendo una selección más cuidadosa del corpus y logrando un mejor pre proceso de la data, puesto que en el corpus utilizado puede notarse ciertas ambigüedades como por ejemplo en

algunos casos la clasificación no sigue las normas generales. Por lo tanto, este tipo de desafíos se pueden resolver utilizando enfoques innovadores.

CONCLUSIONES Y TRABAJOS FUTUROS

Aunque la región centroamericana está en desarrollo, Panamá cuenta con una importante infraestructura tecnológica y de comunicaciones que permite el desarrollar soluciones innovadoras para la población de forma tal que avancemos y adaptemos nuevos servicios para la salud.

Existe también una gran demanda de servicios de salud pública y el número de pacientes en diferentes niveles de atención hospitalaria está creciendo rápidamente. El uso de tecnologías de salud como salud electrónica y la implementación de la IA puede desempeñar un papel importante en las estrategias de salud del país.

Se ha presentado una investigación que hace experimentos sobre un corpus de datos que estaba etiquetado para determinar si una paciente dará a luz o no por cesárea, aplicando diferentes algoritmos de ML supervisado y realizando tareas de clasificación. Nuestra meta fue analizar y validar a través de métricas cual algoritmo era más eficiente para nuestros propósitos.

Para ello creamos una metodología que fue explicada, utilizada y validada obteniendo buenos resultados. Consideramos que esta investigación fue positiva y eficiente en cuanto a la metodología propuesta y por otro lado se pudo ver las ventajas que ofrecen el aprendizaje automático en cuanto a la clasificación en este caso de una patología clínica.

En cuanto a trabajos futuros, seguir encaminados en esta área de la IA pues nos parece muy interesante y proponer otros estudios con otros conjuntos de datos para ver el comportamiento de los algoritmos de clasificación.

REFERENCIAS BIBLIOGRÁFICAS

- Aha, D. W., Kibler, D., & Albert, M. K. (1991). Instance-Based Learning Algorithms. *Machine Learning*, 6(1), 37–66. <https://doi.org/10.1023/A:1022689900470>
- Akusok, A., Bjork, K.-M., Miche, Y., & Lendasse, A. (2015). High-Performance Extreme Learning Machines: A Complete Toolbox for Big Data Applications. *IEEE Access*, 3, 1011–1025. <https://doi.org/10.1109/ACCESS.2015.2450498>
- Cedeno-Moreno, D., & Vargas-lombardo, M. (2016). Towards A Model Of Knowledge Extraction Of Text Mining For Palliative Care Patients In. *International Journal of Scientific & Technology Research*, 5(07).
- Fadly, A. El, Daniel, C., Bousquet, C., Dart, T., Lastic, P.-Y., & Degoulet, P. (2007). Electronic Healthcare Record and Clinical Research in Cardiovascular Radiology. HL7 CDA and CDISC ODM Interoperability. *AMIA 2007 Symposium*

Proceedings, 216–220.
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2655824/pdf/amia-0216-s2007.pdf>

Khairnar, J., & Kinikar, M. (2013). Machine Learning Algorithms for Opinion Mining and Sentiment Classification. *International Journal of Scientific and Research Publications*, 3(6), 1–6. www.ijsrp.org

Li, N., & Wu, D. D. (2010). Using text mining and sentiment analysis for online forums hotspot detection and forecast. *Decision Support Systems*, 48(September), 354–368. <https://doi.org/10.1016/j.dss.2009.09.003>

Maier, R. (2007). Knowledge Management Systems: Information and Communication Technologies for Knowledge Management. *Knowledge Management*, 2, 720. https://doi.org/10.1007/978-3-540-71408-8_10

Maldonado, J. A., Costa, C. M., Moner, D., Menárguez-Tortosa, M., Boscá, D., Miñarro Giménez, J. A., Fernández-Breis, J. T., & Robles, M. (2012). Using the ResearchEHR platform to facilitate the practical application of the EHR standards. *Journal of Biomedical Informatics*, 45(4), 746–762. <https://doi.org/10.1016/j.jbi.2011.11.004>

McCallum, a., Nigam, K., Rennie, J., & Seymore, K. (1999). Building domain-specific search engines with machine learning techniques. *Proc. AAAI-99 Spring Symposium on Intelligent Agents in Cyberspace*, 1999. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.54.4708&rep=rep1&type=pdf>

Mcgregor, A., Hall, M., Lorier, P., & Brunskill, J. (2004). *Flow Clustering Using Machine Learning Techniques*. 205–214.

Nguyen, C., Wang, Y., & Nguyen, H. N. (2013). Random forest classifier combined with feature selection for breast cancer diagnosis and prognostic. *Journal of Biomedical Science and Engineering*, 06(05), 551–560. <https://doi.org/10.4236/jbise.2013.65070>

Ordoñez-Salinas, S., & Gelbukh, A. (2010). Information retrieval with a simplified conceptual graph-like representation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 6437 LNAI(PART 1), 92–104. https://doi.org/10.1007/978-3-642-16761-4_9

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O.,

- Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2012). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830. <https://doi.org/10.1007/s13398-014-0173-7.2>
- Ren, Y. (2021). Python Machine Learning: Machine Learning and Deep Learning With Python. *International Journal of Knowledge-Based Organizations*, 11(1), 67–70.
- Sebastiani, F. (2001). *Machine Learning in Automated Text Categorization*. <https://doi.org/10.1145/505282.505283>
- Sidorov, G., Miranda-Jiménez, S., Viveros-Jiménez, F., Gelbukh, A., Castro-Sánchez, N., Velásquez, F., Díaz-Rangel, I., Suárez-Guerra, S., Treviño, A., & Gordon, J. (2013). Empirical study of machine learning based approach for opinion mining in tweets. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7629 LNAI(PART 1), 1–14. https://doi.org/10.1007/978-3-642-37807-2_1
- Tanuja, S., Acharya, D., & Shailesh, K. R. (2011). Comparison of different data mining techniques to predict hospital length of stay. *Journal of Pharmaceutical and Biomedical Sciences*, 07(07).
- Trstenjak, B., Mikac, S., & Donko, D. (2014). KNN with TF-IDF based framework for text categorization. *Procedia Engineering*, 69, 1356–1364. <https://doi.org/10.1016/j.proeng.2014.03.129>
- Verma, V. K., Ranjan, M., & Mishra, P. (2015). *Text Mining and Information Professionals*.
- Wyner, A., & Peters, W. (2010). Lexical semantics and expert legal knowledge towards the identification of legal case factors. *Frontiers in Artificial Intelligence and Applications*, 223, 127–136. <https://doi.org/10.3233/978-1-60750-682-9-127>
- Zainuddin, N., & Selamat, A. (2014). Sentiment analysis using Support Vector Machine. *I4CT 2014 - 1st International Conference on Computer, Communications, and Control Technology, Proceedings, May 2016*, 333–337. <https://doi.org/10.1109/I4CT.2014.6914200>

Industria 4.0 en la era del 5G: Oportunidades y desafíos en la automatización del hogar mediante el internet de las cosas.

Industry 4.0 in 5G era: Opportunities and challenges in home automation through internet of things.

César Alexis Delgado Batista ¹,

cesar.delgado@up.ac.pa <https://orcid.org/0000-0002-7694-2024>

Mariela Yamileth Sánchez Rodríguez ²,

marielay.sanchezr@up.ac.pa , <https://orcid.org/0000-0002-8043-4153>

Librada Velasco ³

librada.velasco@up.ac.pa <https://orcid.org/0009-0001-3248-464X>

^{1, 2, 3} Universidad de Panamá. Facultad de Informática, Electrónica y Comunicación
- Centro Regional Universitario de Los Santos.

Recibido: 21-2-2023, Aceptado: 21-3-2024

DOI <https://doi.org/10.48204/3072-9696.6356>

RESUMEN

La sociedad actual está experimentando una transformación digital sin precedentes que cambia nuestra interacción con la tecnología. Los avances disruptivos de la industria 4.0, basados en tecnologías de la cuarta revolución industrial, tienen un impacto significativo en disciplinas como ingeniería eléctrica, administración de empresas, informática, tecnología y software, entre otros. Estos avances integran tecnologías físicas, digitales y biológicas como inteligencia artificial, robótica, análisis de datos e Internet de las Cosas (IoT). La tecnología 5G y el IoT están estrechamente relacionados, logrando la integración de viviendas automatizadas y monitorizadas, junto con la interconexión de dispositivos a través de sensores distribuidos en diversas plataformas y servicios con grandes capacidades de procesamiento y almacenamiento de datos. El 5G, con su rápida velocidad de conexión y baja latencia, es fundamental para el desarrollo pleno del IoT y otras tecnologías como realidad aumentada, vehículos autónomos y telemedicina, emergiendo como una evolución de la comunicación y la informática aplicada a objetos, permitiendo la interacción a través de Internet. La implementación de hogares inteligentes comienza con la instalación de dispositivos conectados a Internet, como sensores, termostatos y electrodomésticos inteligentes, que se pueden conectar entre sí para lograr procesos automatizados y un consumo de energía optimizado. Sin embargo, junto con las oportunidades que ofrece la automatización del hogar a través del IoT, también surgen desafíos relacionados con su seguridad. Es esencial implementar medidas de seguridad adecuadas, como contraseñas seguras, actualizaciones frecuentes, firewalls y software antivirus, para proteger los dispositivos conectados de posibles ataques y manipulaciones

externas. Los usuarios también deben ser conscientes de la importancia de mantener la seguridad en sus hogares y tomar medidas inmediatas para mitigar los riesgos en caso de amenazas.

PALABRAS CLAVE:

Cuarta revolución industrial, Industria 4.0, 5G, automatización del hogar, Internet de las cosas.

ABSTRACT

Current society is undergoing an unprecedented digital transformation that is changing our interaction with technology. The disruptive advancements of Industry 4.0, based on technologies from the fourth industrial revolution, have a significant impact on disciplines such as electrical engineering, business administration, computer science, technology, and software, among others. These advancements integrate physical, digital, and biological technologies such as artificial intelligence, robotics, data analysis, and the Internet of Things (IoT). The technology of 5G and IoT are closely related, enabling the integration of automated and monitored homes, along with the interconnection of devices through distributed sensors in various platforms and services with extensive data processing and storage capabilities. 5G, with its fast connection speed and low latency, is crucial for the full development of IoT and other technologies such as augmented reality, autonomous vehicles, and telemedicine. IoT emerges as an evolutionary complement to communication and computer science applied to objects, allowing interaction through the Internet. The implementation of smart homes begins with the installation of internet-connected devices such as sensors, thermostats, and smart appliances that can be interconnected to achieve automated processes and optimized energy consumption. However, along with the opportunities offered by home automation through IoT, challenges related to security also arise. It is essential to implement adequate security measures such as strong passwords, frequent updates, firewalls, and antivirus software to protect connected devices from potential external attacks and manipulations. Users must also be aware of the importance of maintaining security in their homes and take immediate action to mitigate risks in the event of threats.

KEYWORDS:

Fourth industrial revolution, Industry 4.0, 5G, home automation, Internet of things.

INTRODUCCIÓN

La sociedad actual está experimentando una transformación digital sin precedentes que está cambiando la forma en que interactuamos con la tecnología a nuestro alrededor. Los avances tecnológicos disruptivos de la industria 4.0, basados en aquellas tecnologías que aparecieron y aquellas que fueron mejoradas en la cuarta revolución industrial, se proyectan con mayor relevancia en disciplinas como ingeniería eléctrica, administración de empresas, informática, tecnología y

software, negocios e información, ingeniería de software e ingeniería mecánica (Gasca-Hurtado,2019), propiciando avances significativos en la forma de producir y consumir bienes y servicios por la integración de tecnologías físicas, digitales y biológicas como la inteligencia artificial, la robótica, el análisis de datos y el Internet de las Cosas (IoT).

Desde una perspectiva evolutiva, la cuarta revolución industrial (4RI) surgió con la electrónica digital a mediados del siglo XX (Corso, 2020), desencadenando estrategias para el desarrollo de la industria a partir de la Feria de Hannover (Alemania) en el 2011, para mejorar la interconexión de la producción con la tecnología digital. La Industria 4.0 experimentó transformaciones significativas para aumentar la competitividad en el sector industrial que fue definida como “un medio para la competitividad de la industria manufacturera a través de los sistemas ciber físicos (CPS, Cyber-Physical System) en los procesos de fabricación” [3]. Esta visión fue compartida por China en 2013 cuando introdujo su estrategia de "Fabricación Inteligente", buscando una mayor eficiencia y sostenibilidad en el sector industrial a través de la implementación de la robótica y la inteligencia artificial en sus procesos de producción. En una línea similar, Estados Unidos lanzó en 2016 la "Iniciativa de Fabricación Avanzada" (AMI), centrada en el desarrollo de centros de fabricación de vanguardia y en la formación de una fuerza laboral competente en nuevas tecnologías. Hitos relevantes posteriores incluyen la "Iniciativa Industrial Europea" de 2018, que impulsó la creación de plataformas digitales y la inversión en Internet de las Cosas e inteligencia artificial. Además, se destaca la introducción de Cybertruck en 2019 por parte de la multinacional Tesla, un vehículo eléctrico construido con materiales avanzados y tecnología de fabricación de vanguardia como la soldadura láser y una prensa hidráulica de 8000 toneladas. Este vehículo representa un indicador tangible de los avances, retos y oportunidades en el ámbito de la Industria 4.0.

Las tecnologías emergentes de la Industria 4.0 comenzaron su desarrollo simultáneo a finales de la década del 2000, período que coincidió con la aparición de la tecnología de quinta generación (5G). Fue evidente la necesidad de mejorar la velocidad, capacidad y eficiencia de las conexiones móviles dada la proliferación constante de dispositivos móviles, el consumo intensivo de datos y la presión para mejorar la eficiencia energética, reducir costos y minimizar el impacto ambiental. Estas exigencias han justificado plenamente la adopción de tecnologías superiores como la 5G, que ofrece velocidades de conexión notablemente más rápidas y una menor latencia, garantizando una transmisión de datos más rápida y eficiente.

El 5G representa una revolución en términos de velocidad y eficiencia en la transmisión de datos, ofreciendo conexiones que superan los 10 Gbps. De esta manera, es posible conectar un mayor número de dispositivos a redes informáticas de forma simultánea. Además, la baja latencia de esta tecnología es menor que en la cuarta generación (4G), posibilitando la transmisión y recepción de datos casi en tiempo real, una característica esencial para aplicaciones que demandan una conexión rápida y confiable, que trascienden diversas esferas de la vida cotidiana.

En el ámbito empresarial, 5G impulsa la automatización de procesos y sistemas, permitiendo una mayor eficiencia y productividad. En el sector de salud, favorece el desarrollo de aplicaciones de telemedicina y de atención médica remota de alta calidad con la implementación de sensores médicos y dispositivos portátiles de monitoreo que podrán enviar datos a profesionales de la salud de manera rápida y segura, mejorando la calidad de la atención médica y una mejor gestión de enfermedades crónicas. En el sector industrial, propicia la automatización y el control remoto de procesos y maquinaria, a través de la incorporación de dispositivos IoT como sensores y robots industriales que proporcionarán eficiencia en los procesos automatizados, en la cadena de suministros, rastreos de productos, monitoreo de la producción y anticiparse a posibles interrupciones. En el hogar, facilita la conexión de una vasta gama de dispositivos como televisores inteligentes, sistemas de seguridad, electrodomésticos y sistemas de iluminación que hoy día están asociados al uso del Internet de las Cosas.

El Internet de las Cosas (IoT) es una tecnología emergente que ha surgido en paralelo con el desarrollo de la Industria 4.0, brindando una serie de oportunidades y desafíos para la automatización del hogar. Esta innovadora tecnología permite la interconexión y comunicación de máquinas, dispositivos y sistemas, facilitando la automatización, el control y la optimización de los procesos en el entorno doméstico, además de permitir la toma de decisiones basadas en datos. Con la evolución de las generaciones de tecnologías móviles, desde la 1G hasta la 5G, se ha observado un aumento exponencial de la demanda de servicios y una creciente cantidad de dispositivos conectados. Esta tendencia ha impulsado la necesidad de adoptar tecnologías más avanzadas y, en consecuencia, ofrece oportunidades para la automatización del hogar a través del IoT, como la gestión y control remoto de dispositivos domésticos de uso diario, sistemas de iluminación, de seguridad y climatización. Estas soluciones brindan comodidad y eficiencia energética, permitiendo a los usuarios tener un mayor dominio sobre su hogar y reducir los costos de energía. No obstante, también surgen desafíos en la implementación de la automatización del hogar a través del IoT, tales como garantizar la seguridad y privacidad de los datos transmitidos y almacenados en los dispositivos conectados, así como abordar la interoperabilidad de los dispositivos y sistemas para lograr una integración efectiva y un funcionamiento óptimo.

METODOLOGÍA

Para elaborar este artículo, se utilizó una metodología de investigación documental basada en la revisión de fuentes académicas y de divulgación científica, incluyendo libros, artículos científicos, reportes de investigación y documentación tecnológica relevante relacionada con la Industria 4.0, la tecnología 5G, el Internet de las Cosas, sus oportunidades y desafíos en la automatización de los hogares. Se realizó una búsqueda exhaustiva de fuentes documentales en bases de datos académicas, bibliotecas y repositorios digitales para obtener una visión amplia y actualizada de los temas a tratar, para posteriormente revisar detenidamente las fuentes

identificadas, seleccionando la información más relevante y precisa. Se estructuró la información de manera coherente, analizando los hallazgos de diferentes fuentes para presentar una visión integrada y comprensible de los resultados obtenidos.

La metodología utilizada tiene un enfoque cualitativo, con criterios de inclusión y exclusión para la selección de las fuentes documentales. Dentro de los criterios de inclusión, se consideraron aquellos documentos académicos y científicos que abordan de manera específica los temas de la Industria 4.0, la tecnología 5G, el Internet de las Cosas y la automatización de los hogares, priorizando fuentes recientes y relevantes, publicadas en revistas científicas reconocidas, libros de referencia en el campo y documentos técnicos provenientes de instituciones especializadas. Además, se incluyeron fuentes que ofrecen perspectivas diversas y complementarias para garantizar un análisis completo y equilibrado. Los criterios de exclusión descartan fuentes que no cumplieran con los objetivos y enfoque del artículo. Se excluyeron aquellos documentos que no estaban directamente relacionados con los temas de interés o que presentaban información desactualizada o de baja calidad. Asimismo, se descartaron fuentes no académicas o que carecían de rigor científico. El proceso de selección de las fuentes se llevó a cabo de manera sistemática y transparente, siguiendo los criterios de inclusión y exclusión establecidos. Esto aseguró que solo se incluyeran fuentes relevantes y confiables que aportaran información sustancial al desarrollo del artículo.

ANÁLISIS

INDUSTRIA 4.0 EN LA AUTOMATIZACIÓN DEL HOGAR

La cuarta revolución industrial (4RI) también conocida como Industria 4.0, es un término integrador de las tecnologías digitales enfocadas en la producción y competitividad a través de la integración de sistemas CPS en los procesos de fabricación, con máquinas inteligentes, conectadas a Internet, conjuntamente con apoyo de mano de obra humana (Loyanes, 2017). La estrategia de la Industria 4.0 es lograr fábricas inteligentes (Smart Factory) adaptadas de forma autónoma a las necesidades de los mercados (Rojas, 2023) apoyadas en Sistemas Ciber Físicos (CPS) que recopilan y procesan información, que toman decisiones inteligentes y ejecutan tareas en entornos cambiantes, para que puedan comunicarse entre sí a través de etiquetas de radiofrecuencia RFID. La Industria 4.0 es el producto más tangible de la cuarta revolución industrial (Loyanes, 2017), soportada por 9 pilares descritos por The Boston Consulting Group en abril de 2015: el Big Data, robots autónomos, simulación 3D, sistemas integrados, realidad aumentada, fabricación aditiva, la nube (cloud), la ciberseguridad y el Internet de las Cosas para la fabricación inteligente de ecosistemas que proporcionan información en tiempo real e interacciones autónomas entre máquinas, sistemas, objetos y cosas, basados en sectores estratégicos de movilidad, logística, edificios, productos y redes inteligentes.

La Industria 4.0 tiene grandes desafíos. Uno de ellos es lograr que miles de millones de personas se conecten a las redes digitales de manera segura y confiable a través de Internet (Loyanes, 2017), y el uso de sensores con capacidad de “sentir” las cosas, a través de la interconexión de objetos y procesos para IoT (Londoño, 2020). Los sensores son dispositivos que reciben información y detectan cambios en el entorno en función del tipo de variable a medir o detectar: por contacto, ópticos, térmicos, de humedad, magnéticos, infrarrojos, que actúan como “sentidos” para las cosas bajo observación o control. La automatización del hogar se fundamenta en el uso de una amplia gama de sensores de proximidad, movimiento, nivel líquido, humo, sensores magnéticos, temperatura y luz. Estos sensores desempeñan un papel crucial en el desarrollo de la automatización del hogar, ya que permiten detectar y recopilar datos importantes para el funcionamiento de los sistemas. Además, este avance tecnológico ha llevado a una expansión a gran escala, donde millones de dispositivos se interconectan de manera inalámbrica y segura, utilizando diversos protocolos de comunicación. Estos dispositivos se conectan a servicios alojados en la nube, lo que proporciona una mayor flexibilidad y accesibilidad en la gestión y control de la automatización del hogar.

Tecnología 5G y su contribución con el IoT

La tecnología 5G permitirá el pleno desarrollo del IoT (Millás, 2019) y otras tecnologías asociadas, con un tiempo de respuesta de red en milisegundos, una velocidad de conexión 100 veces más rápida que la actual red 4G y un considerable ahorro energético del 90% respecto a los sistemas actuales. La mayoría de las tecnologías estarán soportadas por el despliegue de infraestructuras y sistemas basados en 5G, por lo que será una pieza fundamental en la transformación digital de la sociedad y la economía de los países, bajo la premisa de construir ciudades inteligentes y hogares automatizados conectados con los seres humanos.

La tecnología 5G y el IoT están estrechamente relacionados. Las redes domóticas y electrónicas de consumo se fusionarán a través de multitud de sensores distribuidos y la construcción de viviendas serán edificadas a través de redes automatizadas y monitorizadas (García-Quilachamin, 2021), que serán capaces de integrarse con diversidad de plataformas y servicios para recibir, manipular y almacenar grandes cantidades de datos. Los principales parámetros de conectividad de la IoT establecen que la velocidad de transmisión mínima requerida es de 1024 kbps y 5G se encuentra en un rango promedio de entre 1 a 10 Gbps. El ancho de banda requerido para IoT es de 1.4 MHz y la tecnología 5G se encuentra entre 300 MHz a 1GHz. El mínimo requerido para IoT en cuanto a latencia es menor a 10 segundos y la tecnología 5G se encuentra entre 1 a 2 milisegundos. Las principales aplicaciones que se relacionan entre el IoT y la red 5G se presentan en la siguiente Figura (García-Quilachamin, 2021):

Figura 1.

Aplicaciones que se relacionan con el IoT y el 5G.

Aplicaciones	Descripción	Transmisión		Ref.
		IoT	5G	
Multimedia	Televisores, Proyectoros, equipos de sonido, con acceso a voz e internet, manejado desde el móvil.	SI	SI	(Curado, Tanganelli, Loureiro, & Tsiropoulou, 2020), (Fenton, 2018)
Electrodomésticos	Equipos de línea blanca, dando mayor eficiencia, y con conexión a internet	SI	SI	(Zhan, 2020), (Di, 2020)
Acceso y Bloqueo	Control de puertas, que permitan el paso, con cerrojos inteligentes	SI	SI	(Yao et al., 2021), (Behrad, Bertin, Tuffin, & Crespi, 2020)
Seguridad y Vigilancia	Alarmas, Cámara de vigilancia, Sensores, manejas desde dispositivos móviles.	SI	SI	(El-Latif et al., 2020), (Torroglosa-Garcia et al., 2020), (Tsai et al., 2018)
Medidor de temperatura	Consumo de energía del cuerpo, energía, temperatura, monitoreado en diferentes intervalos de tiempo.	SI	SI	(GSMA, 2017)
Con Voz	Se operan con totalidad por medio de la voz, aunque puede ser controlado manualmente	SI	SI	(Frøytlog et al., 2019), (Suryanegara, Arifin, & Asvial, 2017)

Tabla 10 – Aplicaciones que se relacionan con el IoT y el 5G

Nota: Tomada de (García – Quilachamin, 2021).

La información recopilada muestra la relación entre la tecnología 5G y el IoT, en aplicaciones multimedia, electrodomésticos, acceso y bloqueo, seguridad y vigilancia, medidor de temperatura y aplicaciones con voz. El modelo de comunicación de IoT con 5G no solo mejorará el monitoreo y control de los procesos tecnológicos, sino que mejorará la calidad de vida de las personas con la utilización de dispositivos que ofrezcan eficiencia, seguridad, ahorro de energía, y además de una comunicación estable convirtiéndose 5G en una tecnología habilitadora para el IoT.

Internet de las Cosas - internet of everything

El Internet de las Cosas emerge como un complemento evolutivo de las comunicaciones y la informática aplicadas a los objetos, permitiendo interacción entre ellos a través de la red Internet, conectando máquinas, productos, sistemas y

personas entre sí (Ledesma, 2020) . Sin duda alguna, el punto fuerte de la IoT es el alto impacto que tendrá en diversos aspectos de la vida cotidiana y el comportamiento de las personas (Supe, 2022). El Internet de las cosas (IoT) está cambiando la forma en que vivimos e interactuamos dentro y fuera de nuestros hogares. A través de la automatización de dispositivos el ser humano ha logrado que electrodomésticos, sistemas de seguridad, termostatos, sensores y luces entre otros, sean programados para ejecutar tareas según las necesidades de los usuarios. La implementación de hogares automatizados e inteligentes comienza con la instalación de dispositivos que cuentan con requerimientos de conexión a Internet como sensores, termostatos, sistemas de seguridad y electrodomésticos inteligentes. Estos dispositivos son capaces de conectarse unos con otros, a través de asistentes virtuales controlados por voz, por medio de procesos automatizados y de optimización de consumo de energía.

IoT está conectando objetos, máquinas, dispositivos con las personas de manera exponencial, por lo que no se puede predecir su crecimiento. La estimación hecha por GSMA (Groupe Special Mobile) para el 2020 fue de 24 mil millones de dispositivos conectados, mientras que Cisco y Ericsson estimaron 50 mil millones (Muñoz, 2019), liderando la cuarta revolución industrial por sus beneficios y el alto flujo de datos que se originan y se pueden almacenar.

Cada vez más se observa que existe una tendencia de uso de IoT en nuestro entorno, sobre todo en los hogares y, por ende, también se presentan preocupaciones de seguridad. La seguridad en Internet es un aspecto por considerar en los sistemas informáticos tradicionales y actuales. Desde que un dispositivo electrónico es conectado a Internet, existe el riesgo de ser atacado y manipulado por personas o sistemas externos, convirtiéndose en un riesgo para la seguridad personal y del hogar. Con la llegada del Internet de las Cosas, a pesar de que la población percibe un bajo riesgo de seguridad, se ha convertido en un problema cada vez más importantes por los ataques de los ciberdelincuentes y los problemas de vulnerabilidad.

La seguridad para dispositivos y sistemas basados en IoT cada vez es mayor. El aumento de casos de delitos cibernéticos genera acciones prioritarias para la protección de información e integridad física de usuarios en el hogar, implementando medidas de seguridad en sistemas y dispositivos IoT conectados a Internet. La reincidencia de ataques maliciosos perpetrados por ciberdelincuentes requiere de proteger la seguridad de los usuarios implementando medidas de seguridad adecuadas. Los usuarios juegan un papel importante en la seguridad de IoT en el hogar como primera línea de defensa ante cualquier ataque. Por ello, es importante que el entorno familiar tome en cuenta las medidas preventivas fundamentales como lo son utilizar contraseñas seguras, actualizar frecuentemente los dispositivos y aplicaciones, utilizar soluciones de firewalls y software antivirus, certificados de seguridad, control de permisos, desactivar los dispositivos no utilizados y segmentar la red Internet para uso exclusivo de dispositivos IoT. De existir un ataque se debe accionar de inmediato para evitar una propagación de la

amenaza y mitigar el riesgo, desconectando los dispositivos, además de cambiar las contraseñas de red y de cuentas asociadas a los dispositivos, realizar actualizaciones de seguridad e incluso, restaurar los dispositivos a una configuración de fábrica para eliminar cualquier software o virus malintencionado.

El acceso a través de ataques cibernéticos impacta significativamente a las personas, la familia e inclusive a nivel laboral. Los atacantes acceden a una red doméstica para sustraer información de contacto, multimedia (audio, video e imágenes), contraseñas, números de tarjetas de crédito e incluso al acceso a sistemas poniendo en riesgo el entorno laboral. Esto puede tener consecuencias graves, como el robo de identidad, extorsión, acoso, delitos informáticos que se han incrementado por las tecnologías asociadas al Internet. La primera línea de acción y defensa siempre será adoptada por los fabricantes y desarrolladores de sistemas IoT, pero el usuario juega un papel importante en conservar la información personal.

CONCLUSIÓN

En conclusión, la Industria 4.0 y la automatización del hogar están revolucionando la forma en que interactuamos con la tecnología. La Industria 4.0 busca crear fábricas inteligentes y adaptativas a través de la integración de sistemas ciber físicos, utilizando tecnologías como el Big Data, la realidad aumentada, la inteligencia artificial y el Internet de las Cosas. En este sentido, el IoT se presenta como un componente clave para la automatización del hogar, permitiendo la interconexión de dispositivos y la recopilación de datos importantes para su funcionamiento eficiente.

Sin embargo, el desafío principal radica en garantizar la seguridad en la era digital. La conexión masiva de dispositivos y la interconexión de sistemas plantean riesgos de ataques y manipulaciones externas. Por lo tanto, se deben implementar medidas de seguridad adecuadas, como contraseñas sólidas, actualizaciones frecuentes de dispositivos y aplicaciones, firewalls y software antivirus. Además, los usuarios deben ser conscientes de la importancia de mantener la seguridad en sus hogares y actuar de inmediato ante cualquier amenaza.

La tecnología 5G juega un papel fundamental en el desarrollo del IoT, al proporcionar una mayor velocidad de conexión, baja latencia y un ahorro significativo de energía. Esto facilita la interconexión de dispositivos y abre nuevas posibilidades en aplicaciones multimedia, electrodomésticos inteligentes, seguridad, vigilancia y mucho más. El IoT está cambiando la forma en que vivimos y nos relacionamos en nuestros hogares, al permitir la automatización de diversos dispositivos y ofrecer eficiencia, seguridad y ahorro energético.

Es importante destacar que, a medida que la IoT se expande, también surgen preocupaciones sobre la seguridad. Los usuarios desempeñan un papel crucial como primera línea de defensa al implementar medidas de seguridad y actuar de manera proactiva ante posibles amenazas. La protección de la información personal y la integridad física de los usuarios debe ser una prioridad.

REFERENCIAS BIBLIOGRÁFICAS

- Corzo, G. D. y Alvarez-Aros, E. L., 2020. "Estrategias de competitividad tecnológica en la conectividad móvil y las comunicaciones de la industria 4.0 en Latinoamérica," *CIT Informacion Tecnologica*, vol. 31, no. 6, pp. 183-192
- García-Quilachamin, W. , 2021. 5G y el Internet de las Cosas: Revisión Sistemática, *Revista Ibérica de Sistemas e Tecnologias de Informação - risti*, pp. 238-253
- Gasca-Hurtado , G. P. , Machuca-Villegas , L. , 2019. Era de la Cuarta Revolución Industrial," *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*
- Joyanes,L. 2017. Industria 4.0: La cuarta revolución industrial. Editorial Alfaomega.
- Ledesma, J. D. F , 2020. La cuarta revolución industrial: contexto, conceptos y desarrollo, *Revista Universitas Científica*
- Londoño L. A y Ussa, G. D. C., 2020. "Contextualización de la Cuarta Revolución Industrial, Industria 4.0, Industria 5.0 y Tecnología 5G con el sector Defensa y Seguridad," *Perspectivas en Inteligencia* vol. 12, no. 21, pp. 245-258
- Millás, V. M., 2019. El despliegue de las redes 5G, o la geopolítica digital. recuperado de: <https://www.realinstitutoelcano.org/analisis/el-despliegue-de-las-redes-5g-o-la-geopolitica-digital/>. [Accessed 1 junio 2023].
- Muñoz, O. Q.,2019. Internet de Las Cosas (Iot), Ibukku.
- Rojas, J. H. C.,2017. La Cuarta Revolución Industrial o Industria 4.0 y su Impacto en la Educación Superior en Ingeniería en Latinoamérica y el Caribe," recuperado de https://www.laccei.org/LACCEI2017-BocaRaton/work_in_progress/WP386.pdf. [Accessed 1 junio 2023].
- Supe, D. ,Meza E. y Silva F.,2022 . Analizando Internet de las Cosas y la nube informática, *Revista ODIGOS*, vol. 3, no. 1

Desarrollo de una aplicación móvil para divulgación de la producción científica en redes sociales

Development of a mobile application for the dissemination of scientific production in social networks

José Antonio Murillo Tuñón

Universidad de Panamá, Vicerrectoría de Investigación y Posgrado, Panamá
jose.murillot@up.ac.pa <https://orcid.org/0009-0001-8994-3835>

Edgar Joel Pérez-Rivera

Universidad de Panamá, Vicerrectoría de Investigación y Posgrado, Panamá
edgar.perezr@up.ac.pa <https://orcid.org/0000-0002-0466-001X>

Francisco Farnum

Universidad de Panamá, Panamá
francisco.farnum@up.ac.pa <https://orcid.org/0000-0002-5879-2296>

Recibido: 31-1-2024, Aceptado: 8-5-2024

DOI <https://doi.org/10.48204/3072-9696.6357>

RESUMEN

Con la aparición de tecnologías móviles, como las pantallas táctiles y dispositivos electrónicos más compactos, se puede estar conectado a la información científica de forma inmediata, con información veraz. Con el propósito de visibilizar la producción científica de la Universidad de Panamá, bajo el principio FAIR (Encontrabilidad, Accesibilidad, Interoperabilidad y Reutilización); se desarrolló la Aplicación Móvil *Journal's Tips By Up*, en lenguaje de acceso abierto "Dart" de la plataforma de Google, utilizando Flutter como framework para aplicaciones multiplataforma. Este Apps ofrece un medio interactivo a los artículos científicos publicados en el Portal de Revistas de la Universidad de Panamá, además se vincula a canales de YouTube y otras redes sociales de la Universidad, divulgando entrevistas, videos, resumen de congresos y otros. Desde su lanzamiento en el año 2022, ha contribuido a mejorar las métricas de vista y descarga de artículos en las revistas científicas de la Institución.

PALABRAS CLAVE.

Dispositivo móvil; aplicación informática; desarrollo de software; publicación académica.



ABSTRACT

With the emergence of mobile technologies, such as touch screens and more compact electronic devices, it is possible to be connected to scientific information immediately, with accurate information. With the purpose of making visible the scientific production of the University of Panama, under the FAIR principle (Findability, Accessibility, Interoperability and Reusability); the “Journal's Tips By Up” Mobile App was developed in the open access language “Dart” of the Google platform, using Flutter as a framework for multiplatform applications. This App offers an interactive medium to the scientific articles published in the Portal of Journals of the University of Panama, and links to YouTube channels and other social networks of the University, disseminating interviews, videos, summary of congresses and others. Since its launching in the year 2022, it has contributed to improve the metrics of view and download of articles in the scientific journals of the Institution.

KEYWORDS.

Mobile device; computer application; software development; academic publishing.

INTRODUCCIÓN

En la era digital actual, los dispositivos móviles se han convertido en herramientas indispensables para la comunicación, el acceso a información y el entretenimiento. Actualmente Panamá cuenta con más de 4 millones de usuarios considerando un crecimiento anual del 7.2%, en las aplicaciones móviles generando esto una oportunidad única para acercar la ciencia a la sociedad.

La cúspide en las redes sociales, la falta de divulgación y la propagación de información no cierta hacen necesaria y apremiante la existencia de herramientas confiables que permitan a los usuarios acceder a información científica cierta y de calidad.

En este contexto, se propone el desarrollo de una aplicación móvil denominada "Journal's Tips by Up", diseñada para brindar a los usuarios acceso a artículos científicos, videos educativos, podcasts y herramientas interactivas que fomenten el aprendizaje y la participación en el ámbito científico.

La aplicación se basa en la convergencia de diversas tecnologías y tendencias actuales:

Uso generalizado de dispositivos móviles: La alta penetración de smartphones y tablets en Panamá convierte a los dispositivos móviles en una plataforma ideal para la divulgación científica. Al igual tomamos en cuenta que un dispositivo móvil se define como, un aparato de pequeño tamaño, con algunas capacidades de

procesamiento, con conexión permanente o intermitente a una red, con memoria limitada, que ha sido diseñado específicamente para una función, pero que puede llevar a cabo otras funciones más generales. (Arturo Baz Alonso, 2024)

Así mismo tomamos en cuenta lo que señala Hwang, El uso de dispositivos móviles para la enseñanza y estudio académico ha ido incrementado en los últimos años. (Hwang, G. J., & Tsai, C. C., 2011)

El Instituto Nacional de Estadística y Censo de Panamá (INEC), señala los dispositivos móviles superan en creces a la población, donde para una estadística la población de Panamá supera los 4,064,780 personas, mientras que los dispositivos móviles superan los 6,890,901 con una Variación porcentual anual de 7.2, según los datos (Instituto Nacional de Estadística y Censo, 2023).

Eficacia de las aplicaciones móviles para el aprendizaje: Las investigaciones han demostrado que las aplicaciones móviles pueden ser herramientas efectivas para el aprendizaje y la divulgación de conocimiento.

Ahora bien, así también podemos definir lo que es una Aplicación móvil, la cual se define como un Programa informático destinado a ser ejecutado en teléfonos inteligentes, tabletas u otros dispositivos móviles. (Diccionario panhispánico del español jurídico, 2024)

El propósito de una aplicación móvil se fundamenta en servir como una herramienta para realizar operaciones o funciones específicas. Generalmente para facilitar ciertas tareas complejas y hacer más sencilla la experiencia informática de las personas. (GCFEGlobal, 2024), Así también Puetaman (2016) presento un estudio en el que comparó diversos frameworks, lo que nos da luces en este ámbito de gestión a través de los medios actuales.

Bajo un enfoque actual en las redes sociales, encontramos como hito digital en 2024, los dispositivos inteligentes y el comercio social, donde las identidades activas de los usuarios de medios sociales han superado los 5.000 millones, lo que equivale al 62,3% de la población mundial, aumentando en un 5,6%. (puromarketing.com, 2024)

MATERIALES Y METODOS

Este estudio de tipo investigación acción, se realizó entre septiembre de 2022 y enero de 2024; el mismo se desarrolló en cuatro etapas:

La **Primera etapa Diagnóstico situacional** en la que se busca analizar la problemática en base a la información recopilada para pasar al diseño de la aplicación. La **Segunda etapa de Diseño de software** en esta se diseña y estructura la aplicación. La **Tercera etapa de Desarrollo de código**, en esta se codifica el front-end y el back-end utilizando lenguaje Dart. La **Cuarta etapa de Prueba de ejecución del software** esta se lleva a cabo mediante emuladores.

Toda la metodología se enfocó en las características y funcionalidades clave de las aplicaciones exitosas en este ámbito, así como las mejores prácticas en el diseño de interfaces de usuario y la experiencia del usuario (UX).

Segunda etapa de Diseño de software

Para el desarrollo de la plataforma, se optó por Flutter, un framework de código abierto creado por Google, junto con su lenguaje de programación asociado, Dart. Fundamentamos esta elección en las ventajas que ofrece esta tecnología.

- ✓ Permite crear aplicaciones móviles que funcionan tanto en dispositivos Android como iOS a partir de una única base de código.
- ✓ Se compilan en código nativo, lo que garantiza un alto rendimiento y una experiencia fluida para los usuarios.
- ✓ Es un lenguaje de programación moderno y fácil de aprender, lo que agiliza el proceso de desarrollo.

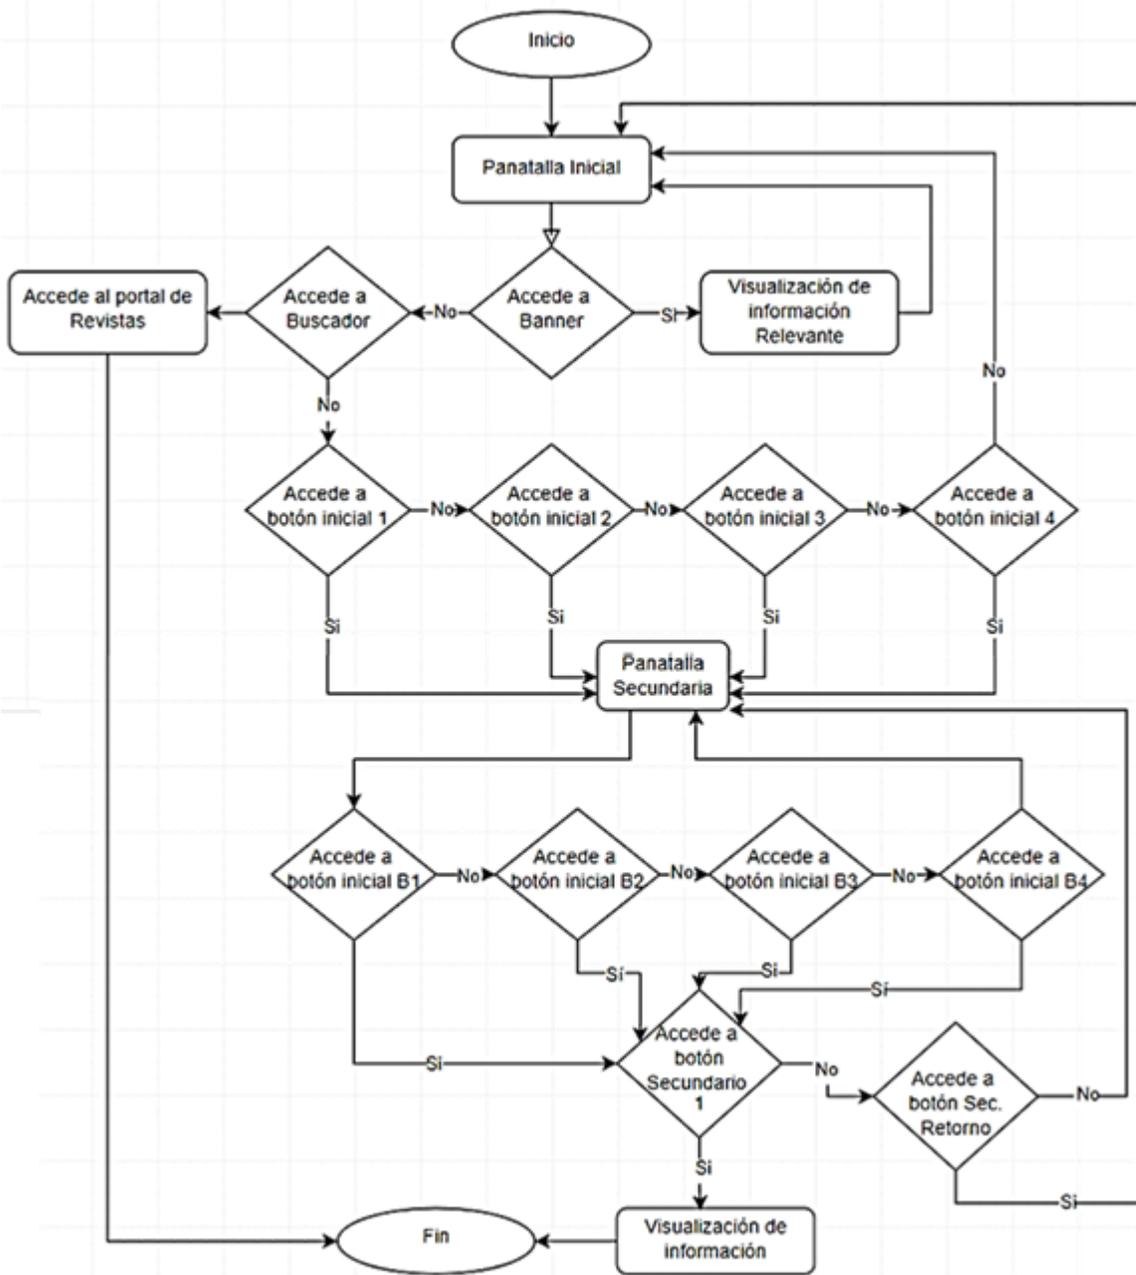
Se diseñó y desarrolló una estructura de flujo detallada que define los niveles y los puntos más relevantes del funcionamiento esperado en la aplicación. Esta estructura se basó en la temática del proyecto, los antecedentes y toda la información obtenida previamente. La Figura 1 ilustra esta estructura de flujo.

La elección de Flutter y Dart no solo ofreció las ventajas mencionadas, sino que también presentó retos en cuanto a la programación dinámica y la optimización. Sin embargo, estos retos se abordaron de manera efectiva durante el proceso de desarrollo.

La estructura de flujo bien definida permitió organizar el desarrollo de la aplicación de manera eficiente y garantizar que se cumplieran los objetivos planteados.

Figura 1

Diagrama de flujo, Estructura.



Nota: Este diagrama muestra la secuencia de funcionamiento de la aplicación a desarrollar.

Tercera etapa Desarrollo de código

Fase del Desarrollo del back-end y de front-end

Se utiliza un entorno de desarrollo integrado IDE (Integrated Development Environment), por ser una herramienta completa para el desarrollo de aplicaciones móviles, escogiendo entorno de desarrollo para aplicaciones móviles "Android Studio" conjuntamente con su kit de desarrollo de software (SDK) como el entorno base, al cual posteriormente integramos a "Visual Studio Code" como el Editor de preferencia para la edición de código fuente considerando su compatibilidad, soporte e compatibilidad, control de integración, resaltado de sintaxis y refactorización de código, incorporando además el Framework de código abierto "Flutter", a fin de tener mayor agilidad y rapidez en cuanto a las distintas plataformas bajo un mismo código como núcleo base, posteriormente se integró al repositorio Git Hub, para mantener un control de versiones y respaldo del desarrollo, En cuanto al lenguaje de desarrollo se utilizó lenguaje Dart como principal.

Utilizando Flutter, se crea la estructura de la aplicación multiplataforma compiladas de forma nativa a partir de una única base de código. Como podemos apreciar en la Figura 1. El código Flutter se compila en código de máquina ARM o Intel, así como en JavaScript, para un rendimiento rápido en cualquier dispositivo.

Figura 2

Journal's Tips By UP en dispositivos con sistema iOS y Android

```
lib > main.dart
1  import 'package:journalstips/screens/home.dart';
2  import 'package:flutter/material.dart';
3
4  void main() {
5    runApp(const MyApp());
6  }
7
8  class MyApp extends StatelessWidget {
9    const MyApp({super.key});
10
11   @override
12   Widget build(BuildContext context) {
13     return const MaterialApp(
14       debugShowCheckedModeBanner: false,
15       home: Home(),
16     );
17   }
18 }
19
```

Fase del Desarrollo del back-end

Considerando que en el back-end se programan las funcionalidades que tendrá la App, no requiere de registro previo y cuenta con características técnicas relevantes, accesibilidad, código abierto, sencilla y entendible, intuitiva, de fácil instalación, diseño amigable, confiable y segura.

Fase del Desarrollo del front end,

En esta fase hacemos referencia a la interfaz gráfica de usuario (GUI) en la que los usuarios de la aplicación interactuarán durante la ejecución de la aplicación a través de la pantalla o medio, mediante los menús, los diseños gráficos, botones, imágenes, tablas, gráficos u otros.

Cuarta etapa Ejecución o Prueba

Posterior a la programación y desarrollo, se llevan a cabo distintas pruebas a través compilación en emuladores, probando diferentes dispositivos según sus sistemas operativos, llevando a cabo los ajustes necesarios, para una posterior revisión por las plataformas de publicación.

RESULTADOS

Se elaboró una ampliación que consiste en una plataforma digital integral que abarca los siguientes elementos: Sección de artículos destacados: Un espacio dedicado a los artículos más relevantes y de mayor impacto publicados en las revistas de la UP. Revistas actualizadas: Una lista actualizada de todas las revistas científicas de la UP, con enlaces a sus sitios web y a los últimos números publicados. Podcast: Un canal de podcast que presenta entrevistas con investigadores, resúmenes de artículos y debates sobre temas de actualidad científica. Redes sociales: Presencia activa en las principales redes sociales para difundir contenido de las revistas y fomentar la interacción con la comunidad científica. Buscador: Un buscador integrado que permite a los usuarios encontrar artículos, revistas y autores específicos. Sección de promoción y divulgación: Un espacio para destacar eventos, becas, premios y otras noticias relevantes para la comunidad científica. Botones de acceso a portales de conocimiento: Enlaces directos a portales de conocimiento especializados en ciencia y tecnología, tanto en español como en inglés. La plataforma estará disponible en múltiples dispositivos, incluyendo móviles, web, computadores de escritorio e integrados, asegurando un acceso amplio y cómodo para los usuarios. Se optimizará el rendimiento para garantizar una experiencia fluida en diferentes sistemas operativos, como iOS y Android. Como podemos ver en la **Figura 3**.

La implementación de esta iniciativa permitirá a la UP:

- ✓ Aumentar la visibilidad y el impacto de sus revistas científicas.
- ✓ Llegar a una audiencia más amplia, tanto nacional como internacional.
- ✓ Fomentar el intercambio de conocimiento científico entre investigadores, estudiantes y público en general.
- ✓ Posicionar a la UP como líder en la divulgación del conocimiento científico en Panamá.

Es este un paso importante para fortalecer el ecosistema de investigación en el país y contribuir al avance del conocimiento. La plataforma digital integral propuesta permitirá acercar el conocimiento científico a una audiencia más amplia y promover el intercambio de ideas entre la comunidad académica y la sociedad en general.

Figura 3

Journal's Tips By UP en dispositivos con sistema iOS y Android



En cuanto a la estructura secundaria, encontraremos en primera instancia la imagen representativa y el título del área de interés accedida desde la ventana inicial. Posteriormente se podrá escoger a través de los botones visuales la información de preferencia, lo que generará el cambio de la imagen de referencia indicando la selección, así como un breve resumen del contenido, resaltando el botón de acceso para una mayor comodidad, permitiéndonos tener acceso controlado a la información científica y verás de acceso en las redes. Tal como podemos apreciar en la Figura 4 y 5.

Figura 4.
Captura de la Estructura inicial.



Figura 5.
Captura de la Estructura interna.



Dentro de los resultados es conveniente mostrar la sección de código o front end que respalda las figuras previas bajo el desarrollo, con el fin de facilitar su reproducción a partir de este artículo y fortalecer así la divulgación de los aportes científicos veraces.

Este código podrá encontrarse completo en el repositorio github, según enlace señalada posteriormente.

https://github.com/murilloj/journalstips_flutter/blob/master/lib/screens/product_detail_screen.dart

Figura 6

Journal's Tips By UP en dispositivos con sistema iOS y Android

```
import 'package:journalstips/constants/colors.dart';
import 'package:journalstips/constants/navigation.dart';
import 'package:journalstips/data/banner_model.dart';
import 'package:journalstips/screens/home.dart';
import 'package:flutter/material.dart';
import 'package:url_launcher/url_launcher.dart';
String textoResumen =
  'Proyecto d.';
String textoTitulo =
  "SELECCIONE UN ELEMENTO y descargue en el BOTÓN Azul, al final del
Resumen";
class ProductDetailScreen extends StatefulWidget {
  int index;
  ProductDetailScreen({super.key, required this.index});
```

CONCLUSIÓN

Un enfoque innovador para la divulgación científica, Journal's Tips by Up se posiciona como una herramienta innovadora en el ámbito de la divulgación científica, diferenciándose de las aplicaciones existentes por su enfoque integral que combina diversos formatos de contenido y herramientas interactivas para fomentar el aprendizaje y la participación de los usuarios.

Entre los aportes significativos tenemos el Acceso a información científica de calidad: La aplicación brinda a los usuarios acceso inmediato a información científica veraz y actualizada, proveniente de fuentes confiables y de alto impacto. Fomento del interés por la ciencia: Journal's Tips by Up busca despertar y cultivar el interés por la ciencia y la investigación en la población, especialmente entre los jóvenes, a través de contenido atractivo y dinámico. El Aprendizaje activo y participativo: La aplicación promueve un aprendizaje activo y participativo mediante herramientas interactivas que estimulan la reflexión, el análisis y la resolución de problemas por parte de los usuarios.

El impacto en la comunidad universitaria, incluyendo docentes, estudiantes y personal administrativo, se beneficia enormemente de Journal's Tips by Up, ya que tienen acceso directo a lo último en materia de innovación, producción y publicaciones científicas relacionadas con la Universidad de Panamá.



La aplicación ha sido diseñada cuidadosamente sobre la base de hallazgos de revisiones de literatura y en consulta con expertos en desarrollo de aplicaciones móviles y divulgación científica. Se evaluaron diferentes frameworks de desarrollo, optando finalmente por Flutter Multiplataforma por su viabilidad y capacidad para crear aplicaciones multiplataforma con un solo código base. La aplicación se encuentra actualmente en fase de desarrollo, con funcionalidades ya implementadas y en constante evaluación para garantizar su compatibilidad, rendimiento y usabilidad en dispositivos iOS y Android.

Journal's Tips by Up se perfila como un modelo de gran utilidad para la divulgación científica, ofreciendo una experiencia de aprendizaje atractiva, interactiva y accesible para una amplia audiencia. Su desarrollo continuo y la incorporación de nuevas funcionalidades prometen un impacto aún mayor en la comunidad científica y en la sociedad en general.

REFERENCIAS BIBLIOGRÁFICAS

Amengual, E. B. (2011). Hacia un Marco de Desarrollo para Apps Móviles. *Universitat de les Illes Balears*. https://tim.uib.es/wordpress/wp-content/uploads/2019/04/JISBD_2017_Amengual_Bibiloni_Mascaro_Palmer.pdf

android developer. (2021). *developer.android*. Retrieved marzo de 2021, from Developer guides: https://developer.android.com/guide?hl=es-419&_gl=1*1fmjid4*_up*MQ..&gclid=CjwKCAjw_LOwBhBFEiwAmSEQAfM-cG5ngzSZATCCi7NBFSNQ5jU8oD5uCrn3C9zNkmwny9HAFwFI5RoCXA8QAvD_BwE&gclsrc=aw.ds

App Master. (s.f.). *appmaster.io*. Retrieved 1 de 4 de 2024, from ¿Qué es la licencia BSD?: <https://appmaster.io/es/blog/que-es-la-licencia-bsd>

Arturo Baz Alonso, I. F. (2024). Dispositivos móviles. *E.P.S.I.G : Ingeniería de Telecomunicación*, 12.

Cocktail marketing - México. (2024). *Audiencia de redes sociales*. Retrieved 1 de 4 de 2024, from Cocktailmarketing.com: <https://cocktailmarketing.com.mx/estadisticas-de-redes-sociales/>

dart dev. (2024). *dart.dev/language*. Retrieved 4 de 2022, from Language Dart: <https://dart.dev/language>

Diccionario panhispánico del español jurídico. (6 de junio de 2024). *dej-enclave2.rae.es*. <https://dej-enclave2.rae.es/lema/aplicaci%C3%B3n-m%C3%B3vil>

flutter dev. (2023). *flutter.dev*. Retrieved 1 de 2023, from multiplatform: <https://flutter.dev/multi-platform>

GCFEGlobal. (6 de 6 de 2024). *edu.gcfglobal.org*. GCFEGlobal Creating Oportunities for a better Life: <https://edu.gcfglobal.org/es/cultura-tecnologica/que-son-las-aplicaciones-o-programas/1/>

Gülcüoğlu, E., Ustun, A. B., & Seyhan, N. (2021). Comparison of Flutter and React Native Platforms. *İnternet Uygulamaları ve Yönetimi Dergisi*, 12(2), 129–143. <https://doi.org/10.34231/IUYD.888243>

Hwang, G. J., & Tsai, C. C. (2011). Research trends in mobile and ubiquitous learning: a review of publications in selected journals from 2001 to 2010. *British Journal of Educational Technology*, 42(4), E65–E70. <https://doi.org/10.1111/J.1467-8535.2011.01183.X>

Instituto Nacional de Estadística y Censo. (2023). Instituto Nacional de Estadística y Censo (INEC). https://www.inec.gob.pa/publicaciones/Default3.aspx?ID_PUBLICACION=1192&ID_CATEGORIA=4&ID_SUBCATEGORIA=23

javascript. (abril de 2022). *www.javascript.com*. Funciones: <https://www.javascript.com/learn/functions>

kotlinlang. (2021). *kotlinlang.org*. Retrieved marzo de 2021, from kotlin docs: <https://kotlinlang.org/docs/home.html>

Puetaman, I. M. (2016). Desarrollo de Apps: un estudio comparativo entre frameworks libres y privativos. *Boletín Informativo CEI*. <https://revistas.umariana.edu.co/index.php/BoletinInformativoCEI/article/view/1083>

puromarketing.com. (31 de Enero de 2024). *Las redes sociales superan los 5,000 millones de usuarios a nivel mundial*. <https://www.puromarketing.com/16/213271/redes-sociales-superan-millones-usuarios-nivel-global#:~:text=Noticia%20Redes%20Sociales-,Las%20redes%20sociales%20superan%20los%205.000%20millones%20de%2>

Tracy, K. W. (2012). Mobile application development experiences on Apples iOS and Android OS. *IEEE Potentials*, 31(4), 30–34. <https://doi.org/10.1109/MPOT.2011.21825710> usuarios%20a,digitales%20de%20todo%20el%20mundo.

Consideraciones sobre el IoT en el Diseño, construcción y gestión del mantenimiento de edificios

Considerations about IoT in the
Building design, construction and maintenance management

Marjorie Gutiérrez de Gómez

Universidad de Panamá, Facultad de Arquitectura y Diseño, Panamá
marjorie.gutierrez@up.ac.pa <https://orcid.org/0000-0002-7509-1512>

Cristóbal Gómez Sevillano

Universidad de Panamá, Facultad de Arquitectura y Diseño, Panamá
Cristobal.gomez@up.ac.pa <https://orcid.org/0000-0002-6324-2272>

DOI <https://doi.org/10.48204/3072-9696.6358>

RESUMEN

La inteligencia artificial (IA), genera controversia si se aplica en el ejercicio de las profesiones liberales que se pensaban eran actividades exclusivas para los humanos; tal como crear cuadros o pinturas, redacción de textos, o el diseño arquitectónico. Sin embargo, el impacto que tienen estas tecnologías ha sido tal que, si no nos actualizamos, iremos perdiendo capacidad de ejecución y por ende quedando obsoletos. Las redes inalámbricas tienen como objetivo proporcionar conectividad de datos y de información con alta eficiencia energética, bajo costo y admitir una gran cantidad de dispositivos conectados como una evolución del Internet de las cosas (IoT), tanto en los procesos de diseño, de construcción, como en el funcionamiento del edificio, en su mantenimiento y en la inserción diaria en la vida de las ciudades inteligentes. Haremos aquí un rápido recuento de las aplicaciones (IoT) disponibles ya en nuestra área de trabajo, con la intención de promover y motivar su uso en los proyectos de intervención en la edificación.

PALABRAS CLAVE.

Domótica; Internet de las cosas; Edificios y Ciudades inteligentes; Sostenibilidad.

ABSTRACT

Artificial intelligence (AI) generates controversy if it is applied in the exercise of liberal professions that were thought to be exclusive activities for humans, such as creating pictures or paintings, writing texts, or architectural design. However, the impact that these technologies have has been such that, if we do not update ourselves, we will lose execution capacity and therefore become obsolete. Wireless networks aim to provide data and information connectivity with high energy efficiency, low cost and

support many connected devices as an evolution of the Internet of Things (IoT) both in the design and construction processes, as well as in the operation of the building, its maintenance and daily insertion into the life of smart cities. Here we will make a quick review of the (IoT) applications already available in our work area, with the intention of promoting and motivating their use in building intervention projects.

KEYWORDS.

Home Automation; Internet of Things; Smart Buildings and Cities; Sustainability.

INTRODUCCIÓN

Desde que el internet comenzó a hacerse presente en las casas y las escuelas, nuestro mundo está en un constante cambio, utilizando la tecnología para automatizar la realización de tareas y mejorar la calidad de vida de la gente.

Las redes inalámbricas tienen como objetivo proporcionar conectividad de datos e información con alta eficiencia energética, bajo costo y admitir una gran cantidad de dispositivos conectados como una evolución del Internet de las cosas (IoT) en la edificación y en las ciudades inteligentes.

La inteligencia artificial (IA), genera controversia ya que su apoyo en las profesiones que se pensaba eran exclusivas para los humanos; tal como crear cuadros o pinturas, redacción de textos, poesía, música, realización de varias versiones para un diseño arquitectónico con sus renders o perspectivas incluidas. Al punto de que, un ciento de expertos han propuesto que, se suspenda su uso por un periodo de 6 meses, para que se pueda regular y ¿evitar en un futuro, dañar a la humanidad? En este sentido, ¿se debería enfocar la IA solo en cubrir las áreas críticas de la salud humana, como por ejemplo en aplicaciones para la cura del cáncer?

Síntesis de las Aplicaciones IoT en la Edificación

En el ámbito de la arquitectura, el uso de las tecnologías IoT, como evolución de la automatización en la edificación o DOMÓTICA, puede hacer uso de los “gemelos digitales” (*SmartWins*) o simulaciones, con el fin de impulsar la investigación en un entorno sostenible, inteligente y neutral en carbono, tal como:

- La coordinación efectiva en el diseño arquitectónico, sanitario, electromecánico, estructural, etc., mediante el *Modelado de la Información en la Construcción* (BIM).
- Así como en la evaluación y control de las unidades ya construidas, utilizando sensores inteligentes y libros de registro digitales para realizar la medición y análisis energético de los edificios en un futuro muy cercano.
- Además, en el estándar de información BIM, recientemente se han desarrollado “*capas adicionales de información*”, o niveles de desglose, relacionadas con la **sostenibilidad del entorno construido**, que pueden

mejorar la información proporcionada a los propietarios y usuarios de edificios con respecto al desempeño ambiental de su edificio (Forkaides, P., et al., 2022).

Figura 1

Control a través del celular de los objetos sistemas de agua potable, gas, etc de los edificios.



Fuente: Imagen de <https://designer.microsoft.com/image-creator>.

En ese sentido, el sistema **AIoT** que es la unión de Inteligencia Artificial e Internet de las Cosas (Bosh.com 2024) puede desarrollar la **evaluación, gestión de la operación y el mantenimiento del entorno de seguridad de los edificios**, como aporte a la *“evaluación de la energía y la sostenibilidad de los edificios con el uso de prácticas de Industria 4.0 relacionadas con la investigación y la gestión de la innovación, para la transferencia de conocimientos de las operaciones de mantenimiento y la gestión inteligente de la edificación”* (Paohua, Y., 2021).

Los investigadores, E. M. Taha and A. Elabd consideran que la IoT en las edificaciones debería ser necesaria para la recertificación de Liderazgo en Energía y Diseño Ambiental (LEED) basados en que *“el diseño de edificios sostenibles es actualmente un objetivo destacado para empresas y países. Evaluar y transformar los edificios existentes para hacerlos sostenibles, sigue siendo un desafío pendiente”*. (Taha, A. et al., 2020).

También, Asopa, Purohit, Nadikattu y Whig proponen utilizar la IoT en el desarrollo sostenible de *Edificios y Ciudades Inteligentes*, con un método novedoso para reducir la huella de carbono utilizando “*tecnología verde habilitada para IoT*”. El prototipo, utiliza sensores y termostatos en placas Arduino, junto con un portal web para detectar las salidas de energía. En este estudio, se ha encontrado que la huella de carbono se reduce en más del 22% para un edificio habilitado con el internet de las cosas- IoT (detectar y actuar), en comparación con un edificio normal que no lo utilice. (Asopa, P. et al., 2021).

En el área de investigación académica en arquitectura, existen dispositivos IoT con modelado de conectividad personalizados, para analizar los patrones de comportamiento de los usuarios y las variables del entorno en las ciudades inteligentes, monitoreando así, miles de datos diarios, para optimizar la eficiencia, el rendimiento y la solución a los problemas de los edificios y la ciudad; promoviendo un diseño centrado en las personas. (Reátegui, J. et al, 2021).

Por su parte Bottaccioli, también nos propone una arquitectura de software para la **gestión y simulación de comportamientos energéticos en edificios que integran datos heterogéneos; como BIM, IoT, GIS (Sistema de Información Geográfica) y servicios meteorológicos**”. Esta integración permite, primero la visualización (casi) en tiempo real de la información de consumo de energía en el contexto del edificio y segundo, la evaluación del rendimiento del edificio a través del modelado y simulación de energía que aprovechan los datos de campo y las condiciones climáticas reales. (Bottaccioli, L. et al., 2017).

En cuanto a la rehabilitación de edificios ya existentes, el *Comfort Eye* es una aplicación con sensores infrarrojo IoT para la **medición del rendimiento térmico del edificio**, que garantiza un entorno de vida cómodo y saludable con un consumo mínimo de energía. Este sensor adquiere imágenes termográficas de forma continua y realiza un seguimiento a largo plazo en los edificios, al escanear todas las paredes que dan al exterior. (Serroni S., et al., 2022) O la integración de tecnologías BIM e IoT en sistemas innovadores de **gestión de incendios**, según Sergi y otros autores; con equipos de rescate que deben emprender rápidamente estrategias de intervención encaminadas a evitar la pérdida de vidas humanas. (Sergi, I., et al., 2020).

En otras implementaciones de IoT para edificios inteligentes, podemos **analizar el consumo de agua** Vrsalović, y otros autores, proporcionando a los usuarios datos transparentes en tiempo real. (Vrsalović, A., et al., 2021).

Finalmente, en esta síntesis, haríamos notar un *Sistema Inteligente de Revestimiento de Fachadas*, donde Janabi, y otros, basados en la **detección de multitudes y monitoreo de la calidad del aire propone un banco de pruebas en tiempo real para una fachada cambiante cognitiva**. Los nodos de sensores se utilizan para conectar toda la infraestructura física con tecnologías inteligentes;

incluye dos tipos de nodos IoT: un nodo sensor interior y otro nodo actuador exterior. Se propone el algoritmo de detección ambiental y actuación remota (**ESRAA**) para **permitir que el edificio respire como un pulmón**. Mientras que el sistema inteligente de revestimiento de fachadas (**IFSS**) funciona como “*músculos*” que permiten que los edificios coloquen sus perfiles en la configuración requerida; en otras palabras, la **fachada del edificio se puede transformar aprendiendo el ambiente interior de acuerdo con los estándares de calidad del aire interior**. Se desarrolla un modelo basado en una red neuronal artificial (**ANN**). (Al-Janabi, et al., 2022).

Figura 2:

Fachadas de un edificio con vegetación que mejoran el ambiente interior, con aire de calidad.



Fuente: Representación a través de <https://designer.microsoft.com/image-creator>

CONCLUSIONES

El impacto que ha tenido la tecnología en todas las áreas científicas y por ende en las distintas profesiones, ha sido tal que, si uno no se actualiza, irá perdiendo capacidad de ejecución y por ende quedando obsoleto. Por eso, todas

las actividades industriales, comerciales y agrícolas, están actualizando sus procesos con alta tecnología, por ejemplo, los robots narradores de noticias, los que enseñan, los que fabrican autos, y lo último ya en la ciudad de New York, EE. UU., robots con funciones de policía.

Por otro lado, los resultados de estos impactantes avances, tan prometedores y novedosos abren las puertas a nuevas líneas de investigación para profesionales de la arquitectura, con el fin de brindar mejor calidad de vida a los usuarios; adaptarse a sus nuevas necesidades en los edificios, reducir el coste de operación, mejorar la eficiencia, seguridad, fiabilidad y ser al mismo tiempo ecológicos y sostenibles.

Referencias Bibliográficas

Al-Janabi, I. M., Al-Kaseem, B. R. & Alani, M. W., "Intelligent Façade Skinning System Based on Crowd-Sensing and Air-Quality Monitoring," 2022 Engineering and Technology for Sustainable Architectural and Interior Design Environments (ETSAIDE), Manama, Bahrain, 2022, pp. 1-7, doi: 10.1109/ETSAIDE53569.2022.9906380

Asopa, P. Purohit, P., Nadikattu, R. & Whig, P., (2021). "Reducing Carbon Footprint for Sustainable development of Smart Cities using IoT," 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV), Tirunelveli, India, 2021, pp. 361-367, doi: 10.1109/ICICV50876.2021.9388466

Bottaccioli, L. et al., (2017). "Building Energy Modelling and Monitoring by Integration of IoT Devices and Building Information Models," 2017 IEEE 41st Annual Computer Software and Applications Conference (COMPSAC), Turin, Italy, 2017, pp. 914-922, doi: 10.1109/COMPSAC.2017.75

CES® 2024: Energized #LikeABosch <https://www.bosch.com.co/noticias-e-historias/aiot/> Las Vegas. Consultado del 09 al 12 de enero de 2024.
<https://www.bosch.com.co/noticias-e-historias/aiot/>

Forkaides, P., Jurelionis, A. & Spudys, P., (2022).
https://www.researchgate.net/publication/365110253_Boosting_Research_for_a_Smart_and_Carbon_Neutral_Built_Environment_with_Digital_Twins_SmartWins

Paohua, Y., (2021). "Evaluation of Building Safety Environment Operation and Maintenance Management based on the AioT System," 2021 IEEE 3rd

Eurasia Conference on IOT, Communication and Engineering (ECICE), Yunlin, Taiwan, 2021, pp. 57-60, doi: 10.1109/ECICE52819.2021.9645740

Reátegui, J. L. & Herrera, P. C., (2021). "Customized IoT devices for the architectural education future in connectivity for smart cities," 2021 2nd Sustainable Cities Latin America Conference (SCLA), Medellin, Colombia, 2021, pp. 1-6, doi: 10.1109/SCLA53004.2021.9540124

Sergi, I., Malagnino, A., Rosito, R. C., Lacasa, V., Corallo, A. & Patrono, L., (2020). "Integrating BIM and IoT Technologies in Innovative Fire Management Systems," 2020 5th International Conference on Smart and Sustainable Technologies (SpliTech), Split, Croatia, 2020, pp. 1-5, doi: 10.23919/SpliTech49282.2020.9243838

Serroni S., Arnesano, M., Martarelli M. & Revel, G. M., "Application of an IoT infrared sensor for thermal transmittance measurement in building renovation," 2022 7th International Conference on Smart and Sustainable Technologies (SpliTech), Split / Bol, Croatia, 2022, pp. 1-6, doi: 10.23919/SpliTech55088.2022.9854241

Taha, A. & Elabd, A., (2020). "An IoT Architecture for LEED Certification of Existing Buildings," 2020 IEEE International Conference on Communications Workshops (ICC Workshops), Dublin, Ireland, 2020, pp. 1-5, doi: 10.1109/ICCWorkshops49005.2020.9145407

Vrsalović, A., Perković, T., Andrić, I., Čuvčić, M. A. & Šolić, P., (2021). "IoT Deployment for Smart Building: Water Consumption Analysis," 2021 6th International Conference on Smart and Sustainable Technologies (SpliTech), Bol and Split, Croatia, 2021, pp. 01-05, doi: 10.23919/SpliTech52315.2021.9566437

Arquitectura de robot semiautónomo de búsqueda y rescate de rápida manufactura

Semi-autonomous search and rescue robot architecture of fast manufacturing

Yenikarina Salazar¹

¹Licenciatura en Ingeniería en Mecatrónica - Facultad de Informática Electrónica y Comunicación - Universidad de Panamá,

Yenikarina.salazar@up.ac.pa <https://orcid.org/0009-0007-7603-859X>

Iván Armuelles²

²Facultad de Informática Electrónica y Comunicación - Universidad de Panamá.

Ivan.armuelles@up.ac.pa <https://orcid.org/0000-0002-3429-6546>

Recibido: 21-2-2023, Aceptado: 21-3-2024

DOI <https://doi.org/10.48204/3072-9696.6359>

RESUMEN

En este artículo, se expone el diseño de la arquitectura para desarrollar un prototipo de robot vehicular terrestre no tripulado de búsqueda y rescate de rápida manufactura, que tenga la capacidad de desplazarse en terrenos irregulares, escombros y planos inclinados a través de un sistema semiautónomo que pueda detectar y evaluar el estado de una víctima que se encuentre en peligro entre los escombros de una estructura colapsada. Realizar un vehículo terrestre no tripulado de rápida manufactura debe contar no solo con las capacidades de maniobrabilidad en lugares de difícil acceso, sino también obtener información sobre el entorno físico para localizar a las víctimas mediante sensores, identificar la orientación de desplazamiento dentro del campo, detectar presencia de calor, percibir movimientos en espacios confinados, captar altos niveles de dióxido de carbono y comunicarse con una víctima mediante micrófono y altavoz. El robot móvil debe desempeñar misiones y objetivos de búsqueda y rescate similares a los de un robot industrializado.

PALABRAS CLAVE

Búsqueda, rescate, robótica, telecomunicación.

ABSTRACT

In this paper we propose the development of a rapidly manufactured search and rescue unmanned ground vehicle prototype capable of traveling on uneven terrain, debris, and inclined planes through a semi-autonomous system that can detect and evaluate the state of a victim who is in danger among the rubble of a collapsed structure.

The development of a rapidly manufactured unmanned ground vehicle must not only have maneuverability capabilities in difficult access. Also, obtain information about the physical environment to locate victims through sensors. Being able to identify the orientation of movement within the field, detect the presence of heat, perceive motion in confined spaces, determine the presence of toxic gases, such as high levels of carbon dioxide; communicate with a victim through a microphone and speaker, and be able to respond in case of finding a person alive. The mobile robot must carry out search and rescue missions and objectives similar to those completed by an industrialized robot.

KEYWORDS

Search, rescue, robotics, telecommunication.

INTRODUCCIÓN

A través de la historia, los desastres naturales se han suscitado debido a diferentes factores ambientales y cambios climáticos ocasionados por la tala indiscriminada de bosques y contaminación ambiental provocada por los seres humanos. La mala planificación urbana sobre asentamientos informales es una de las consecuencias de colapso de viviendas por lluvias, inundaciones y terremotos, provocando el derrumbe de las estructuras que dejan atrapadas a personas y animales. El rescate de las víctimas debe ser lo más rápido posible porque cada segundo que transcurre define las posibilidades de sobrevivir de los afectados.

En Panamá, el día 10 de septiembre de 2015, tras intensas lluvias, se produjeron deslizamientos de tierras que afectaron a 55 viviendas en el área de San Miguelito y Juan Díaz, dejando un total de 1,063 personas afectadas (TVN Noticias, 2015). Muchas casas colapsaron y fueron desalojadas para evitar la pérdida de vidas humanas. El Sistema Nacional de Protección Civil (SINAPROC) brindó el apoyo, seguridad y traslado para los damnificados que fueron reubicados. Éste es uno de los sucesos con más damnificados por el colapso de estructuras que se pudo registrar en ese año (UNDRR,2020).

Las siguientes instituciones gubernamentales de Panamá, son las encargadas de prestar servicios de ayuda y rescate a la ciudadanía:

- a. **Benemérito Cuerpo de Bomberos de la República de Panamá:** Institución encargada de la seguridad ciudadana, con personal altamente capacitada para salvaguardas y proteger vidas. Esta institución posee una unidad encargada de las operaciones de extinción de fuego, búsqueda y rescate de animales y personas en peligro, llamada Dirección de Operaciones de Extinción, Búsqueda y Rescate (DOEXBURE) (Cuerpo de Bomberos, 2022).
- b. **El Sistema Nacional de Protección Civil (SINAPROC):** Institución encargada de salvaguardar la vida de los ciudadanos en situaciones de peligro y cuentan con un equipo especialmente entrenado en el rescate urbano, llamado "USAR PANAMÁ" (SINAPROC, 2019).

El Benemérito Cuerpo de Bomberos y el SINAPROC no disponen de un vehículo no tripulado terrestre para realizar las tareas de búsqueda y rescate de víctimas que se encuentren bajo los escombros en caso de colapso de estructuras; sólo cuentan con el personal técnico capacitado, instrumentos tecnológicos, indumentaria especializada y herramientas de trabajo para proceder a una labor de búsqueda y rescate, adaptándose a los sistemas de comandos, técnicas, normas y protocolos internacionales, pero arriesgando la vida de los colaboradores y la unidad canina.

Se pretende que, con el desarrollo de un vehículo no tripulado de rápida manufactura para la búsqueda y rescate, los rescatistas no arriesguen sus vidas al introducirse en espacios reducidos o de poco acceso, apoyándose en la tecnología para obtener un escaneo físico de la víctima y un mejor pronóstico para reducir el tiempo de exposición al peligro. Es importante que, al desarrollar un prototipo de rápida manufactura, se disminuyan los costos de producción, pero aumentando la resistencia en los materiales, utilizando impresoras 3D y máquinas de corte láser, para mantener las mismas características de operación de un prototipo de rescate desarrollado en países industrializados.

El objetivo del presente artículo es establecer el modelo de arquitectura que debe seguir al diseño e implementación de un robot semiautónomo de Búsqueda y Rescate de Rápida Manufactura. Por lo tanto, el presente artículo se estructura de la siguiente manera, después de la presente Introducción, en la sección 2 se muestra el estado del arte intentando establecer los trabajos previos para la definición de robots de búsqueda y rescate. En la sección 3 se justifica la importancia de esta investigación para la República de Panamá; en la sección 4, se aborda la metodología del trabajo de investigación general; en la sección 5 se definen los requisitos funcionales para el establecimiento de la arquitectura del robot semiautónomo de Búsqueda y Rescate de Rápida Manufactura. Finalmente, en la sección 6 se expresan las conclusiones del artículo, además se añaden agradecimientos y referencias.

ESTADO DEL ARTE

Partimos de un análisis documental de tipo cualitativo, en búsqueda de datos reciente sobre los robots de búsqueda y rescate, a través de documentos, investigaciones, avances tecnológicos y la adquisición de información en las bases de datos de revistas especializadas a nivel nacional e internacional. Se realizaron entrevistas para conocer el panorama real que se está estableciendo en las instituciones gubernamentales y competentes.

El diseño de un robot de búsqueda y rescate terrestre de rápida manufactura se inspira en las iniciativas internacionales para la creación de modelos de robots que tengan la posibilidad de ser construidos rápidamente. Una de estas iniciativas es la Competencia Internacional “Rapidly Manufactured Robot Challenge (RMRC) (RoboCup Junior, 2018) de la RoboCup Junior (Robocup Junior, 2022) que promueve el desarrollo de robots compactos (0.30m de ancho) de bajo costo y de fabricación rápida, dirigido por el Instituto Nacional de Estándares y Tecnología

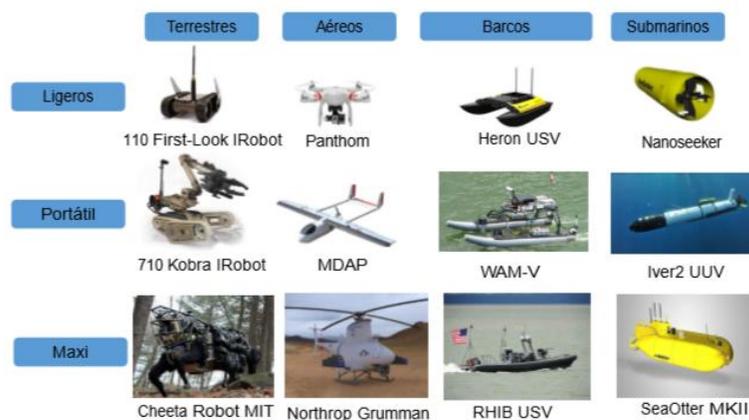
(NIST, National Institute of Standards and Technology) de los Estados Unidos (NIST, 2019).

1.1. Tipos de robots de Búsqueda y Rescate

A continuación, realizamos una clasificación de los robots de búsqueda y rescate que se han desarrollado en la actualidad (Tordesillas, 2015) como se muestra en la figura 1.

Figura 1.

Clasificación de los robots de búsqueda y rescate.



Nota: Fuente: J. Tordesillas Torres. “Diseño y Simulación del Sistema de Locomoción de un Robot Hexápodo para tareas de búsqueda y rescate”. Tesis de grado. Universidad Politécnica de Madrid, España. 2015-2016.

1.1.1. Ligeros (Man-packable)

Suelen ser los primeros en desplegarse en las situaciones de desastre y suelen transportarse fácilmente por los escombros o superficies.

1.1.2. Portátiles (Man -Portable)

Estos robots pueden ser llevados por dos personas a una distancia corta.

1.1.3. Maxis

Son muy pesados. Para ser transportados se necesitan de la ayuda de camiones o vehículos espaciales.

1.2. Tipos de robots según el entorno

1.2.1. Terrestres (UGVs - Unmanned Ground Vehicles)

Son los robots con mayor aplicación práctica en las tareas de evacuación de víctimas, retiro de escombros y búsqueda en estructuras colapsadas.

1.2.2. Aéreos (UAVs – Unmanned Aerial Vehicles)

Se usan principalmente para labores de reconocimiento y mapeo de la zona.

1.2.3. Barcos (USVs - Unmanned Surface Vehicles)

Su principal utilidad está en las labores de rescate tras inundaciones y tsunamis.

1.2.4. Submarinos (UUVs - Unmanned Underwater Vehicles)

Se suelen usar para inspección de zonas submarinas. De esta clasificación podemos concluir que nuestro proyecto se ubica dentro de la clasificación en la creación de un robot tipo ligero (man-packable) y terrestre no tripulado (UGV).

2. Importancia de la creación de un robot de búsqueda y rescate de rápida manufactura

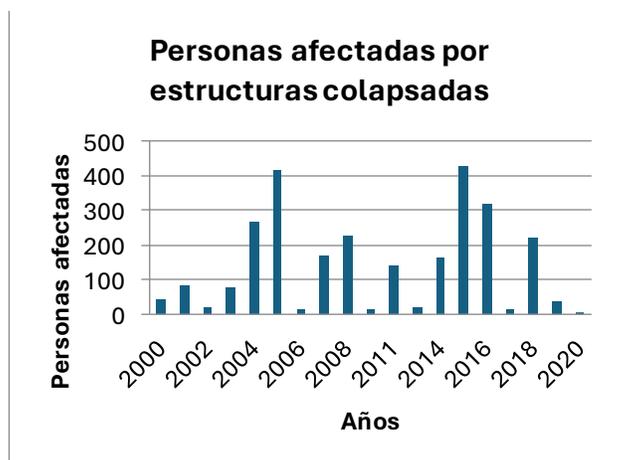
En Panamá, y a nivel mundial, se incrementa el interés por el uso de la robótica para la realización de tareas rutinarias y/o de riesgo para los seres humanos. Debido al crecimiento de la población mundial, los cambios climáticos negativos, la falta de la planificación en la construcción de los entornos urbanos, etc., es cada vez más común y frecuente tener que enfrentar situaciones de riesgo como ciudadanos. Los países han tenido que implementar protocolos de acción y la creación de unidades responsables en el salvamento de víctimas de distintos tipos de eventos naturales o provocados. Muchos de estos eventos son peligrosos para los mismos rescatistas por lo que la Robótica ha sido un pilar de apoyo para la realización de salvamentos.

De todas las catástrofes acontecidas en núcleos urbanos, se ha estimado que el 80% de los sobrevivientes son víctimas que se encuentran en la superficie o fácilmente visibles. Sin embargo, el 20% restante son víctimas con mayor posibilidad de muerte bajo los escombros. Este porcentaje de afectados es la causa principal por la que nos motiva a crear robots de rescate, ya que los robots pueden explorar bajo las ruinas y encontrar sobrevivientes (Tordesillas, 2015).

En la base de datos del "Sistema de Inventario de Efectos de Desastres (DesInventar)" (UNDRR, 2020), de la Red de Estudios Sociales en Prevención de Desastres en América Latina (LA RED), se pueden encontrar estadísticas actualizadas de los desastres naturales más frecuentes en Panamá.

Gráfica 1.

Promedio de personas afectadas por estructuras colapsadas. Panamá: 2000-2020.



Nota: Datos suministrados en la página web: <https://www.desinventar.net/DesInventar/profiletab.jsp?countrycode=pan&continue>
≡

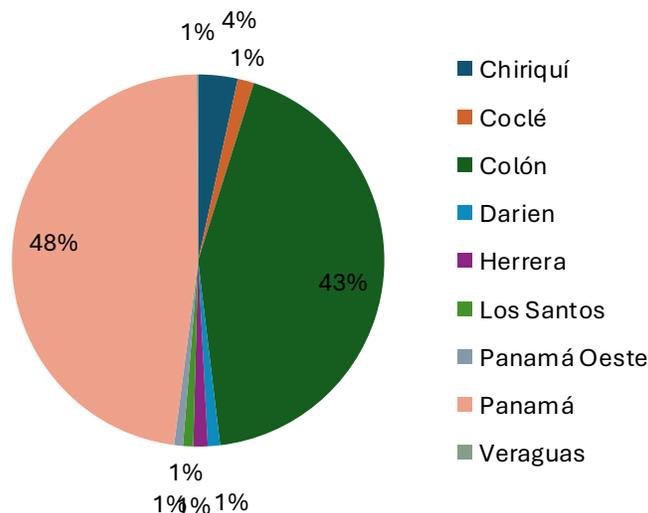
La gráfica 1 muestra un promedio aproximado de personas afectadas por estructuras colapsadas que entre los años 2000 al 2020, siendo los años 2005 y 2015 con mayor número de damnificados a nivel nacional.

La mayor cantidad de registros de estructuras colapsadas corresponden a la provincia de Panamá (48%) y Colón (43%), estos datos fueron obtenidos en la base de datos Desinventar (UNDRR; 2020), como se muestra en la Gráfica 2. Esta base de datos se sigue actualizando manualmente por el SINAPROC (Gordón,2014).

Gráfica 2.

Porcentaje de Provincias afectadas por estructuras colapsadas. Panamá: 2000 - 2020.

Provincias afectadas por estructuras colapsadas 2000 - 2020



Nota: Datos suministrados en la página web: <https://www.desinventar.net/DesInventar/profiletab.jsp?countrycode=pan&continue>
≡

Los desastres naturales más frecuentes en Panamá son los deslizamientos de tierra e inundaciones, causadas mayormente por la mala disposición de la basura, tala de árboles y malas edificaciones.

El objetivo principal de esta investigación es demostrar la capacidad de crear prototipos de robots de búsqueda y rescate de bajo costo, fácil replicación y que pueda utilizarse eficientemente en distintos escenarios en los que se requiera la movilidad terrestre.

METODOLOGÍA

La metodología que se utilizará para esta investigación se detalla a continuación:

- Se estudian los requisitos derivados del diseño de un robot de rescate para identificar los sistemas de locomoción más aptos utilizados en un rescate o búsqueda de víctimas a nivel terrestre.
- Se realiza un análisis y selección del tipo de ruedas que le darán movimiento al vehículo en terrenos planos e irregulares.
- Se investigan los requisitos funcionales que debe tener un robot de búsqueda y rescate en función a los objetivos planteados en el diseño y confección.
- El diseño involucra también la creación y planificación de diversos módulos como el de energía, de comunicaciones, la estación de tele-operación, módulo de instrumentación (sensores) para el reconocimiento del entorno y detección de víctimas, entre otros.
- Programación de los sensores y motores para las tareas de búsqueda y rescate de forma tele- operada.
- Concretar el sistema de comunicación entre el operador, el robot móvil y la víctima.
- Por último, verificar el funcionamiento del prototipo en un entorno de prueba estándar, evaluar su efectividad, identificar y corregir fallas para mejorar el rendimiento y eficiencia del equipo.

ARQUITECTURA FUNCIONAL

Los requisitos funcionales con los que debe contar un prototipo de vehículo no tripulado de búsqueda y rescate terrestre de rápida manufactura son los siguientes:

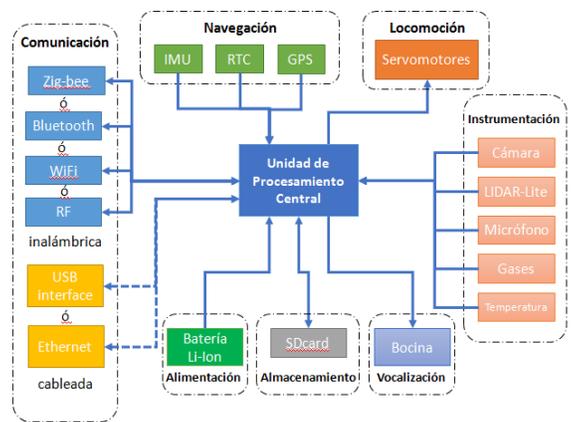
- Debe contar con sensores y múltiples herramientas para adentrarse entre estructuras no uniformes y espacios confinados.
- Deberá procesar sonidos e imágenes y transmitir la información en tiempo real, según las condiciones del medio.
- Las imágenes transmitidas serán usadas para su tele-operación y con el apoyo de los sensores se podrá mejorar la inspección del entorno (por ejemplo, con un láser portátil o LIDAR-Lite) para la toma de decisiones en menor tiempo y aumentando las probabilidades de rescate de las víctimas.
- Las dimensiones deben ser adaptadas al entorno en el que se va a desempeñar el prototipo de búsqueda y rescate.
- El robot móvil podrá identificar la orientación de desplazamiento dentro del campo (usando una Unidad de Medición Inercial –IMU), detectar presencia de calor, percibir movimientos en espacios confinados, determinar los altos niveles

de dióxido de carbono; comunicarse con una víctima mediante micrófono y altavoz, detectar sonido y poder responder en caso de encontrar a una persona con vida.

Todos estos requisitos funcionales serán considerados en la implementación final, además no se mencionan otros requisitos de diseño como son la economía y rapidez de producción ya que son requisitos de fabricación.

Figura 2.

Arquitectura de alto nivel del vehículo no tripulado de búsqueda y rescate, utilizando un microcontrolador como memoria principal para el control de las funciones.



Cada proceso enumerado como requisito funcional será coordinado a través de la unidad de procesamiento Central (microprocesador), como se muestra en la figura 2, encargado de controlar los elementos de entrada/salida, vocalización, alimentación, comunicación, navegación, locomoción e instrumentación. Mediante el bloque de comunicación, el sistema debe comunicarse con un operador desde su consola, recibiendo información del entorno a través del robot móvil.

CONCLUSIÓN

Mediante la propuesta de la arquitectura de un robot de búsqueda y rescate, se espera que, en un futuro próximo, como resultado de nuestra investigación, se pueda implementar un vehículo móvil limitándose únicamente a las actividades de búsqueda y rescate en tierra a una distancia no mayor de 100 metros de línea de vista de los rescatistas.

Aunque se pretende el rescate de víctimas, dichas actividades no incluyen el desplazamiento ni extracción de las víctimas, sino su detección y el establecer un medio de comunicaciones y evaluación del estado de la víctima para facilitar el rescate. También se excluye de esta actividad, el retiro de los escombros, sino su navegación entre éstos.

Para la implementación del prototipo, se contemplan los parámetros requeridos para participar en la Competencia Internacional “Rescue Rapidly Manufactured Robot Challenge” de la RoboCup Junior y los reglamentos del NIST de los EE.UU que permiten calificar la eficiencia de un robot de rescate válido para actividades de la vida real dentro de un escenario de rescate.

REFERENCIAS

- Benemérito Cuerpo de Bomberos de la República de Panamá. (2022). Misión y Visión. Disponible: <https://www.bomberos.gob.pa/mision-y-vision/>
- Gordón, C. 2014. “Caracterización de la ocurrencia e impacto por desastres de origen natural en Panamá”. Universidad Santa María La Antigua (USMA). República de Panamá. vol: 2. pág: 04-25.
- National Institute of Standards and technology. U.S. Department of Commerce. 2019. Disponible: <https://www.nist.gov/>
- Redacción de TVN Noticias. (2015). “Samaria y Juan Díaz, los sectores más afectados por las lluvias en la capital”. TVN Noticias. República de Panamá. Disponible: https://www.tvn-2.com/nacionales/panama/Samaria-Juan-Diaz-sectores-afectados-panama_0_4298570229.html
- RobocupJunior. (2018, Mayo 24). RobocupRescue League - RapidlyManufactured Robot Challenge.Robocup Junior. Disponible: <https://junior.robocup.org/robocuprescue-league-rapidly-manufactured-robot-challenge/>
- [RobocupJunior. (2022). Robocup Junior: Creating a learning for today, fostering technological advancement for tomorrow. Robocup Junior. Disponible: <https://junior.robocup.org/>
- Sistema Nacional de Protección Civil. (2019). Plataforma web CendiccGer. República de Panamá. Disponible: <http://prevencionpanama.com/>
- Tordesillas Torres, J. 2015. “Diseño y Simulación del Sistema de Locomoción de un Robot Hexápodo para tareas de búsqueda y rescate”. Tesis de grado. Universidad Politécnica de Madrid, España.
- UNDRR, DesInventar, SENDAI. 2020. Sistema gratuito de gestión de información sobre desastres de código abierto. Mapa de consulta de Panamá. Disponible: <https://www.desinventar.org/>

Estudio de las llamaradas solares y su influencia en los canales de comunicación electrónica mediante la implementación de un sistema de monitoreo para la banda de frecuencia VLF

Study of solar flares and their influence on electronic communication channels through the implementation of a monitoring system for the VLF frequency band

Angie K. Márquez A.,
Universidad de Panamá, Panamá
angie.marquez01@up.ac.pa <https://orcid.org/0009-0007-4120-7242>,

Axel A. Márquez Z.
Universidad de Panamá, Panamá,
axel.marquez@up.ac.pa <https://orcid.org/0009-0003-7031-0637>

Fermín A. Póvaz J.,
Universidad de Panamá, Panamá,
fermin.povaz@up.ac.pa <https://orcid.org/0000-0001-7657-9408>,

Recibido: 31-1-2024, Aceptado: 8-5-2024

DOI <https://doi.org/10.48204/3072-9696.6360>

RESUMEN

Este trabajo de investigación analiza la no incidencia de las llamaradas solares en los sistemas de comunicación inalámbrica que operan en la banda de frecuencia de microondas, específicamente en la banda S (2.4 GHz), como las redes WiFi. El estudio se centra en la influencia de las llamaradas solares en la propagación de ondas electromagnéticas en la banda de Frecuencias Muy Bajas (Very Low Frequency, VLF). Se implementó un sistema de monitoreo que incluye antenas loop, receptores VLF especializados y microcontroladores para capturar datos en tiempo real. Este sistema permitió investigar la relación entre eventos solares y la variabilidad en la propagación de ondas VLF, con aplicaciones relevantes en comunicaciones submarinas y sistemas de navegación. El análisis abarca los antecedentes del problema, la metodología de investigación y la contribución al conocimiento del clima espacial. Además, se examinan los tipos de filtros, sistemas de recepción y antenas utilizados, destacando su importancia en la captura precisa de datos durante eventos solares. Los resultados de esta investigación avanzan en el entendimiento de los impactos de los fenómenos solares en las comunicaciones electrónicas en la banda VLF, proporcionando información valiosa para mitigar posibles efectos adversos.

PALABRAS CLAVES:

Llamaradas Solares, Banda de Frecuencia VLF, Sistema de Monitoreo, Comunicaciones Electrónicas, Antenas Loop, Propagación de Ondas, Microcontroladores, Clima Espacial, Comunicación Submarina, Navegación Electrónica.

ABSTRACT

This research work analyzes the non-occurrence of solar flares on wireless communication systems operating in the microwave frequency band, specifically in the S band (2.4 GHz), such as WiFi networks. The study focuses on the influence of solar flares on the propagation of electromagnetic waves in the Very Low Frequency (VLF) band. A monitoring system was implemented that includes loop antennas, specialized VLF receivers, and microcontrollers to capture real-time data. This system allowed for the investigation of the relationship between solar events and the variability in VLF wave propagation, with relevant applications in submarine communications and navigation systems. The analysis covers the background of the problem, the research methodology, and the contribution to the knowledge of space weather. Additionally, the types of filters, reception systems, and antennas used are examined, highlighting their importance in accurately capturing data during solar events. The results of this research advance the understanding of the impacts of solar phenomena on electronic communications in the VLF band, providing valuable information to mitigate possible adverse effects.

KEYWORDS

Solar Flares, VLF Frequency Band, Monitoring System, Electronic Communications, Loop Antenna, Wave Propagation, Microcontrollers, Space Weather, Submarine Communication, Electronic Navigation.

INTRODUCCIÓN

El Sol, como fuente primaria de radiación electromagnética, desencadena eventos dinámicos, entre ellos, las llamaradas solares. Estas emisiones de energía pueden tener consecuencias significativas en la atmósfera terrestre, especialmente en la ionosfera, y afectar la propagación de ondas de radio en la banda VLF. La banda VLF, abarcando frecuencias entre 3 kHz y 30 kHz, es vital para aplicaciones como comunicaciones submarinas y sistemas de navegación (Isak, 2022).

La investigación sobre el impacto de las llamaradas solares en las comunicaciones electrónicas se remonta a los primeros estudios del siglo XX. A medida que

avanzaba la tecnología de las comunicaciones, los científicos comenzaron a observar fenómenos inesperados en la propagación de las ondas electromagnéticas durante eventos solares. Los primeros estudios buscaron comprender cómo la radiación solar afecta la ionosfera y la propagación de ondas de radio de baja frecuencia (Webb y Howard, 2012).

En la actualidad, la comunicación electrónica es esencial para la vida moderna y abarca desde las telecomunicaciones cotidianas hasta aplicaciones importantes como la navegación y el seguimiento del medio ambiente. La propagación eficiente de ondas electromagnéticas a través de la atmósfera terrestre es fundamental para garantizar la integridad y confiabilidad de estos sistemas (UIT-R, 2016). Sin embargo, los fenómenos naturales siempre obstaculizan esta propagación, y las llamaradas solares son uno de los más fascinantes y potencialmente perjudiciales.

Las llamaradas solares, que son explosiones súbitas de energía en la atmósfera solar, producen radiación electromagnética de una amplia gama de longitudes de onda. Al interactuar con la ionosfera de la Tierra, esta radiación puede tener un impacto significativo en la propagación de ondas electromagnéticas, lo que tiene un impacto directo en los sistemas de comunicación. Debido a su uso en áreas como las comunicaciones submarinas, los sistemas de navegación y el monitoreo ambiental, la banda de frecuencia muy baja (VLF) se ha vuelto cada vez más importante (Du et al., 2023).

La comprensión completa de cómo las llamaradas solares afectan específicamente la propagación de ondas en la banda VLF es esencial para contextualizar el problema. La falta de conocimiento detallado sobre los efectos de las llamaradas solares en la banda VLF presenta un desafío importante para la confiabilidad y la continuidad de estas aplicaciones debido a la creciente dependencia de sistemas tecnológicos en esta frecuencia, desde la comunicación entre submarinos hasta la transmisión de datos para investigaciones científicas.

Para abordar estas incertidumbres en este contexto, la investigación busca comprender mejor la relación entre las llamaradas solares y la propagación de ondas en la banda VLF. Este conocimiento no solo servirá como base teórica para la física solar y de la ionosfera, sino que también tendrá aplicaciones prácticas para el diseño y la operación de sistemas críticos que utilizan la banda VLF. De esta manera, ayudará a garantizar la seguridad y la eficacia de una variedad de aplicaciones de comunicación electrónica (Adlard, Tozer & Burr, 1999).

La confiabilidad y la eficiencia de las comunicaciones electrónicas pueden verse afectadas durante eventos solares por variabilidad en la ionosfera, cambios en la atenuación de señales y otros fenómenos relacionados. La falta de investigación exhaustiva en este campo deja numerosas preguntas importantes sin respuesta: ¿De qué manera se altera la propagación de las ondas VLF durante una llamarada solar? ¿Cómo afecta la comunicación electrónica en esta banda de frecuencia crítica?

Se plantea la siguiente hipótesis debido a la falta de investigación específica sobre la interacción entre llamaradas solares y bandas de frecuencia muy bajas (VLF) en las comunicaciones electrónicas.

La propagación de ondas electromagnéticas en la banda VLF se verá muy alterada durante llamaradas solares. La validación de estas hipótesis ayudará a comprender mejor la compleja interacción entre las llamaradas solares y la propagación de ondas en la banda VLF. Esto permitirá desarrollar medidas prácticas para mejorar la confiabilidad y la eficiencia de los sistemas que utilizan esta frecuencia crucial en las comunicaciones electrónicas.

La estructura metodológica se basa en los objetivos de la tesis y se centra en comprender cómo las llamaradas solares y las bandas de frecuencia muy bajas (VLF) interactúan en las comunicaciones electrónicas.

El enfoque de la investigación es cuantitativo y experimental. Se diseñó y construyó un sistema de monitoreo para capturar datos VLF durante eventos de llamaradas solares, con el objetivo de analizar la variabilidad en la propagación de ondas VLF en respuesta a la actividad solar.

Se seleccionaron eventos solares de diferente intensidad y duración para garantizar una comprensión exhaustiva de la interacción entre llamaradas solares y la banda VLF. El sistema de monitoreo VLF incluye antenas, amplificadores y dispositivos de registro de datos.

Los datos se recopilaron durante eventos solares y las variaciones en la propagación de las ondas VLF se registraron continuamente. Estos datos se correlacionarán con la actividad solar observada para encontrar patrones y tendencias.

Se utilizaron técnicas de procesamiento de señales y análisis estadístico para investigar las correlaciones entre la variabilidad en la propagación de ondas VLF y la intensidad y duración de las llamaradas solares. Además, se examinó cómo los cambios en la ionosfera y la atenuación de señales VLF se relacionan durante eventos solares.

El término "clima espacial" se refiere a las condiciones en la atmósfera solar y el espacio interplanetario que afectan las actividades humanas y los sistemas tecnológicos. La actividad solar, especialmente las llamaradas solares, es clave en el clima espacial, liberando energía en forma de radiación electromagnética. "El clima espacial afecta a las actividades en la Tierra, como las telecomunicaciones (satélites que controlan los teléfonos, el Internet y la televisión), la red eléctrica y las plantas petroquímicas, la navegación aérea y los sistemas de posicionamiento, el clima terrestre, e incluso la salud de los seres vivos" (Ruiz, Cruz y Díaz, 2017).

Las llamaradas solares son fenómenos explosivos en la atmósfera solar que liberan rápidamente grandes cantidades de energía debido a la reconfiguración de los campos magnéticos en la superficie del Sol. Esta energía se manifiesta en radiación

electromagnética y viento solar (Schrijver & Siscoe, 2010). La potencia de la radiación de rayos X determina esta clasificación. Clasificación de llamaradas solares:

Clase X: Más intensa.

Clase M: Menor intensidad.

Clase C: Aún menor.

Las eyecciones de masa coronal (Coronal Mass Ejection) o CME son eventos en los que grandes cantidades de material solar, como plasma y campos magnéticos, se expulsan al espacio interplanetario. A diferencia de las llamaradas solares, las CME tienen un impacto significativo en la magnetosfera terrestre (Kilpua et al., 2017).

Cuando una CME alcanza la magnetosfera, puede provocar auroras y tormentas geomagnéticas que afectan las operaciones de comunicación y navegación.

El concepto de bandas de frecuencia es fundamental para entender cómo las llamaradas solares y eventos solares pueden afectar la propagación de ondas electromagnéticas, especialmente en la banda de frecuencia VLF (Group, 2013). Aquí se explora la relevancia de las bandas de frecuencia en el marco de la investigación.

Las ondas electromagnéticas se clasifican en función de su frecuencia. Esta clasificación es crucial para comprender cómo diferentes fenómenos solares afectan las comunicaciones electrónicas en diversas aplicaciones. Las principales bandas incluyen:

Baja Frecuencia (LF): 30 kHz a 300 kHz.

Very Low Frequency (VLF): 3 kHz a 30 kHz.

Ultra Low Frequency (ULF): 300 Hz a 3 kHz.

Para la investigación sobre cómo las llamaradas solares influyen en la propagación de ondas VLF, la implementación de filtros es crucial para seleccionar y analizar las señales de interés en la banda de baja frecuencia (VLF). Los filtros de banda VLF son esenciales para asegurar que solo las señales relevantes dentro de la gama de frecuencias VLF sean procesadas. La selectividad de frecuencia de un sistema de filtrado se encuentra directamente ligada al orden de dicho sistema. (Jaramillo Alvarado et al., 2017).

En el contexto de una tesis sobre llamaradas solares y su impacto en las ondas VLF, los sistemas de recepción son cruciales. Los receptores VLF especializados son ideales para la banda VLF, con una arquitectura optimizada para capturar señales eficientemente. Los receptores de onda completa permiten analizar múltiples

frecuencias, clave para estudiar cambios en la propagación de ondas durante eventos solares. Los receptores de alta sensibilidad son esenciales dada la baja intensidad de las señales VLF, facilitando la captura de variaciones sutiles durante eventos solares.

Las antenas son fundamentales en la recepción de señales VLF, especialmente al estudiar la influencia de las llamaradas solares (Gu et al., 2023). Las antenas de bucle magnético son efectivas para capturar componentes magnéticas de ondas VLF, siendo ideales en investigaciones solares.

MATERIALES Y MÉTODOS

El enfoque de la investigación se circunscribe al área de estudio que limitará los lugares de implementación del sistema de monitoreo. Aunque la selección de estos sitios será estratégica, no se garantiza una cobertura global. Por lo tanto, los resultados obtenidos pueden no reflejar completamente la variabilidad geográfica en la interacción entre las llamaradas solares y las frecuencias muy bajas (VLF). Es importante mencionar que la ubicación geográfica específica cuenta con las siguientes coordenadas: 8°59'58.0"N 79°29'50.0"W.

Se diseñó e implementó la unidad receptora de VLF, la capturadora de datos y la antena loop correspondiente. La antena VLF, primer componente crucial, se eligió por su capacidad de capturar eficientemente ondas electromagnéticas de baja frecuencia. Estas antenas se ubicaron estratégicamente para maximizar la recepción de señales VLF y minimizar la interferencia externa. La antena se diseñó utilizando un cable AWG 20 con una longitud diagonal de 1 metro en cada lado. Los valores de la antena se obtuvieron mediante las siguientes fórmulas utilizadas en su diseño.

$$w = \frac{\sqrt{2}}{2} L$$

$$p = 4 * w$$

$$A = w^2$$

$$Lc = p * T$$

$$Lh = N^2 \frac{\mu_0 \mu_r}{\pi} \left[-2(w + h) + 2\sqrt{h^2 + w^2} - h \left(L_N \left[\frac{h + \sqrt{h^2 + w^2}}{w} \right] \right) - w \left(L_N \left[\frac{w + \sqrt{h^2 + w^2}}{h} \right] \right) + h \left(L_N \left[\frac{2h}{a} \right] \right) + w \left(L_N \left[\frac{2w}{a} \right] \right) \right]$$

$$C = \frac{1}{L} \left(\frac{1}{2\pi f_o} \right)^2$$

En donde cada parámetro es representado de la siguiente forma:

w = Ancho de la antena.

L = longitud diagonal en metros = 1 m.

p = perímetro de la antena.

A = área de la antena.

L_c = Longitud del cable.

T = número de vueltas del cable = 15.

L_h = Inductancia de la antena.

$N = T$ = Número de vueltas = 15.

$h = w$ = Ancho de la antena.

a = diámetro del cable = 0.008128m.

$\mu_0 = 12.5636 \times 10^{-7}$ Henrios/m permeabilidad magnética del vacío.

μ_r = permeabilidad relativa del aire = 1.

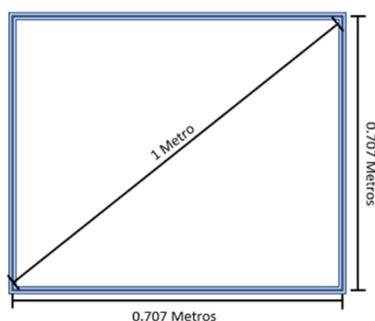
$f_0 = 30$ KHz.

C = capacitor de acoplamiento.

Con base en estos valores, se procedió al diseño de la antena utilizando las fórmulas previamente mencionadas. Cada uno de estos valores debe ajustarse según las necesidades del estudio; por ejemplo, el número de vueltas (15) fue una estimación que dependerá del tipo de cable que se desee utilizar, ya que a menor calibre se recomienda una mayor cantidad de vueltas. Asimismo, la longitud diagonal de la antena fue una estimación, la cual debe adaptarse al estudio. Por esta razón, se optó por utilizar una antena de tamaño mediano para este proyecto. Teniendo en cuenta estos aspectos, se obtuvo una inductancia de 1.22 nH y un capacitor de 23069.48 μ F como resultado final.

Figura 1:

Diseño e implementación de antena de cuadro basados en dos loops.

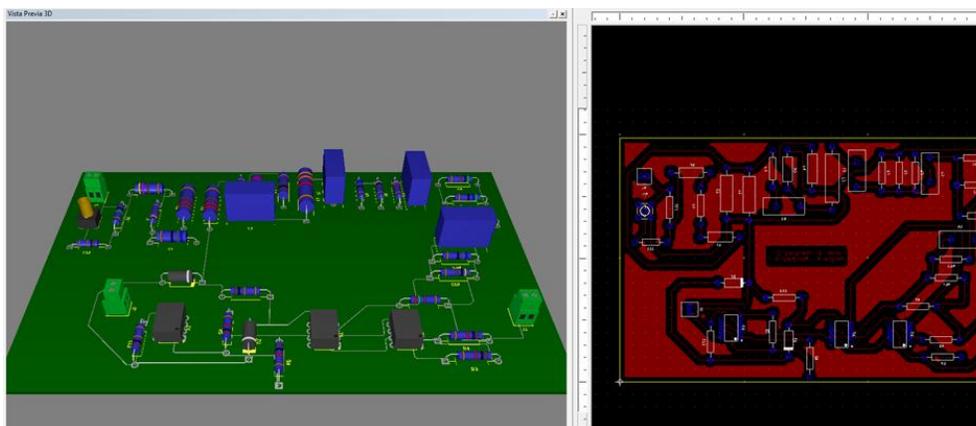


Se implementaron dos antenas colocadas a 90 grados entre sí para captar las señales de llamaradas solares provenientes de múltiples direcciones, como se muestra en la figura 1. Para asegurar la sensibilidad del sistema, se aplicó amplificación a las señales débiles de las antenas VLF. Se optó por amplificadores de bajo ruido (Putera et al., 2014), para minimizar la adición de ruido a las señales, lo cual es crucial para registrar con precisión incluso las señales más débiles, especialmente durante eventos solares. Además, se implementaron filtros de frecuencia para seleccionar específicamente el segmento de la banda de interés, ya que la banda VLF cubre un amplio rango de frecuencias. Estos filtros mejoran la selectividad del sistema y reducen la interferencia de frecuencias no deseadas al procesar únicamente las señales en la banda VLF.

En la figura 2 aparece el diseño de la placa PCB donde se instalarán los diversos componentes del receptor VLF.

Figura 2:

Diseño de la placa PCB del receptor VLF.



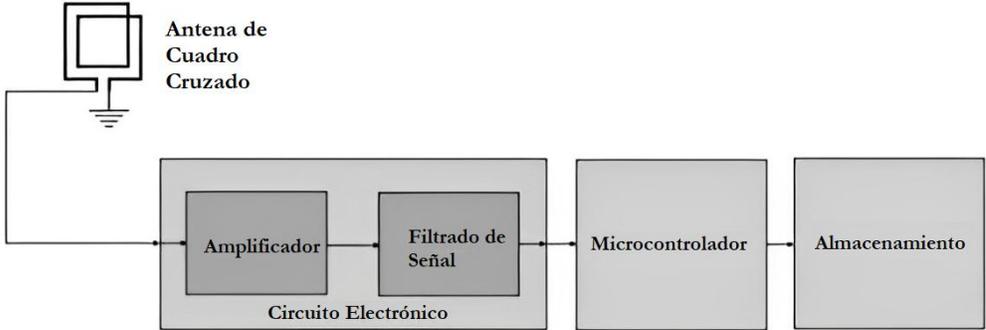
Antes de su implementación en el campo, el sistema de monitoreo se someterá a una exhaustiva verificación y calibración. Se llevarán a cabo pruebas de respuesta en frecuencia, análisis de ruido y calibración de amplificadores para asegurar la precisión y confiabilidad de los datos capturados. Además, se tomarán medidas de seguridad para proteger el sistema de interferencias externas y garantizar la confiabilidad de los datos recopilados. Estas medidas incluirán estrategias para reducir la interferencia electromagnética (Chaluvadi & Thomas, 2018), y humana en el área de despliegue, así como la implementación de sistemas de protección contra sobrecargas eléctricas.

Por otro lado, estos equipos de registro de datos recibirán la información amplificada y filtrada, como se observa en la figura 3. La variabilidad en la propagación de ondas VLF durante eventos solares se capturará utilizando mediante el desarrollo de una unidad capturadora de datos basadas en la utilización de una tarjeta Arduino Mega, el receptor VLF implementado con la antena Loop, y la unidad convertidora

analógica-digital integrada en la tarjeta Arduino, el software Arduino IDE, al igual se trabajó con una laptop para la el análisis de los datos. La correlación temporal necesaria para el análisis se garantizará mediante la sincronización precisa de estos equipos con los eventos solares registrados por observatorios espaciales.

Figura 3:

Diagrama bloque simplificador de la unidad capturadora de datos de las llamadas solares.

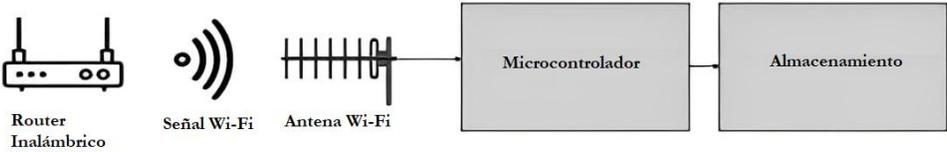


La correlación temporal entre los eventos solares y las variaciones en la propagación de ondas VLF será crucial para la interpretación correcta de los datos. Por lo tanto, se establecerá una conexión sincronizada con observatorios espaciales, como el Observatorio Solar y Heliosférico (SOHO) (NASA Solar and Heliospheric Observatory, 2020), para obtener datos precisos sobre la actividad solar durante el período de estudio.

Por otro lado, se registrarán señales de WiFi 2.4GHz utilizando un microcontrolador y una laptop, utilizando el esquema básico de conexión demostrado en la figura 4. La laptop será el encargado de registrar los datos. La distancia de separación entre la fuente y el receptor fue de aproximadamente de 10 metros.

Figura 4:

Diagrama de bloque simplificado del sistema de recolección de las señales provenientes de un sistema de WiFi.



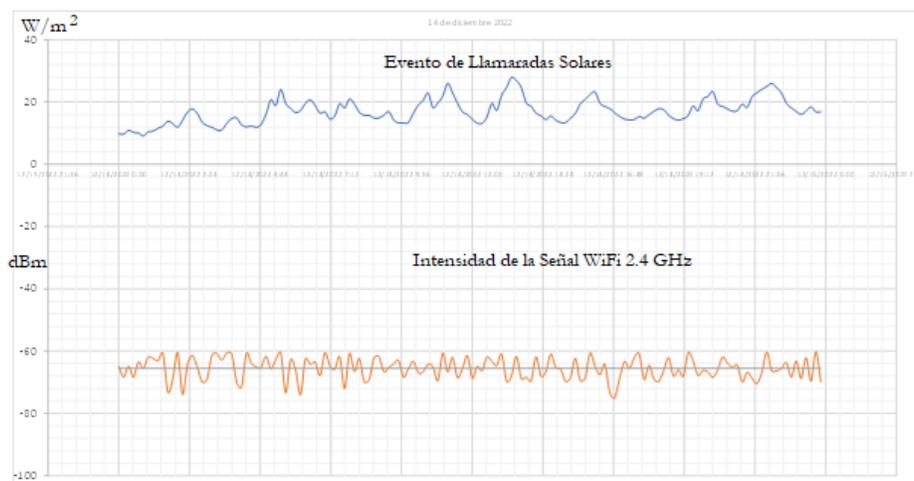
RESULTADOS

Durante el período de estudio que abarcó desde el 12 de diciembre de 2022 hasta el 21 de febrero de 2023, se recolectaron datos con un intervalo de captura de 10 minutos. Estos datos ofrecen una visión detallada del comportamiento de las llamaradas solares y de los niveles de ruido que pueden afectar un canal de comunicaciones de una red WiFi, lo que permite realizar un análisis exhaustivo de los patrones y tendencias observados durante este lapso de tiempo.

En la figura 5 se muestra el comportamiento de las llamaradas solares (línea de color azul), las señales de un enlace de WiFi de 2.4 GHz (línea de color naranja) y la intensidad promedio de la señal de WiFi (línea de color gris). Es importante destacar que, aunque estas líneas están representadas en una misma gráfica, la línea de color azul está expresada en potencia W/m^2 , mientras que las líneas de color naranja y gris están representadas en dBm.

Figura 5:

Gráfica de las señales captadas de las llamaradas solares, enlace de WiFi y señal promedio del enlace de WiFi, del día 14 de diciembre del año 2022.



Para realizar un análisis estadístico de los datos se tomaron en cuenta los 5 días con más actividad solar de cada uno de los meses estudiados (diciembre, enero, febrero). Dando como resultado los siguientes valores obtenidos.

A continuación se presenta en la figura 6, los eventos ocurridos de mayor actividad comparados con los niveles de las llamaradas solares y la información capturada por la unidad de recepción de VLF desarrollada para el estudio, este evento corresponde al de los días 16 de diciembre de 2022, 9 de enero de 2023, 9 de febrero de 2023 y 11 de febrero de 2023.

Figura 6a:

Eventos de Llamadas Solares proporcionado por el sitio SoHo (Izquierda) y los capturados por la unidad de recepción VLF desarrollada (derecha) del 16 de diciembre de 2022 y 9 de enero de 2023.

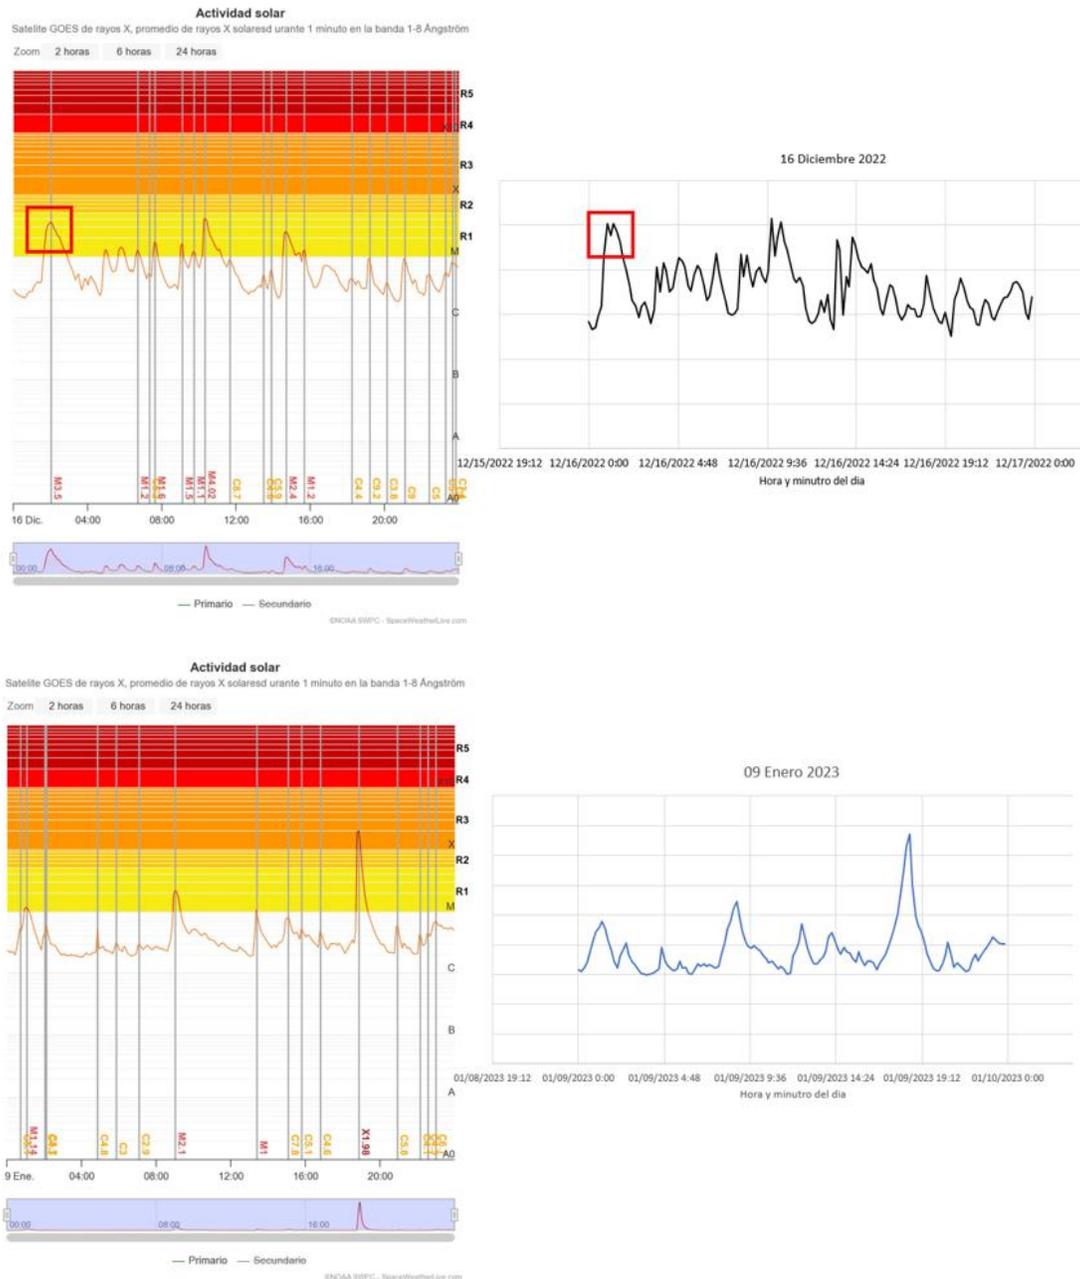


Figura 6b:

Eventos de Llamadas Solares proporcionado por el sitio SoHo (Izquierda) y los capturados por la unidad de recepción VLF desarrollada (derecha) del 9 y 11 de febrero de 2023 respectivamente.



Tabla 1:

Valores de la intensidad de la señal de WiFi el 14 de diciembre del año 2022.

HORA	VALOR (dBm)	HORA	VALOR (dBm)	HORA	VALOR (dBm)	HORA	VALOR (dBm)	HORA	VALOR (dBm)	HORA	VALOR (dBm)
12/14/2022 0:00	-64.93	12/14/2022 4:00	-69.9	12/14/2022 8:00	-66.61	12/14/2022 12:00	-68.73	12/14/2022 16:00	-60.65	12/14/2022 20:00	-66.68
12/14/2022 0:10	-68.37	12/14/2022 4:10	-71.65	12/14/2022 8:10	-62.4	12/14/2022 12:10	-64.92	12/14/2022 16:10	-64.86	12/14/2022 20:10	-68.41
12/14/2022 0:20	-64.87	12/14/2022 4:20	-60.74	12/14/2022 8:20	-69.88	12/14/2022 12:20	-66.26	12/14/2022 16:20	-67.59	12/14/2022 20:20	-65.95
12/14/2022 0:30	-68.37	12/14/2022 4:30	-63.93	12/14/2022 8:30	-69.17	12/14/2022 12:30	-61.88	12/14/2022 16:30	-64.19	12/14/2022 20:30	-61.88
12/14/2022 0:40	-63.54	12/14/2022 4:40	-65.05	12/14/2022 8:40	-62.21	12/14/2022 12:40	-63.28	12/14/2022 16:40	-73.26	12/14/2022 20:40	-63.86
12/14/2022 0:50	-65.51	12/14/2022 4:50	-65.23	12/14/2022 8:50	-61.78	12/14/2022 12:50	-64.62	12/14/2022 16:50	-75.14	12/14/2022 20:50	-65.21
12/14/2022 1:00	-61.92	12/14/2022 5:00	-61.64	12/14/2022 9:00	-66.63	12/14/2022 13:00	-60.92	12/14/2022 17:00	-68.87	12/14/2022 21:00	-64.57
12/14/2022 1:10	-62.38	12/14/2022 5:10	-65.63	12/14/2022 9:10	-65.23	12/14/2022 13:10	-69.8	12/14/2022 17:10	-63.38	12/14/2022 21:10	-69.95
12/14/2022 1:20	-63.14	12/14/2022 5:20	-62.72	12/14/2022 9:20	-64.13	12/14/2022 13:20	-68.03	12/14/2022 17:20	-65.61	12/14/2022 21:20	-66.8
12/14/2022 1:30	-60.75	12/14/2022 5:30	-60.56	12/14/2022 9:30	-62.95	12/14/2022 13:30	-61.69	12/14/2022 17:30	-62.12	12/14/2022 21:30	-68.66
12/14/2022 1:40	-73.16	12/14/2022 5:40	-73.44	12/14/2022 9:40	-68.36	12/14/2022 13:40	-68.87	12/14/2022 17:40	-60.73	12/14/2022 21:40	-70.48
12/14/2022 1:50	-68.93	12/14/2022 5:50	-62.78	12/14/2022 9:50	-65.75	12/14/2022 13:50	-68.38	12/14/2022 17:50	-69.15	12/14/2022 21:50	-66.79
12/14/2022 2:00	-60.47	12/14/2022 6:00	-65.82	12/14/2022 10:00	-63.26	12/14/2022 14:00	-69.61	12/14/2022 18:00	-64.58	12/14/2022 22:00	-60.27
12/14/2022 2:10	-73.98	12/14/2022 6:10	-74.08	12/14/2022 10:10	-66.89	12/14/2022 14:10	-61.81	12/14/2022 18:10	-68.94	12/14/2022 22:10	-66.34
12/14/2022 2:20	-64.17	12/14/2022 6:20	-62.54	12/14/2022 10:20	-66.72	12/14/2022 14:20	-68.09	12/14/2022 18:20	-69.7	12/14/2022 22:20	-66.39
12/14/2022 2:30	-61.44	12/14/2022 6:30	-64.3	12/14/2022 10:30	-64.21	12/14/2022 14:30	-66.58	12/14/2022 18:30	-66.21	12/14/2022 22:30	-65.55
12/14/2022 2:40	-65.21	12/14/2022 6:40	-63.53	12/14/2022 10:40	-65.06	12/14/2022 14:40	-60.93	12/14/2022 18:40	-62.12	12/14/2022 22:40	-63.68
12/14/2022 2:50	-69.98	12/14/2022 6:50	-67.84	12/14/2022 10:50	-69.5	12/14/2022 14:50	-65.33	12/14/2022 18:50	-68.02	12/14/2022 22:50	-68.39
12/14/2022 3:00	-68.95	12/14/2022 7:00	-60.53	12/14/2022 11:00	-60.56	12/14/2022 15:00	-65.8	12/14/2022 19:00	-65.96	12/14/2022 23:00	-63.18
12/14/2022 3:10	-61.21	12/14/2022 7:10	-64.72	12/14/2022 11:10	-66.72	12/14/2022 15:10	-69.72	12/14/2022 19:10	-68.05	12/14/2022 23:10	-68.85
12/14/2022 3:20	-60.8	12/14/2022 7:20	-65.84	12/14/2022 11:20	-62.01	12/14/2022 15:20	-68.62	12/14/2022 19:20	-60.49	12/14/2022 23:20	-62.11
12/14/2022 3:30	-62.87	12/14/2022 7:30	-61.82	12/14/2022 11:30	-68.52	12/14/2022 15:30	-62.36	12/14/2022 19:30	-63.13	12/14/2022 23:30	-69.65
12/14/2022 3:40	-60.57	12/14/2022 7:40	-72.12	12/14/2022 11:40	-65.7	12/14/2022 15:40	-69.48	12/14/2022 19:40	-67.84	12/14/2022 23:40	-60.19
12/14/2022 3:50	-60.83	12/14/2022 7:50	-60.75	12/14/2022 11:50	-61.44	12/14/2022 15:50	-68.67	12/14/2022 19:50	-66.18	12/14/2022 23:50	-69.92

Para utilizar como referencia el primer análisis se realizó con la información obtenida el día 14 de diciembre del año 2022 (Figura 5). Como primer paso se calculó la intensidad promedio de la señal de Wifi en dicho día con los valores de la tabla 2, obteniendo un valor de -65.584 dBm.

A partir de este punto solo se consideraron los valores que sean menores que la intensidad promedio para obtener un porcentaje promedio de variación, el cual fue de 4.53%, en otras palabras, de los 144 valores, el propósito de esta exclusión de datos es obtener una medición más precisa y representativa de la variabilidad de la señal de WiFi al eliminar valores que podrían ser considerados ruido o atípicos.

Tabla 2:

Valores filtrados menores a el valor promedio -65.584 dBm de la intensidad de la señal de WiFi

HORA	VALOR (dBm)	HORA	VALOR (dBm)	HORA	VALOR (dBm)	HORA	VALOR (dBm)	HORA	VALOR (dBm)	HORA	VALOR (dBm)
12/14/2022 0:10	-68.37	12/14/2022 6:50	-67.84	12/14/2022 11:30	-68.52	12/14/2022 15:20	-68.62	12/14/2022 19:00	-65.96	12/14/2022 22:20	-66.39
12/14/2022 0:30	-68.37	12/14/2022 7:20	-65.84	12/14/2022 11:40	-65.7	12/14/2022 15:40	-69.48	12/14/2022 19:10	-68.05	12/14/2022 22:50	-68.39
12/14/2022 1:40	-73.16	12/14/2022 7:40	-72.12	12/14/2022 12:00	-68.73	12/14/2022 15:50	-68.67	12/14/2022 19:40	-67.84	12/14/2022 23:10	-68.85
12/14/2022 1:50	-68.93	12/14/2022 8:00	-66.61	12/14/2022 12:20	-66.26	12/14/2022 16:20	-67.59	12/14/2022 19:50	-66.18	12/14/2022 23:30	-69.65
12/14/2022 2:10	-73.98	12/14/2022 8:20	-69.88	12/14/2022 13:10	-69.8	12/14/2022 16:40	-73.26	12/14/2022 20:00	-66.68	12/14/2022 23:50	-69.92
12/14/2022 2:50	-69.98	12/14/2022 8:30	-69.17	12/14/2022 13:20	-68.03	12/14/2022 16:50	-75.14	12/14/2022 20:10	-68.41		
12/14/2022 3:00	-68.95	12/14/2022 9:00	-66.63	12/14/2022 13:40	-68.87	12/14/2022 17:00	-68.87	12/14/2022 20:20	-65.95		
12/14/2022 4:00	-69.9	12/14/2022 9:40	-68.36	12/14/2022 13:50	-68.38	12/14/2022 17:20	-65.61	12/14/2022 21:10	-69.95		
12/14/2022 4:10	-71.65	12/14/2022 9:50	-65.75	12/14/2022 14:00	-69.61	12/14/2022 17:50	-69.15	12/14/2022 21:20	-66.8		
12/14/2022 5:10	-65.63	12/14/2022 10:10	-66.89	12/14/2022 14:20	-68.09	12/14/2022 18:10	-68.94	12/14/2022 21:30	-68.66		
12/14/2022 5:40	-73.44	12/14/2022 10:20	-66.72	12/14/2022 14:30	-66.58	12/14/2022 18:20	-69.7	12/14/2022 21:40	-70.48		
12/14/2022 6:00	-65.82	12/14/2022 10:50	-69.5	12/14/2022 15:00	-65.8	12/14/2022 18:30	-66.21	12/14/2022 21:50	-66.79		
12/14/2022 6:10	-74.08	12/14/2022 11:10	-66.72	12/14/2022 15:10	-69.72	12/14/2022 18:50	-68.02	12/14/2022 22:10	-66.34		

No obstante, para poder obtener el valor real de afectación de la señal con referencia a las llamadas solares, solo se tomarán en cuenta aquellos valores ubicados en la clase M o superior, o, en otras palabras, aquellos valores que sean superiores a los $10 \times 10^{-5} \text{ W/m}^2$, ya que a partir de esta intensidad es donde se conoce que se comienzan a afectar las señales de telecomunicación.

Considerando estos filtros, se obtienen nuevos valores que serán comparados con el valor promedio de la señal (observar tabla 3).

Tabla 3:

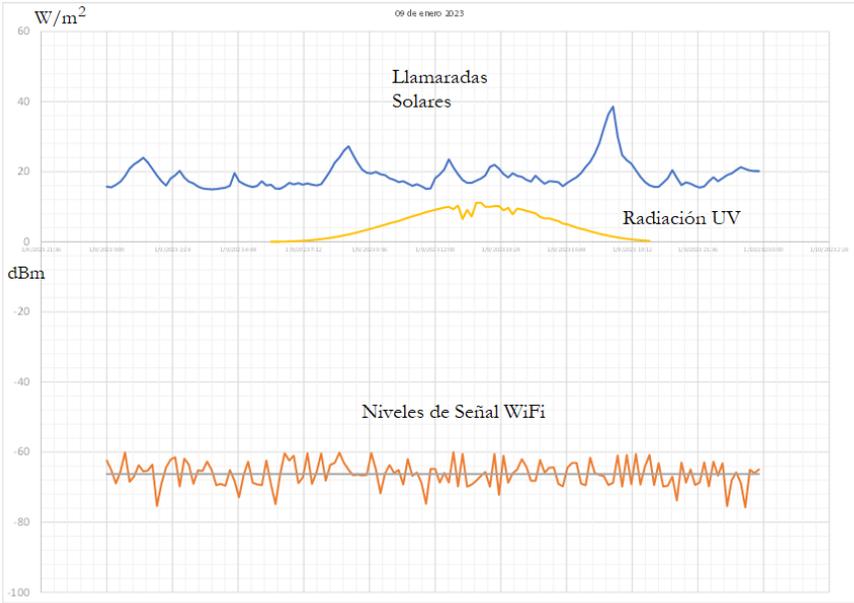
Valores finales representados en base al nivel de ruido y la irradiancia solar del 14 de enero 2022.

HORA	VALOR (dBm)	Llamarada Solar (W/m2)	HORA	VALOR (dBm)	Llamarada Solar (W/m2)	HORA	VALOR (dBm)	Llamarada Solar (W/m2)
12/14/2022 0:30	-68.37	10.22	12/14/2022 11:40	-65.7	16.88	12/14/2022 19:10	-68.05	14.67
12/14/2022 1:40	-73.16	13.83	12/14/2022 12:00	-68.73	14.48	12/14/2022 19:40	-67.84	17.2
12/14/2022 1:50	-68.93	13.04	12/14/2022 12:20	-66.26	13.14	12/14/2022 19:50	-66.18	20.92
12/14/2022 2:10	-73.98	14.15	12/14/2022 13:10	-69.8	24.68	12/14/2022 20:00	-66.68	21.82
12/14/2022 2:50	-69.98	13.52	12/14/2022 13:20	-68.03	27.93	12/14/2022 20:10	-68.41	23.38
12/14/2022 3:00	-68.95	12.42	12/14/2022 13:40	-68.87	24.63	12/14/2022 20:20	-65.95	19.38
12/14/2022 4:00	-69.9	14.89	12/14/2022 13:50	-68.38	19.71	12/14/2022 21:10	-69.95	19.33
12/14/2022 4:10	-71.65	12.71	12/14/2022 14:00	-69.61	18.65	12/14/2022 21:20	-66.8	18.25
12/14/2022 5:10	-65.63	20.74	12/14/2022 14:20	-68.09	15.56	12/14/2022 21:30	-68.66	21.71
12/14/2022 5:40	-73.44	19.6	12/14/2022 14:30	-66.58	14.38	12/14/2022 21:40	-70.48	22.96
12/14/2022 6:00	-65.82	16.66	12/14/2022 15:00	-65.8	13.42	12/14/2022 21:50	-66.79	24.09
12/14/2022 6:10	-74.08	17.27	12/14/2022 15:10	-69.72	13.4	12/14/2022 22:10	-66.34	25.95
12/14/2022 6:50	-67.84	16.38	12/14/2022 15:20	-68.62	14.81	12/14/2022 22:20	-66.39	24.64
12/14/2022 7:20	-65.84	15.55	12/14/2022 15:40	-69.48	19.39	12/14/2022 22:50	-68.39	18.14
12/14/2022 7:40	-72.12	18.06	12/14/2022 15:50	-68.67	20.8	12/14/2022 23:10	-68.85	16.02
12/14/2022 8:00	-66.61	19.3	12/14/2022 16:20	-67.59	19.65	12/14/2022 23:30	-69.65	18.42
12/14/2022 8:20	-69.88	15.75	12/14/2022 16:40	-73.26	17.89	12/14/2022 23:50	-69.92	16.92
12/14/2022 8:30	-69.17	15.74	12/14/2022 16:50	-75.14	16.6			
12/14/2022 9:00	-66.63	15.77	12/14/2022 17:00	-68.87	15.34			
12/14/2022 9:40	-68.36	13.3	12/14/2022 17:20	-65.61	14.28			
12/14/2022 9:50	-65.75	13.4	12/14/2022 17:50	-69.15	14.82			
12/14/2022 10:10	-66.89	19	12/14/2022 18:10	-68.94	17.08			
12/14/2022 10:20	-66.72	20.5	12/14/2022 18:20	-69.7	17.87			
12/14/2022 10:50	-69.5	19.72	12/14/2022 18:30	-66.21	17.53			
12/14/2022 11:10	-66.72	25.99	12/14/2022 18:50	-68.02	14.67			
12/14/2022 11:30	-68.52	19.59	12/14/2022 19:00	-65.96	14.17			

Para el mes de enero del 2023 se realiza otra captura de datos de las llamadas solares, el comportamiento del ruido dentro de un canal de comunicaciones WiFi y adicionalmente los niveles de radiación ultravioleta (UV), el resultado se observa en la figura 7.

Figura 7:

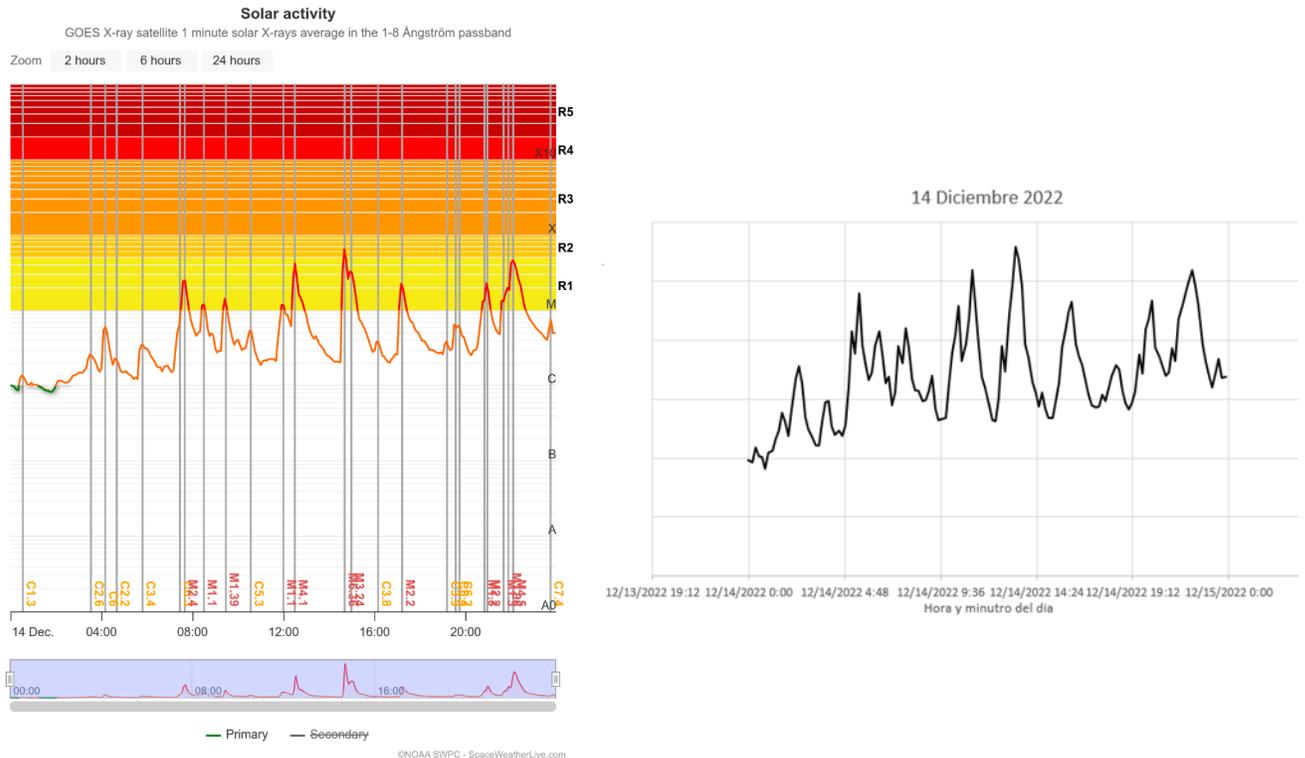
Gráfica de las señales captadas de las llamadas solares, enlace de WiFi y señal promedio del enlace de WiFi, del día 09 de enero del año 2023. La línea de color amarillo representa los rayos UV captados por Arpansa



Se efectúa una comparación de la efectividad del sistema de medición implementado en donde se compara la señal de los días con mayor porcentaje de variación, ya que serían los días en los que hubo una actividad solar más alta del Observatorio Solar y Heliosférico, SOHO para los siguientes días: 14 de diciembre del 2022 (Figura 8, 16 de diciembre del 2022, 09 de enero del 2023, 09 de febrero del 2023 y 11 de febrero del 2023).

Figura 8:

Comparativa entre la gráfica captada por SOHO (Gráfica ubicada en la zona izquierda) y el sistema construido (Gráfica ubicada en la zona derecha).



CONCLUSIÓN

La investigación sobre la influencia de las llamaradas solares en la propagación de ondas electromagnéticas en la banda de Frecuencias Muy Bajas (VLF) ha proporcionado información crucial para comprender mejor los efectos del clima espacial en las comunicaciones electrónicas. A través de la implementación de un sistema de monitoreo especializado, que incluye antenas loop y receptores VLF, se capturaron datos en tiempo real que permitieron analizar la relación entre los eventos solares y la variabilidad en la propagación de ondas VLF.

Los resultados obtenidos demuestran que las llamaradas solares tienen un impacto significativo en la propagación de ondas VLF. Este impacto se manifiesta a través de variaciones en la intensidad y estabilidad de las señales capturadas, especialmente durante eventos solares de alta intensidad. La comprensión de estos efectos es vital para aplicaciones críticas como las comunicaciones submarinas y los sistemas de navegación, que dependen en gran medida de la integridad y confiabilidad de las señales VLF. Además, el estudio destaca la importancia de utilizar sistemas de recepción y filtros adecuados para capturar con precisión las señales de interés durante eventos solares. La implementación de antenas de bucle

magnético y amplificadores de bajo ruido se mostró efectiva para minimizar las interferencias y garantizar la calidad de los datos recolectados.

En conclusión, esta investigación avanza el conocimiento sobre los impactos de los fenómenos solares en las comunicaciones electrónicas en la banda VLF, proporcionando una base teórica y práctica para mitigar los posibles efectos adversos. Los hallazgos obtenidos no solo enriquecen la física solar y de la ionosfera, sino que también tienen aplicaciones directas en el diseño y operación de sistemas de comunicación crítica. Este trabajo subraya la necesidad continua de monitoreo y análisis del clima espacial para garantizar la seguridad y eficacia de las comunicaciones electrónicas en un entorno cada vez más dependiente de la tecnología.

REFERENCIAS BIBLIOGRÁFICAS

- Adlard, J. E., Tozer, T. C., & Burr, A. G. (1999). Interference rejection in impulsive noise for VLF communications. En MILCOM 1999. IEEE Military Communications. Conference Proceedings (pp. 296-300, vol. 1). Atlantic City, NJ, USA. <https://doi.org/10.1109/MILCOM.1999.822691>
- Beneitez, B. (3 de febrero de 2022). ¿Sabes qué efectos producen sobre la Tierra las llamaradas solares como la del 20 de enero? Obtenido de La Vanguardia: <https://www.lavanguardia.com/natural/20220203/8020643/espacio-llamaradas-solares-nasa-nbs.html>
- Carracedo, G., & Montes, D. (20 de julio de 2022). Llamadas solares: ¿qué impacto tienen estos fenómenos en nuestro planeta? Obtenido de BBC: <https://www.bbc.com/mundo/noticias-62245749>
- Chaluvadi, M., & Thomas, K. G. (2018). An Equivalent Transmission Line Model for Predicting the Electromagnetic Interference Suppression Characteristics of Ferrite cores. En 2018 15th International Conference on ElectroMagnetic Interference & Compatibility (INCEMIC) (pp. 1-4). Bengaluru, India. <https://doi.org/10.1109/INCEMIC.2018.8704609>
- Comunicaciones DFI - U. de Chile. (13 de enero de 2022). Académico del DFI lidera investigación que descubrió pistas claves sobre llamaradas solares. Obtenido de Diario U Chile: <https://radio.uchile.cl/2022/01/13/academico->

[del-dfi-lidera-investigacion-que-descubrio-pistas-claves-sobre-llamaradas-solares/](#)

Du, Y., et al. (2023). Very-Low-Frequency Magnetolectric Antennas for Portable Underwater Communication: Theory and Experiment. *IEEE Transactions on Antennas and Propagation*, 71(3), 2167-2181.
<https://doi.org/10.1109/TAP.2022.3233665>

Group, S. V. (2013). Stanford VLF Group. Obtenido de Stanford VLF Group:
https://vlfstanford.ku.edu.tr/research_topic_inlin/introduction-vlf/

Gu, X., Yi, J., Wang, S., Hu, Z., Xu, W., Ni, B., Li, B., & He, F. (2023). Comparison of VLF Signal Responses to Solar Flares along Daytime and Nighttime Propagation Paths. *Remote Sensing*, 15(4), 1018. Publicado 12 de febrero de 2023. <https://doi.org/10.3390/rs15041018>

Guevara, D., & Sanchez, D. (2017). Implementación de un sistema de monitoreo y protección de datos en la red de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial. Ambato.

Isak, C. (2022, January 24). ¿Qué es una llamarada solar y cómo podría afectarnos en la Tierra? TechAcute. https://techacute.com/what-is-a-solar-flare/#google_vignette.

Jaramillo Alvarado, A. F., Galvis Rodríguez, H. D., & Quintero, E. A. (2017). Monitoreo del Clima Espacial desde Colombia Mediante Radio Receptores Butterworth de Orden Superior. *Ingeniería*, 22(1).
<https://doi.org/10.14483/udistrital.jour.reving.2017.1.a08>.

Journal of Geophysical research: Space Physics. (2004). Global dayside ionospheric uplift and enhancement associated with interplanetary electric fields. *Journal of Geophysical research: Space Physics*.

Kilpua, E. K. J., Koskinen, H. E. J., & Pulkkinen, T. I. (2017). Coronal mass ejections and their sheath regions in interplanetary space. *Living Reviews in Solar Physics*, 14(1), 5.

NASA Solar and Heliospheric Observatory. (2020). SOHO: NASA Solar and Heliospheric Observatory. Recuperado de <https://soho.nascom.nasa.gov/>

National Geographic. (22 de noviembre de 2022). Llamadas solares, el peligro que podría golpear la Tierra. Obtenido de National Geographic: https://www.nationalgeographic.com.es/ciencia/que-son-llamadas-fulguraciones-solares_19110

Oldrich Burger, M. D. (2015). *Magnetic Loop Antenna Slightly Different Each Time*. Ostrava: EDUCA TV o.p.s.

Putera, R., Kusnandar, Najmurokhman, A., Sunubroto, Chairunnisa, & Munir, A. (2014). High gain RF amplifier for very low frequency receiver application. En *2014 6th International Conference on Information Technology and Electrical Engineering (ICITEE)* (pp. 1-4). Yogyakarta, Indonesia. <https://doi.org/10.1109/ICITEED.2014.7007925>

Ruiz Vanoye, J. A., Ambrocio Cruz, P., & Díaz Parra, O. (2017). ¿Cómo nos afecta el clima solar? *Revista Ciencia*, 68(4), Recuperado de https://www.revistaciencia.amc.edu.mx/images/revista/68_4/PDF/68_4_como_afecta_climasolar.pdf

Schrijver, C. J., & Siscoe, G. L. (2010). *Heliospheric Physics*. Cambridge University Press.

Tandberg-Hanssen, E. (2009). *The Physics of Solar Flares* (1st ed.). Cambridge Astrophysics, Series Number 14.

UIT-R. (2016). Recomendación UIT-R P. 684-7: Predicción de la Intensidad de Campo por Debajo de los 150 kHz. Serie P Propagación de las Ondas Radioeléctricas. Geneva, Switzerland: UIT-R.

Webb, D., & Howard, T. (2012). *Living Reviews in Solar Physics*.

Algoritmos de aprendizaje automático en la predicción del rendimiento académico universitario: una revisión sistemática

Machine learning algorithms in the prediction of university academic performance: a systematic review

Fabiola Montero

Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación
fabiola.monterog@up.ac.pa <https://orcid.org/0000-0002-4681-9471>

Nelson Montilla

Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación
nelson.montilla@up.ac.pa <https://orcid.org/0000-0002-4220-4912>

Julio Arcia

Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación
julio.arcia@up.ac.pa <https://orcid.org/0009-0006-8052-792X>

Recibido: 31-1-2024, Aceptado: 8-5-2024

DOI <https://doi.org/10.48204/3072-9696.6361>

RESUMEN

En los últimos años, el crecimiento del Aprendizaje Automático o Machine Learning ha tenido un impacto significativo en diversos campos, incluyendo la educación. En el ámbito educativo, se han aplicado técnicas o algoritmos de Aprendizaje Automático para diversos propósitos, como predecir el rendimiento académico de estudiantes de educación superior. Este artículo se enfoca en la revisión de publicaciones que muestran los resultados obtenidos al emplear algoritmos de Aprendizaje Automático para predecir el rendimiento académico de estudiantes universitarios. Se realizó una revisión sistemática en bases de datos académicas como Redalyc, Google Académico y Scielo, empleando filtros de búsqueda y palabras clave pertinentes. Posteriormente, se seleccionaron aquellos artículos más relevantes para el análisis. El propósito de este artículo de revisión es identificar los algoritmos de Aprendizaje Automático más frecuentemente utilizados y efectivos en la predicción del rendimiento académico de estudiantes universitarios, así como examinar cómo han sido implementados en distintas universidades para que sea una guía en futuras investigaciones que incluyan la aplicación de estos algoritmos con datos de estudiantes de la Universidad de Panamá. Los resultados muestran que los algoritmos más empleados para este tipo de predicción son Árboles de Decisión, K-Vecinos más Cercanos (KNN), Naive Bayes, Random Forest (Bosques Aleatorios) y Máquinas de Soporte Vectorial (SVM), así como las Redes Neuronales Artificial, las cuales también destacan por su alta precisión. El empleo de estos algoritmos

para predecir el rendimiento académico en universidades ofrece un gran potencial para reducir la deserción, mejorar los resultados académicos, respaldar las decisiones pedagógicas y optimizar recursos educativos.

ABSTRACT

In recent years, the growth of Machine Learning has had a significant impact across various fields, including education. In the educational sphere, Machine Learning techniques or algorithms have been applied for various purposes, such as predicting the academic performance of higher education students. This article focuses on reviewing publications that present the results obtained by employing Machine Learning algorithms to predict the academic performance of university students. A systematic review was conducted using academic databases such as Redalyc, Google Scholar, and Scielo, utilizing search filters and relevant keywords. Subsequently, the most relevant articles were selected for analysis. The purpose of this review article is to identify the most frequently used and effective Machine Learning algorithms for predicting the academic performance of university students, as well as to examine how they have been implemented in different universities, serving as a guide for future research involving the application of these algorithms with student data from the University of Panama. The results show that the most commonly used algorithms for this type of prediction are Decision Trees, K-Nearest Neighbors (KNN), Naive Bayes, Random Forest, and Support Vector Machines (SVM), as well as Artificial Neural Networks, which also stand out for their high accuracy. The use of these algorithms to predict academic performance in universities offers great potential to reduce dropout rates, improve academic outcomes, support pedagogical decisions, and optimize educational resources.

PALABRAS CLAVES

Algoritmo, aprendizaje automático, aprendizaje supervisado, rendimiento académico.

KEYWORDS

Algorithm, machine learning, supervised learning, academic performance.

INTRODUCCIÓN

El Aprendizaje Automático, también conocido como Machine Learning en inglés, es un campo muy desarrollado dentro de la Inteligencia Artificial. Según Norman (2019), el Aprendizaje Automático consiste en proporcionar a una computadora un conjunto de datos para que construya un modelo capaz de predecir comportamientos futuros. Géron (2020), citado por Díaz (2021), define el Aprendizaje Automático como la “ciencia (y arte) de programar computadores para que aprendan a partir de datos” (p.182).

Para Soria et al. (2023), el Aprendizaje Automático es la disciplina que permite a las computadoras aprender sin necesidad de ser programadas con reglas específicas. Esta disciplina aplica estadística y otros métodos matemáticos para detectar patrones en los datos y, a partir de ellos, hacer predicciones e incluso tomar decisiones, mejorando con cada intento.

Según Moreno et al. (1994) desde sus inicios, se han identificado diferentes paradigmas en el Aprendizaje Automático, como el aprendizaje deductivo, analítico, analógico, inductivo, mediante descubrimiento, algoritmos genéticos y conexionismo, entre otros. Sin embargo, de acuerdo con Díaz (2021) la disponibilidad masiva de datos y el crecimiento exponencial de Internet han impulsado el rápido desarrollo del Aprendizaje Automático, dividiéndose en categorías como aprendizaje supervisado y no supervisado, entre otras. Estos enfoques desarrollan modelos mediante algoritmos que permiten entrenarlos con una gran cantidad de datos y capacitarlo para resolver tareas específicas, como la realización de predicciones.

Aprendizaje Supervisado y No Supervisado

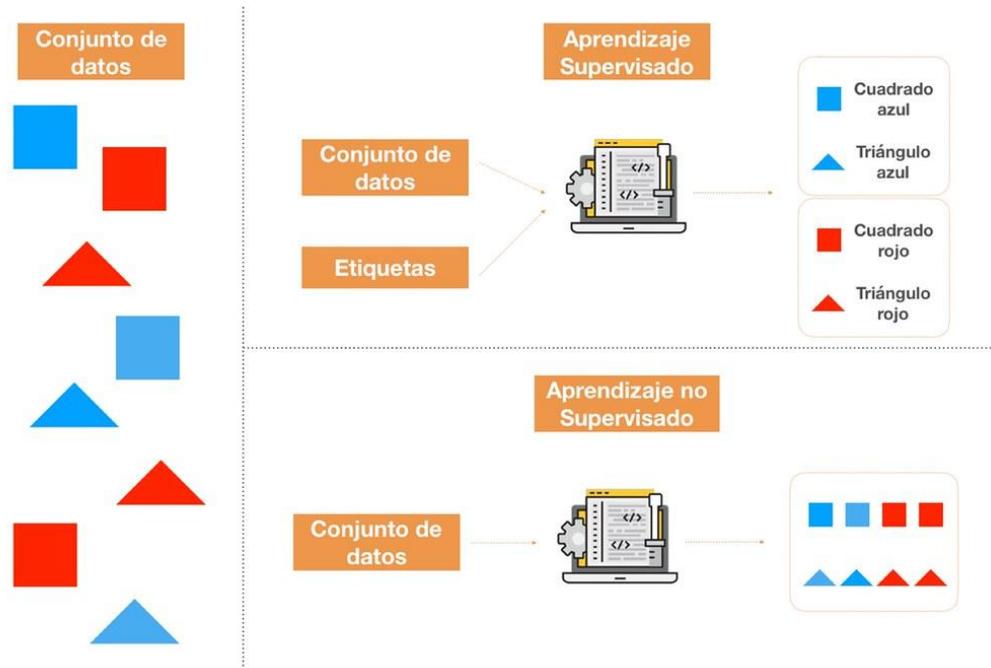
Los algoritmos de aprendizaje supervisado se caracterizan por el uso de un conjunto de datos etiquetados para entrenar un modelo que clasifique datos o que prevea resultados con precisión. En la medida en que se ingresan datos al modelo, este va realizando ajustes hasta que se adapte de manera correcta, permitiendo que aprenda con el tiempo (IBM, 2023).

El aprendizaje supervisado utiliza datos etiquetados, donde tanto las entradas como las salidas son conocidas (González, 2018). Según Sandoval (2018), se entrena un algoritmo de aprendizaje supervisado proporcionándole características y etiquetas para que pueda realizar predicciones en el futuro. En este proceso, el modelo aprende de estos ejemplos para hacer predicciones sobre nuevos conjuntos de datos, aplicando el conocimiento adquirido a datos no vistos anteriormente.

Los algoritmos de aprendizaje no supervisado, por otro lado, analizan y agrupan conjunto de datos no etiquetados utilizando variables de entrada. Estos algoritmos descubren patrones ocultos o agrupaciones de datos sin intervención humana (IBM, 2023), identificando patrones que describan el comportamiento general de los datos. De acuerdo con Sandoval (2018), en el aprendizaje no supervisado se proporcionan solo las características, no las etiquetas, para que el algoritmo agrupe los datos según sus similitudes.

La Figura 1, ilustra la diferencia fundamental entre el aprendizaje supervisado y el no supervisado en términos de etiquetado y resultados.

Figura 1
Comparación de los tipos de aprendizaje: supervisado y no supervisado



Nota. Adaptado de Diferencia entre aprendizaje supervisado y no supervisado, por L. Gonzalez, 2018, AprendeIA (<https://aprendeia.com/diferencia-entre-aprendizaje-supervisado-y-no-supervisado/>)

En la Tabla 1, se aprecia una comparación entre los algoritmos de aprendizaje supervisado y no supervisado, destacando sus características fundamentales, de acuerdo con Serrato (2021) y González (2018, 2020). La tabla resume los aspectos clave que diferencian a estos dos tipos de aprendizaje automático, facilitando la comprensión de sus principios y su uso en diferentes escenarios.

Tabla 1
Diferencias entre aprendizaje supervisado y no supervisado

Característica	Aprendizaje Supervisado	Aprendizaje No Supervisado
Etiquetado de datos	Requiere etiquetado de datos con la salida deseada	No requiere datos etiquetados
Objetivo	Predecir resultados para nuevos datos	Descubrir patrones y estructuras en datos sin etiquetar
Datos de entrenamiento	Etiquetados con el resultado esperado	No etiquetado ni con información sobre resultados esperados
Complejidad computacional	Sencilla	Compleja
Relación entrada-salida	Aprende la relación entre la entrada y la salida	No utiliza datos de salida
Aplicaciones	Regresión, clasificación	Agrupación de datos detección de anomalías, reducción de dimensionalidad

Según, Pineda (2022), los algoritmos supervisados se pueden agrupar en las siguientes categorías:

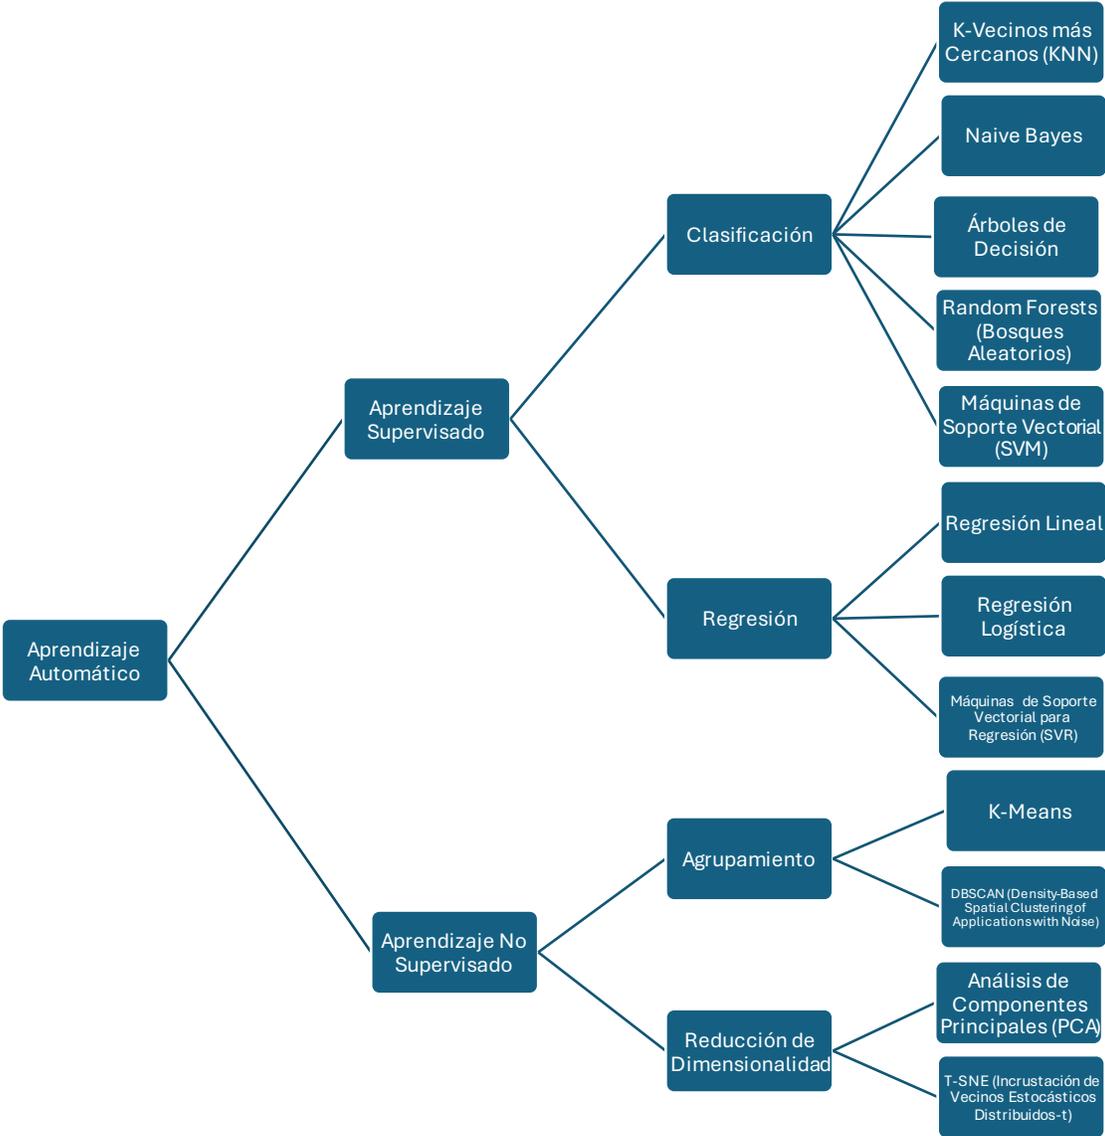
- Clasificación: se utilizan para asignar etiquetas categóricas a nuevas observaciones.
- Regresión: Se utilizan para predecir valores numéricos a partir de datos.

Por otra parte, de acuerdo con Soria et al. (2023), los algoritmos no supervisados se pueden clasificar en las siguientes categorías principales:

- Agrupamiento: se utilizan para agrupar observaciones similares en grupos.
- Reducción de dimensionalidad: se utilizan para reducir el número de variables en un conjunto de datos sin perder información importante.

En la Figura 2, se presenta una clasificación de algoritmos de aprendizaje automático, tanto supervisado como no supervisado, acompañada de ejemplos representativos de los algoritmos más comúnmente utilizados en cada categoría.

Figura 2
Clasificación de Algoritmos de Aprendizaje Automático



Los algoritmos, tanto supervisados como no supervisados, están en constante evolución. Con el tiempo, sus capacidades, aplicaciones y diversidad se han expandido, consolidándolos como una de las áreas de desarrollo más importantes en la actualidad.

Aprendizaje Profundo o Deep Learning

Además de los algoritmos de aprendizaje supervisado y no supervisado se encuentra el Aprendizaje Profundo o Deep Learning, que es un subcampo del Aprendizaje Automático que a su vez lo es de la Inteligencia Artificial y que es más poderoso que los algoritmos de aprendizaje supervisado y no supervisado, puesto que está basado en técnicas distintas que imitan el comportamiento de la naturaleza mediante programación evolutiva. De acuerdo con, Lagares et al. (2022), el Aprendizaje Profundo es utilizado para resolver problemas que requieren modelos con mayor complejidad y que con las técnicas comunes de los aprendizajes supervisados y no supervisados no son suficientes.

Los algoritmos de Aprendizaje Profundo se distinguen por extraer conocimiento de los datos, ya que en el medio de estos algoritmos existe una estructura denominada Redes Neuronales o Redes Neuronales Artificiales que simulan la estructura biológica que encontramos en una neurona en el cerebro humano y de la misma manera como funcionan biológicamente, las neuronas del Aprendizaje Profundo procesan información y cuentan con grandes capacidades de aprendizaje. Existe una gran cantidad de tipos de algoritmos de Aprendizaje Profundo que han sido clasificados como redes con aprendizaje supervisado, no supervisado o aprendizaje por refuerzo. Para Yepes (2022), una de las Redes Neuronales más utilizadas son las Redes Neuronales Convolucionales (Convolutional Neural Network, CNN), que es una variación del Perceptrón Multicapa, pero que su aplicación se realiza en matrices bidimensionales, por lo que son muy efectivas en aplicaciones de visión artificial, clasificación y segmentación de imágenes.

Adicionalmente a las Redes Neuronales Convolucionales, están las Redes Neuronales Profundas (Deep Neuronal Network, DNN), Redes Neuronales Recurrentes (Recurrent Neuronal Network, RNN) y un subtipo de estas llamado las Redes Neuronales de gran memoria a corto plazo (Long Short Term Memory, LSTM) (Lagares et al., 2022).

De acuerdo con la tarea que deba llevarse a cabo, se puede optar por trabajar con algoritmos supervisados, no supervisados o de aprendizaje profundo e incluso combinando algoritmos de diferentes tipos si es necesario, para lograr satisfacer de manera más adecuada la necesidad y alcanzar un nivel más efectivo en los resultados.

Rendimiento Académico

En el ámbito de la educación superior, un elemento crítico es el rendimiento académico tal como resalta Enughwure y Ogbise (2020), ya que constituye el indicador primordial de éxito o fracaso del estudiante que puede ser analizado desde diferentes dimensiones de acuerdo con el contexto o la situación de interés (Zhang et al., 2021). Por lo general, el rendimiento se evalúa mediante calificaciones que se asignan en una escala que puede clasificarse como Excelente, Bueno, Regular o Deficiente, entre otras categorías posibles de acuerdo con el nivel de enseñanza o el sistema educativo. Albreiki et al. (2021) considera que la predicción del rendimiento académico de los estudiantes proporciona excelentes beneficios para aumentar las tasas de retención, una gestión eficaz de la matrícula, la gestión de exalumnos, un mercadeo dirigido mejorado y la eficacia general de la institución.

El rendimiento de los estudiantes en el proceso educativo de acuerdo con Sandra et al. (2021), se puede definir idealmente como algo que se obtiene a partir de cambios en el comportamiento de los estudiantes en función de sus experiencias, ya que los resultados de aprendizaje también son una realización del potencial o capacidad que poseen los estudiantes. Sandra et al. (2021) sostiene que los resultados de aprendizaje de los estudiantes se pueden observar en su comportamiento y en la forma de comprensión de conocimientos, habilidades de pensamiento o habilidades motoras.

García (2020) define el rendimiento académico “como una consecuencia de la relación entre la capacidad del estudiante y su desempeño” (p. 3). Para Oliver (2007), citado por García (2020), suele existir una tendencia a asumir que el rendimiento académico de un estudiante está relacionado principalmente con sus responsabilidades y hábitos de estudio, sin profundizar en una evaluación más completa que tenga en cuenta otros factores importantes que afectan el resultado como lo indican Buenaño et al. (2019) y Ojajuni et al. (2021). Estos factores no son fáciles de identificar o analizar a simple vista y, a menudo, están ocultos en los datos de los estudiantes que las instituciones suelen recopilar y almacenar. Lamentablemente, por cuestiones como el desconocimiento, la complejidad o el volumen, estos datos no siempre se utilizan correctamente. No obstante, el uso de técnicas de Aprendizaje Automático como lo indica Issah et al. (2023) ofrece la posibilidad de descubrir información valiosa disponible en los resultados académicos obtenidos.

Para Chandana et al. (2022), al identificar diferentes factores que afectan el desempeño de aprendizaje y el desempeño de un estudiante durante su carrera académica; es posible comprender mejor las causas del bajo rendimiento académico. En los sistemas educativos es difícil rastrear el comportamiento y las características de los estudiantes ya que no existe ninguna automatización o herramienta que prediga o proyecte cómo será el desempeño académico de los estudiantes. Encontrar la correlación entre los factores que afectan el rendimiento de los estudiantes y los resultados académicos juega un papel vital en el sector educativo actual. La predicción del rendimiento para Ghazal (2020) es importante para los estudiantes, ya que ellos y sus asesores académicos pueden utilizarla para

tomar decisiones informadas. Esto también puede ayudar a identificar las medidas adecuadas a tomar y crear programas de titulación personalizados que les permitan adquirir con éxito y eficacia los conocimientos necesarios para completar sus estudios de manera oportuna.

Diversos estudios sobre el rendimiento académico en estudiantes universitarios han determinado que múltiples factores pueden influir en su desempeño como lo resaltan Balaji et al. (2021) y Contreras et al. (2023). Entre estos, se destaca el realizado por Jiménez (2018), que menciona tres factores que inciden en el rendimiento académico: el sexo, el acceso a becas y el nivel de uso de las tecnologías de la información y la comunicación (TIC).

Además, según Espejel y Jiménez (2019) el rendimiento de los estudiantes universitarios también puede estar influenciado por el nivel de estudios de la madre y la ocupación del padre. La influencia del nivel de estudios de la madre se debe a que participa activamente en actividades escolares y quien coadyuva al desarrollo de habilidades cognitivas debido a la convivencia. También se pudo comprobar que a nivel universitario el rendimiento académico de los estudiantes está influenciado por la ocupación del padre, donde aquellos con mejor ingreso pueden proporcionar fuentes y recursos físicos y electrónicos para el aprendizaje y así mejorar sus habilidades cognitivas.

En cambio, Bedregal et al. (2020) señalan que el rendimiento académico está estrechamente relacionado con la proporción entre el número de créditos aprobados y el número de créditos en los que un estudiante se matriculó. En cambio, Mora (2015) destaca que existen otros factores como lo son el entorno familiar, laboral o de salud, pero que las variables de tipo académicas son de mayor utilidad para la toma de decisiones.

Según Lunghi (2022), un fenómeno recurrente es la entrada masiva de estudiantes a programas universitarios, pero la cantidad de graduados no guarda proporción con la cantidad de estudiantes que ingresan, situación que se ha agravado en muchos países desde 2020 debido a la pandemia de COVID-19. En este sentido, Preciado et al. (2022), consideran que esta disparidad se atribuye a diversos factores que inciden en el rendimiento académico, como se mencionó previamente, lo que lleva a que los estudiantes repitan múltiples asignaturas del plan de estudio, prolongando su tiempo de estudio.

De acuerdo con Ayala (2022); Cruz et al. (2022); Valero et al. (2022) y Contreras et al. (2023), ante esta problemática, se han implementado algoritmos de Aprendizaje Automático para predecir o anticipar el rendimiento de estudiantes en distintas universidades. Los resultados han permitido la detección temprana de dificultades académicas y la toma de decisiones adecuadas, como el diseño de estrategias para asegurar el éxito académico, que es el principal objetivo de cualquier institución educativa.

Es importante resaltar que, además de la predicción del rendimiento académico, se han empleado algoritmos de Aprendizaje Automático para predecir la deserción de estudiantes universitarios. Por ejemplo, Miranda y Guzmán (2017) emplearon tres clasificadores distintos: redes bayesianas, árboles de decisión y redes neuronales, cada uno de los cuales produjo resultados determinantes para identificar la deserción estudiantil. Por otro lado, Urteaga et al. (2020) señalan que, a pesar de las ventajas de la educación en línea, tiende a experimentar altos índices de abandono. Por lo que, implementaron diversos algoritmos para desarrollar modelos predictivos de deserción en cursos virtuales ofrecidos por la Secretaría de Extensión de la Universidad Tecnológica Nacional de la República Argentina, Regional Buenos Aires, concluyendo que el algoritmo más eficaz para la creación de modelos fue una red neuronal.

Este artículo se fundamenta en la revisión de diversas publicaciones que presentan los resultados de la implementación de algoritmos de Aprendizaje Automático para predecir el rendimiento académico de estudiantes universitarios. Es esencial tener en cuenta que no existe una única solución para abordar este problema, ya que la elección del algoritmo adecuado puede variar según los datos específicos de cada institución. Por lo tanto, este artículo de revisión tiene como objetivo identificar los algoritmos de Aprendizaje Automático más frecuentemente utilizados que han demostrado una alta precisión y exactitud en la predicción del rendimiento académico de estudiantes universitarios, además de examinar cómo se han implementado o aplicado en distintas universidades.

MATERIALES Y MÉTODOS

La metodología empleada para la elaboración del artículo es la de revisión sistemática. Fonseca y López (2014) señalan que la revisión sistemática resume de manera efectiva los resultados de investigaciones primarias, por medio de estrategias diseñadas para limitar el sesgo y el error aleatorio. Estas estrategias incluyen desde una búsqueda exhaustiva de todos los artículos relevantes hasta la identificación, selección y análisis de los estudios que se incluirán en la revisión. Posteriormente, se lleva a cabo la síntesis de la información recopilada, seguida de la interpretación de los resultados obtenidos.

Inicialmente, se definieron los objetivos de la revisión:

- Identificar los algoritmos de Aprendizaje Automático más frecuentemente utilizados y efectivos en la predicción del rendimiento académico de estudiantes universitarios.
- Examinar cómo han sido implementados o aplicados en distintas universidades para que sea una guía en futuras investigaciones que incluyan la aplicación de estos algoritmos con datos de estudiantes de la Universidad de Panamá.

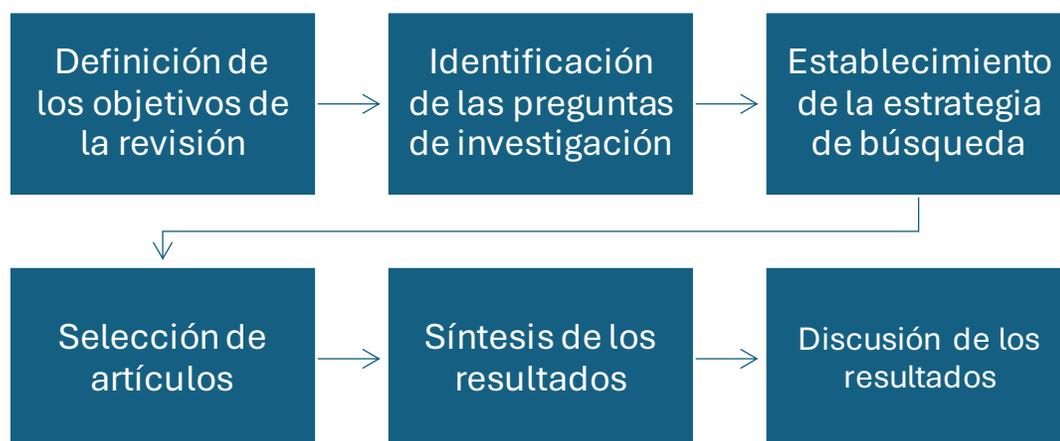
Luego, se definieron las preguntas de investigación:

- ¿Cuáles son los algoritmos de Aprendizaje Automático más utilizados y efectivos en la predicción del rendimiento académico de estudiantes universitarios?
- ¿Cómo han sido aplicados estos algoritmos en distintas universidades para predecir el rendimiento académico de estudiantes universitarios?

Posteriormente, se llevó a cabo una búsqueda exhaustiva, siguiendo criterios de selección de artículos, específicamente consultando en bases de datos académicos, incluyendo Google Académico, Redalyc, Scielo, Dialnet, así como la consulta de revistas especializadas y libros relacionados con el tema de interés. Para llevar a cabo esta búsqueda, se utilizaron palabras clave pertinentes y se aplicaron filtros de búsqueda adecuados para optimizar la selección de artículos relevantes publicados desde 2019 al 2024. En este sentido, los artículos presentados en esta revisión han seguido un proceso compuesto por seis etapas distintas, tal como se ilustra en la Figura 3.

Cada artículo encontrado fue minuciosamente revisado, resultando en la selección de 30 artículos definitivos o primarios para la presentación de los resultados y discusión. Esta selección se basó en la importancia de estos artículos en relación con las distintas aplicaciones de algoritmos de Aprendizaje Automático en la predicción del rendimiento académico de estudiantes universitarios.

Figura 3
Diagrama del proceso de revisión sistemática



RESULTADOS

A continuación, hacemos referencia a los artículos que han sido seleccionados y revisados en relación con la aplicación de algoritmos de Aprendizaje Automático en la predicción del rendimiento académico de estudiantes universitarios:

En un estudio realizado por Gutiérrez et al. (2022), se evaluaron cuatro algoritmos de Aprendizaje Automático: Árboles de Decisión, Bosques Aleatorios, Redes Neuronales y Máquinas de Soporte Vectorial (SVM), con el objetivo de predecir el rendimiento académico de estudiantes de la Facultad de Ciencias Empresariales y Económicas de la Universidad de Lima, Perú. Se utilizaron métricas como la matriz de confusión, el nivel de precisión y la curva de ROC para comparar y seleccionar el algoritmo más adecuado. Los resultados mostraron que los Bosques Aleatorios obtuvieron la mayor precisión en comparación con los otros algoritmos evaluados, con un 80%.

Por otro lado, Contreras et al. (2020) llevaron a cabo un estudio sobre la predicción del rendimiento académico en estudiantes de Ingeniería Industrial de la Universidad Distrital de Colombia. Su metodología incluyó la aplicación de algoritmos de clasificación como Árbol de Decisión, Máquinas de Soporte Vectorial (SVM), Red Neuronal (Perceptrón) y K-Vecinos más cercanos (KNN), y la evaluación de la calidad de la clasificación utilizando métricas como exactitud, precisión, recall y el puntaje F1. Se identificaron siete variables que influyen significativamente en el rendimiento académico, entre las que se incluyen la edad, género, puntajes ICFES para aptitudes matemáticas y puntaje global ICFES. Los algoritmos SVM y Red Neuronal (Perceptrón) se seleccionaron debido a su alta precisión en la predicción del rendimiento académico.

El estudio realizado por Gamboa y Salinas (2022) identifica las variables determinantes en la predicción del rendimiento académico de estudiantes universitarios después de seis semestres en la Universidad Nacional Agraria La Molina de Lima, Perú, utilizando algoritmos de Aprendizaje Automático. Se aplicó la metodología CRISP (Cross-Industry Standard Process for Data Mining) y se analizó un conjunto de datos con 622 registros. Se probaron varios algoritmos, como Regresión Logística, K-Vecinos más Cercanos (KNN), Naive Bayes, Árboles de Decisión (C5.0 y CART), Red Neuronal Perceptrón Multicapa, Máquinas de Soporte Vectorial con Kernel Lineal (SVM-L) y Kernel Radial (SVM-R), destacando Regresión Logística, Naive Bayes y SVM-L. Posteriormente, se combinaron estos tres mediante un algoritmo de ensamblaje, una técnica para fortalecer el rendimiento mediante el promedio de las probabilidades obtenidas. Los resultados resaltaron la importancia de las variables calificaciones del primer semestre, mientras que las variables sociodemográficas no fueron significativas en la predicción del rendimiento académico a largo plazo.

Rico et al. (2019) desarrollaron y aplicaron un modelo predictivo para el rendimiento académico de estudiantes de Ingeniería en el Instituto Politécnico Nacional de la Ciudad de México, utilizando el algoritmo Naive Bayes en un proceso de Descubrimiento de Conocimiento en Bases de Datos (KDD). Recopilaron datos

de 122 estudiantes a través de una encuesta y utilizaron estos datos para predecir el rendimiento de 71 estudiantes adicionales. Realizaron la integración y recopilación de datos, el procesamiento de datos y la construcción del modelo predictivo, evaluando la precisión de las predicciones mediante validación cruzada. Los resultados demostraron una alta precisión en las predicciones del algoritmo Naive Bayes, incluso con un conjunto de datos limitado, lo que sugiere su utilidad en entornos universitarios con pocos datos disponibles. Además, el modelo desarrollado identifica los factores más influyentes en la aprobación y reprobación de los estudiantes desde el inicio del curso.

Gerson (2019) realizó un estudio sobre la predicción del rendimiento académico de los estudiantes de la Facultad de Ingeniería de la Universidad Nacional del Centro del Perú, utilizando modelos de Aprendizaje Automático Supervisado como la Regresión Logística y Random Forest. En esta investigación, se emplearon el lenguaje de programación Python y la librería Scikit-Learn, con el apoyo de las librerías Pandas y Numpy para el tratamiento de los datos. Los resultados mostraron que el modelo de Regresión Logística alcanzó una exactitud del 77%, mientras que el modelo de Random Forest logró un 84%.

Por su parte, Candia (2019), realizó una investigación para predecir el rendimiento académico de los estudiantes de la Universidad Nacional de San Antonio Abad del Cusco (UNSAAC). Empleando la metodología CRISP-DM, WEKA como plataforma, así como varios algoritmos supervisados como Árboles de Decisión J48, Random Forest, K-Vecinos más Cercanos (KNN), Regresión Logística y Perceptrón Multicapa. Los resultados indican que el algoritmo que proporcionó la mejor predicción fue el Random Forest con una efectividad del 69%. En segundo lugar, se ubicó la Regresión Logística con un 68%. Los factores que influyen en el rendimiento académico incluyen la nota de ingreso a la institución, la Escuela Profesional donde estudia, el semestre, la modalidad de ingreso y la cantidad de cursos matriculados.

Castrillón et al. (2020) emplearon el algoritmo de clasificación Bayesiano J48 a través del programa WEKA para identificar los factores más influyentes en el rendimiento académico de los estudiantes. Entre estos factores se encuentran la pedagogía de los profesores, horarios de clase adecuados, una buena relación docente-estudiante, la calidad académica de los docentes y una actividad extracurricular moderada. Mediante este algoritmo, lograron generar un Árbol con los atributos más relevantes, obteniendo una efectividad del 91.67%.

En su investigación, Diaz et al. (2021) emplearon el algoritmo de Árbol de Decisión en conjunto con minería de datos, específicamente el algoritmo J48 de Árbol de Decisión del software WEKA. Utilizaron datos de 237 estudiantes de maestría de la Escuela de Postgrado de la Universidad Nacional José Faustino Sánchez Carrión en Perú, recopilados mediante cuestionarios. La precisión del modelo se evaluó con el índice Kappa de Cohen, mostrando un alto nivel de acierto en las predicciones. Los resultados obtenidos con el algoritmo de Árbol de Decisión fueron exitosos, lo que demuestra la eficacia para predecir problemas de

rendimiento académico. Sin embargo, los autores sugieren mejorar la precisión del modelo priorizando ciertas variables.

Rico y Gaytán (2022) diseñaron y evaluaron modelos para predecir el rendimiento académico de un curso de matemáticas en una Universidad de México, utilizando técnicas de aprendizaje automático como Bayes Ingenuo, K-Vecinos más Cercanos (KNN) y Árbol de Decisión. La construcción y evaluación de los modelos se realizaron con el software Weka. Para el entrenamiento, se recopilaron las calificaciones de las primeras cinco actividades académicas de 260 estudiantes de cursos anteriores. Los datos de pruebas correspondieron a los registros de 112 estudiantes inscritos en el curso actual. Se compararon las predicciones con los resultados reales obtenidos por estos 112 estudiantes al finalizar el curso, para calcular la exactitud de cada técnica, terminado el curso. Bayes Ingenuo logró una exactitud del 75.9%, seguido por KNN con un 69.6%, y finalmente el Árbol de Decisión con un 60.7%.

En el estudio de Santamaría et al. (2023), se compararon varios algoritmos de Aprendizaje Automático, como Random Forest, Máquinas de Soporte Vectorial (SVM), K-Vecinos más Cercanos (KNN) y Regresión Logística, junto con un modelo de Aprendizaje Profundo basado en Redes Neuronales Artificiales (ANN). El objetivo era determinar cuál de estos modelos ofrecía la mayor precisión al predecir el rendimiento académico de estudiantes universitarios de la Universidad de Guayaquil en Ecuador. Los datos se prepararon para el aprendizaje supervisado, asignando el 80% para entrenamiento y el 20% para pruebas. Se evaluaron mediante métricas como la curva ROC, el área bajo la curva (AUC) y la métrica F1-score que indicó que todos los modelos tenían un nivel aceptable de robustez, destacando la Red Neuronal Artificial con un 89.3% de robustez en las predicciones.

Rico (2022), desarrollo y evaluó modelos predictivos para el rendimiento académico de estudiantes universitarios en México. Se incluyeron 260 estudiantes y 14 actividades académicas. Se construyó un modelo predictivo utilizando los algoritmos Naive Bayes, K-Vecinos más Cercanos (KNN) y Árbol de Decisión, para predecir el rendimiento de 112 estudiantes en un semestre posterior. Los resultados mostraron que a medida que aumentaba el número de actividades consideradas, la exactitud de las predicciones también aumentaba. Los modelos con Naive Bayes mostraron un mejor desempeño, alcanzando una exactitud del 81.25%, en comparación con las otras dos técnicas empleadas. Esta metodología permitió identificar a los estudiantes en riesgo de reprobación del curso antes de que finalizara.

Chavez et al. (2023), propusieron un modelo de Red Neuronal Artificial para predecir el rendimiento académico, alcanzando una precisión del 93.81%. En comparación, otras técnicas como Bosques Aleatorios lograron una precisión del 92.81%, Máquina de Soporte Vectorial (SVM) un 80.03% y Naive Bayes un 92.21%. El modelo se evaluó utilizando información de al menos 32000 estudiantes de la Universidad Abierta del Reino Unido, considerando variables como la frecuencia de cursado, evaluaciones promedio, tasa de aprobación del curso, uso de materiales virtuales y clics en aulas virtuales. La arquitectura del modelo consta de tres capas,

utilizando funciones de activación como la tangente hiperbólica sigmoidea para las capas de entrada y oculta, y una función lineal para la capa de salida. Este enfoque logró una efectividad de predicción del 78% y 75% para los dos primeros sujetos, respectivamente.

Carles (2023) desarrolló varios modelos de aprendizaje automático para predecir el rendimiento académico de los estudiantes universitarios de Universitat Politècnica de València en España. Con una población de 5035 alumnos, empleó algoritmos como Máquinas de Soporte Vectorial (SVM), Árboles de Decisión, Random Forest, Vecinos más Cercanos (KNN) y métodos de Regresión. Tras evaluar cada uno de estos modelos, el modelo de Árboles de Decisión fue seleccionado como el más adecuado, ya que mostró una precisión competente y una sólida capacidad de generalización en la predicción de la nota media de los estudiantes. Además, se concluyó que la nota de acceso al grado universitario es el factor más determinante del rendimiento académico global a lo largo de los años de estudio.

El estudio de El-Keiey et al. (2022) analizó el impacto de los rasgos de personalidad y la inteligencia de los estudiantes en su rendimiento académico, utilizando datos recopilados de la Facultad de Computación e Inteligencia Artificial de la Universidad de El Cairo. Se recolectaron datos de aproximadamente 300 estudiantes de diferentes niveles de pregrado. Se utilizaron algoritmos de Aprendizaje Automático, incluyendo K-Vecino más Cercano (KNN), Máquina de Soporte Vectorial (SVM), Árbol de Decisión (DT) y Naive Bayes (NB), para predecir el rendimiento. El DT mostró el mejor rendimiento, con una precisión del 90%. Se concluyó que los rasgos de personalidad son importantes para predecir el desempeño de los estudiantes universitarios.

Según Contreras et al. (2021), al emplear algoritmos supervisados como K-Vecinos más Cercanos (KNN), Máquinas de Soporte Vectorial (SVM), Naive Bayes y Árbol de Decisión para predecir el rendimiento académico, se obtiene un resultado de exactitud, del 74%, siendo el mejor resultado alcanzado mediante el algoritmo Árbol de Decisión. Sin embargo, se observa que los métodos de ensamblaje superan a los supervisados. Se implementan algoritmos de ensamblaje que mejoran la exactitud de los clasificadores previos. Entre estos, se destacan métodos como Bagging (CART, Random Forest, ExtraTreesClassifier), métodos Boosting (AdaBoost, GBM, XGBoost, CatBoost, Light Boost) y Voting (Blending, Stacking). Los resultados indican que los algoritmos de Stacking y Blending alcanzan valores de precisión en cada semestre alrededor del 85% para entrenamiento y del 75% para prueba, lo que muestra los mejores resultados.

Chen et al. (2021), investigaron la capacidad de predecir el rendimiento académico de estudiantes universitarios basándose en sus comportamientos de lectura en un curso con libros electrónicos, utilizando un sistema desarrollado por la Universidad de Kyoto. Participaron 100 estudiantes de primer año de la Universidad de Asia en Taiwán. Se emplearon algoritmos de clasificación de Aprendizaje Automático, como Regresión Logística (LR), Bayes ingenuo Gaussiano (NB), una

variante de Naive Bayes), Clasificación de Vectores de Soporte (SVC), Árbol de Decisión (DT), Bosque Aleatorio (RF) y Red Neuronal (NN), para predecir el rendimiento académico. NB destacó en la identificación de estudiantes en riesgo, mientras que LR y NN mostraron un rendimiento consistente en diferentes métricas para la predicción del rendimiento.

Bedregal et al. (2020) aplicaron Redes Neuronales y técnicas de aprendizaje supervisado para generar Árboles de Decisión, como C4.5 e ID3. De estas, el algoritmo C4.5 produjo las mejores métricas de rendimiento. Utilizaron variables como los créditos aprobados, los créditos que debería haber cursado, las calificaciones, el Promedio Ponderado Ajustado (PPA), el Índice de Rendimiento Exógeno y Endógeno (IREX, IREN), y el Índice de Rendimiento Total (IRT). Sin embargo, se encontró que la variable más significativa en la construcción del modelo es la relación entre los créditos aprobados por un estudiante y los créditos que debería haber cursado, seguida por las calificaciones.

En el caso de Ahmad et al. (2021), se propone un método para predecir el desempeño de los estudiantes de la Facultad de Ingeniería Eléctrica de la Universiti Teknologi MARA (UiTM) Terengganu, Malasia. El alcance de este artículo es la predicción de los estudiantes que podrían alcanzar la Lista del Decano (promedios de calificaciones GPA de 3.5 y superiores). Se empleó un modelo predictivo basado en una técnica de Aprendizaje Automático que utiliza Redes Neuronales Artificiales (ANN) para predecir el desempeño real de los estudiantes del primer semestre. Los hallazgos han demostrado que el modelo desarrollado podría predecir con precisión el resultado real de los estudiantes del primer semestre con éxito y con errores mínimos.

Por su parte, Ekubo y Esiefarienrhe (2022) evaluaron varias técnicas de Aprendizaje Automático para predecir el bajo rendimiento académico utilizando datos de estudiantes de la Universidad del Delta del Níger en Nigeria. El estudio aplicó la metodología CRISP-DM y la herramienta WEKA para modelado. Se probaron algoritmos clasificadores como Árbol de Decisión J48, Regresión Logística (LR), Perceptrón Multicapa (MLP) y Bayes ingenuo Gaussiano (NB). Los resultados indicaron que MLP fue el mejor clasificador para este conjunto de datos.

Alturki y Alturki (2021) recopilaron registros de 300 estudiantes de la Facultad de Ciencias de la Información y Computación en Arabia Saudita. Se comparó el rendimiento de los siguientes algoritmos: Árboles de Decisión (C4.5, Simple CART, LADTree), Naive Bayes y Random Forest. Los resultados muestran que Naive Bayes y Random Forest logran la mayor precisión, con un 63,33% y 63%, respectivamente.

Por otro lado, Al-Alawi et al. (2023), emplearon algoritmos de Aprendizaje Automático Supervisado para investigar los factores que influyen negativamente en el rendimiento académico de estudiantes universitarios en calidad condicional. Utilizaron un conjunto de datos proporcionado por la Universidad Sultán Qaboos, que incluía 33 características y 37599 estudiantes, desde el otoño de 2009 hasta el

verano de 2019. Se aplicó la metodología de Descubrimiento de Conocimiento en Bases de Datos (KDD) y después de seleccionar las características más efectivas, se construyeron modelos predictivos utilizando varios algoritmos supervisados que incluyeron Árbol de Decisión (J48 y Random Tree), Random Forest, Naive Bayes, K-Vecinos más Cercanos (KNN), Máquinas de Soporte Vectorial (SVM) y Redes Neuronales Artificiales (ANN). El algoritmo J48 de Árbol de Decisión obtuvo el mejor resultado con una precisión del 82,4%.

En cambio, Abdelmagid y Qahmash (2023), exploró la detección de patrones educativos y la predicción del rendimiento académico de estudiantes universitarios mediante la tecnología "Orange" para minería de datos. El estudio analizó los resultados de los estudiantes de la Universidad King Khalid en varios cursos para identificar los factores que influyen en su rendimiento. Se utilizaron técnicas de clasificación, agrupamiento y predicción, junto con algoritmos como Random Forest, Regresión Lineal, K-Vecinos más Cercanos (KNN) y Máquina de Soporte Vectorial (SVM). Los resultados mostraron que el algoritmo Random Forest fue el más efectivo para clasificar las puntuaciones de los estudiantes, seguido por Regresión Lineal, KNN y SVM.

A su vez, Meghji et al. (2023), proponen desarrollar un modelo de clasificación para predecir el rendimiento académico final de los estudiantes en una etapa temprana y determinar qué cursos influyen en este desempeño. Utilizan datos de estudiantes de Ingeniería de Software de la Universidad de Ingeniería y Tecnología de Mehran en Pakistán, con una muestra de 291 alumnos. Se emplearon algoritmos de clasificación como Naive Bayes (NB), Árbol de Decisión J48, Random Forest (RF) y KStar (variante del algoritmo K-Vecinos más cercanos (KNN)) para predecir el rendimiento al final de 4 años. Para cada algoritmo, se realizaron experimentos utilizando diferentes combinaciones de los datos recopilados. El clasificador de Árbol de Decisión J48 se identificó como el más efectivo para identificar cursos que podrían requerir intervención educativa.

Alturki et al. (2022), emplearon algoritmos de minería de datos para prever el rendimiento académico de estudiantes de maestría utilizando un conjunto de datos reducido y características fácilmente accesibles al inicio del programa. Recopilaron más de 700 registros de estudiantes de la Facultad de Informática Empresarial y Matemáticas de la Universidad de Mannheim en Alemania, abarcando datos demográficos y calificaciones semestrales. Se aplicaron seis algoritmos: Regresión Logística (LR), Random Forest (RF), K-Vecinos más cercanos (KNN), Naive Bayes (NB), Máquina de Soporte Vectorial (SVM) y Redes Neuronales Artificiales (ANN). Los resultados revelaron que el modelo RF, superó a los demás algoritmos en términos de predicción del rendimiento académico de los estudiantes de maestría.

Yagci (2022) propone un nuevo modelo basado en algoritmos de Aprendizaje Automático para predecir las calificaciones de exámenes finales de estudiantes de pregrado, utilizando las calificaciones de exámenes parciales como fuente de datos. Se evaluaron y compararon varios algoritmos, utilizando datos de rendimiento académico de 1854 estudiantes en un curso de idioma turco I en una Universidad

Estatad de Turquía. Los algoritmos evaluados incluyeron Random Forest (RF), Redes Neuronales (NN), Regresión Logística (LR), Máquina de Soporte Vectorial (SVM), Naive Bayes (NB) y K-Vecinos más cercanos (KNN), con el algoritmo RF logrando una precisión del 74,6% en la predicción del rendimiento académico de los estudiantes.

Ghosh et al. (2022) investigaron los factores que influyen en el rendimiento estudiantil y predicen su desempeño utilizando algoritmos de Aprendizaje Automático en la Universidad de Textiles de Bangladesh. Identificaron 11 factores significativos, incluidos aspectos psicológicos, personales y del entorno académico. Utilizaron dos algoritmos de aprendizaje supervisado, Máquina de Soporte Vectorial (SVM) y Bosques Aleatorios, para clasificar los resultados estudiantiles y predecir su desempeño. La comparación entre ambos algoritmos reveló que el modelo de Bosques Aleatorios superó al de SVM en términos de precisión, alcanzando un impresionante 96.88%, frente al 81.25% del SVM.

Alsubaie (2023), propuso un enfoque de Aprendizaje Automático para mejorar la calidad de los programas de capacitación en línea en la Universidad de Taif, utilizando la plataforma Maharat y los estándares de aprendizaje en línea del Reino de Arabia Saudita. Su objetivo fue predecir el rendimiento académico de los estudiantes basándose en su participación en el entorno de aprendizaje en línea. Después de extraer características relevantes y realizar la clasificación, se evaluaron las predicciones utilizando Máquina de Soporte Vectorial (SVM), Naive Bayes, K-Vecinos más Cercanos y Árbol de Decisión. Los resultados mostraron que SVM alcanzó una precisión del 93.2%, seguido por Naive Bayes con 92.3% en términos de predicción.

Por otro lado, Incio et al. (2023) desarrollaron y entrenaron una Red Neuronal Artificial para predecir los resultados académicos de estudiante de Ingeniería Civil en la asignatura de Matemática II en la Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua, Perú. Utilizaron la metodología CRISP-DM y el software Matlab, empleando dos algoritmos de aprendizaje supervisado: Scaled Conjugate Gradient (SCG) y Levenberg-Marquardt (LM), para comparar los resultados. La implementación de la Red Neuronal mostró mejores resultados utilizando el 85% de los datos para el entrenamiento, el 10% para la validación y el 5% para la prueba. El algoritmo ML demostró una mayor efectividad en la predicción, alcanzando una capacidad predictiva del 86%, mientras que la red entrenada con el algoritmo SCG alcanzó una capacidad predictiva del 70%.

En su investigación sobre la predicción del rendimiento académico de los estudiantes ingresantes de la Facultad de Ingeniería en Industrias Alimentarias de la Universidad Nacional Agraria de la Selva (UNAS) de Perú, Ponce (2024) utilizó el software WEKA para analizar algoritmos como K-Vecinos más Cercanos (KNN), Random Forest (RF), Naive Bayes y Bagging. Empleando la metodología CRISP-DM y técnicas de minería de datos, logró desarrollar un modelo de aprendizaje automático que predice de manera significativa el rendimiento académico. Los indicadores considerados fueron la opción de ingreso, la nota de ingreso, el sexo

del ingresante y el número de hermanos en la familia. Las pruebas de Anova de Friedman mostraron que los modelos de RF y KNN alcanzaron una exactitud del 98.4%.

Salto y Cruz (2024) en su estudio del rendimiento académico de estudiantes de las carreras de Economía y Turismo de la Universidad Técnica de Manabí en Ecuador, emplearon la metodología CRISP-DM y ejecutaron varios algoritmos de aprendizaje automático, como Árbol de Decisión, Random Forest, Redes Neuronales y Máquina de Soporte Vectorial, para obtener el rendimiento académico. Después de evaluar los distintos algoritmos, encontraron que el más eficiente fue Random Forest, con una estimación aceptable del 86%. Este algoritmo proporciona valores precisos, lo que permitió crear un panel de control en Power BI, que muestra y analiza datos de manera clara y efectiva, incluyendo asistencia, notas, calificaciones y otros resultados académicos de los estudiantes.

En tabla 2, se aprecia la frecuencia con la que se han empleado los algoritmos de Aprendizaje Supervisado y Aprendizaje Profundo en la predicción del rendimiento académico, en esta revisión.

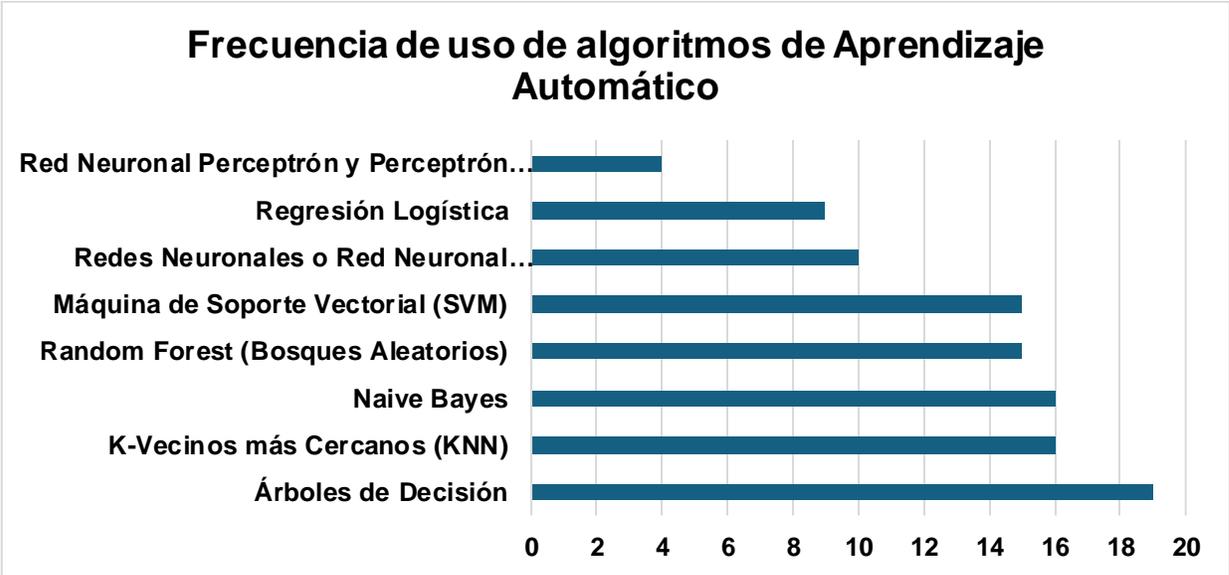
Tabla 2

Algoritmos más utilizados para la predicción del rendimiento académico.

Algoritmo	Tipo de algoritmo	Número de veces
Árboles de Decisión	Aprendizaje Supervisado	19
K-Vecinos más Cercanos (KNN)	Aprendizaje Supervisado	16
Naive Bayes	Aprendizaje Supervisado	16
Random Forest (Bosques Aleatorios)	Aprendizaje Supervisado	15
Máquina de Soporte Vectorial (SVM)	Aprendizaje Supervisado	15
Redes Neuronales o Red Neuronal Artificial (ANN)	Aprendizaje Profundo	10
Regresión Logística	Aprendizaje Supervisado	9
Red Neuronal Perceptrón y Perceptrón Multicapa	Aprendizaje Profundo	4

Con el fin de ofrecer una representación visual más clara de esta información, se presenta un gráfico que facilita la identificación de los algoritmos más comúnmente empleados en la predicción del rendimiento académico de estudiantes universitarios. Dicho gráfico se encuentra detallado en la Figura 4.

Figura 4
Frecuencia de uso de algoritmos de Aprendizaje Automático para la Predicción del Rendimiento Académico



DISCUSIÓN

De los artículos revisados sobre la aplicación de algoritmos de Aprendizaje Automático para predecir el rendimiento académico de estudiantes universitarios, se evaluaron y compararon tanto algoritmos de Aprendizaje Supervisado como algoritmos de Aprendizaje Profundo. Entre los algoritmos de Aprendizaje Supervisado más ampliamente empleados se encuentran: Árboles de Decisión, K-Vecinos más Cercanos (KNN), Naive Bayes, Random Forest (Bosques Aleatorios) y Máquinas de Soporte Vectorial (SVM), junto con algunas de sus variantes consideradas en el estudio. Los algoritmos de Aprendizaje Profundo incluyeron los siguientes: Red Neuronal Perceptrón, Red Neuronal Perceptrón Multicapa y Redes Neuronales o Red Neuronal Artificial (ANN).

Según la revisión realizada, los algoritmos de Aprendizaje Supervisado reconocidos por su precisión en la predicción del rendimiento académico en entornos universitarios son: Random Forest (Bosques Aleatorios), Árboles de Decisión y Naives Bayes. Y de los algoritmos de Aprendizaje Profundo, tanto las Redes Neuronales Perceptrón como las Redes Neuronales Artificiales (ANN) han demostrado una notable precisión.

Lo resultados de este artículo de revisión coinciden en gran medida con los hallazgos de García (2020), quien señala que los algoritmos más utilizados para predecir el rendimiento académico son el Naive Bayes, las Redes Neuronales, los Árboles de Decisión y las Máquina de Soporte Vectorial.

Es importante destacar que durante la revisión no se encontraron artículos que presentaran resultados basados en el uso de algoritmos de Aprendizaje No

Supervisado en la predicción del rendimiento académico de estudiantes universitarios. Según Serrato (2021), esto se debe a que estos algoritmos se utilizan principalmente para descubrir patrones ocultos en los datos en lugar de realizar predicciones directas. Además, los resultados de estos algoritmos suelen ser difíciles de interpretar en términos de variables específicas que influyen en el rendimiento académico.

En esta tarea, comprender las razones detrás del rendimiento de los estudiantes es fundamental para intervenir de manera efectiva. Por lo general, esto se logra de manera más eficaz mediante el uso de algoritmos de Aprendizaje Supervisado, que permiten establecer relaciones directas entre las variables y las predicciones, ofreciendo una comprensión más clara de los factores que impactan en el rendimiento académico.

CONCLUSIÓN

Los artículos revisados resaltan el predominio de algoritmos de Aprendizaje Supervisado en la tarea de predecir el rendimiento académico de estudiantes universitarios. Además, se observa la presencia de algoritmos de Aprendizaje Profundo en este ámbito.

El uso de algoritmos de Aprendizaje No Supervisado para predecir el rendimiento académico de estudiantes universitarios es menos común, en comparación con los algoritmos de Aprendizaje Supervisado y Aprendizaje Profundo, puesto que generalmente se prefieren los algoritmos de Aprendizaje Supervisado por su orientación hacia la realización de predicciones y por la necesidad de obtener resultados precisos y de fácil interpretación.

Es evidente que los algoritmos de Aprendizaje Automático pueden considerar una amplia variedad de variables, como historiales académicos, factores socioeconómicos, características personales y datos de comportamiento, entre otros, para lograr una precisión significativamente mayor en la predicción del rendimiento de los estudiantes. A través del análisis de datos históricos de estudiantes y variables relevantes relacionadas con los factores que influyen en el rendimiento académico, estos algoritmos pueden identificar y capturar información compleja que va más allá de los métodos estadísticos tradicionales, generando así modelos predictivos altamente precisos.

Es fundamental señalar que la aplicación de algoritmos de Aprendizaje Automático en la predicción del rendimiento académico tiene un gran potencial para contribuir a la reducción de la tasa de deserción, mejorar los resultados educativos, identificar tempranamente a los estudiantes en riesgo de fracaso y respaldar la toma de decisiones en la enseñanza, así como optimizar los recursos educativos. Por lo tanto, es crucial continuar profundizando en la investigación sobre la predicción del rendimiento académico para explorar otros factores que puedan influir en el éxito de los estudiantes.

Con un enfoque equilibrado y una implementación adecuada, los algoritmos de Aprendizaje Automático tienen el potencial de generar mejoras significativas en la educación superior y en el logro académico de los estudiantes.

REFERENCIAS BIBLIOGRÁFICAS

- Abdelmagid, A. S., & Qahmash, A. I. (2023). Utilizing the Educational Data Mining Techniques "Orange Technology" for Detecting Patterns and Predicting Academic Performance of University Students. *Information Sciences Letters*, 17. doi:<http://dx.doi.org/10.18576/isl/120330>
- Ahmad, N., Hassan, N., Jaafar, H., & Enzai, N. (2021). Students' Performance Prediction using Artificial Neural Network. *IOP Conference Series: Materials Science and Engineering*, 9. doi:<https://doi.org/10.1088/1757-899X/1176/1/012020>
- Al-Alawi, L., Al Shaqsi, J., Tarhini, A., & Al-Busaidi, A. (2023). Using machine learning to predict factors affecting academic performance: the case of college students on academic probation. *Education and Information Technologies*, 26. doi:<https://doi.org/10.1007/s10639-023-11700-0>
- Albreiki, B., Zaki, N., & Alashwal, H. (2021). A Systematic Literature Review of Student' Performance Prediction Using Machine Learning Techniques. *Education Sciences*. doi:<https://doi.org/10.3390/educsci11090552>
- Alsubaie, M. (2023). Predicting student performance using machine learning to enhance the quality assurance of online training via Maharat platform. *Alexandria Engineering Journal*, 323-339.
- Alturki, S., & Alturki, N. (2021). Using Educational Data Mining to Predict Student's Academic Performance for Applying Early Interventions. *Journal of Information Technology Education: Innovations in Practice*, 17. doi:<https://doi.org/10.28945/4835>
- Alturki, S., Cohausz, L., & Stuckenschmidt, H. (2022). Predicting Master's students' academic performance: an empirical study in Germany. *Smart Learning Environments*, 22. doi:<https://doi.org/10.1186/s40561-022-00220-y>
- Ayala Franco, E. (2022). Sistema predictivo de rendimiento escolar de alumnos universitarios de primer ingreso. México: Dirección General de Bibliotecas y Servicios Digitales de Información. Obtenido de <https://ri-ng.uaq.mx/handle/123456789/3866>
- Balaji, P., Alelyani, S., Qahmash, A., & Mohana, M. (2021). Contributions of Machine Learning Models towards Student Academic Performance Prediction: A Systematic Review. *Applied Sciences*. doi:<https://doi.org/10.3390/app112110007>

- Bedregal Alpaca, N., Tupacyupanqui Jaén, D., & Cornejo Aparicio, V. (2020). Análisis del rendimiento académico de los estudiantes de Ingeniería de Sistemas, posibilidades de deserción y propuestas para su retención. *Ingeniare. Revista chilena de ingeniería*, 28(4), 668-683. Obtenido de https://www.scielo.cl/scielo.php?pid=S0718-33052020000400668&script=sci_arttext
- Buenaño-Fernández, D., Gil, D., & Luján-Mora, S. (2019). Application of Machine Learning in Predicting Performance for Computer Engineering Students: A Case Study. *Sustainability*. doi:doi:<https://10.3390/su11102833>
- Candia Oviedo, D. (2019). Predicción del rendimiento académico de los estudiantes de la UNSAAC a partir de sus datos de ingreso utilizando algoritmos de aprendizaje automático. Cusco, Cusco, Perú. Obtenido de <https://repositorio.unsaac.edu.pe/handle/20.500.12918/4120>
- Carles Vega, J. (2023). Modelización de los factores que inciden en el rendimiento académico de los estudiantes universitarios con técnicas de estadística multivariante y de machine learning. Valencia, España: Universitat Politècnica de València. Obtenido de <http://hdl.handle.net/10251/192774>
- Castrillón, O. D., Sarache, W., & Ruiz Herrera, S. (2020). Predicción del rendimiento académico por medio de técnicas de inteligencia artificial. *Formación universitaria*, 13(1), 93-102. Obtenido de https://www.scielo.cl/scielo.php?pid=S0718-50062020000100093&script=sci_arttext
- Chandana, D. A., Sundaram, M., Bhumika, S., & Meghana, B. N. (2022). Application of Machine Learning Techniques to Evaluate the Performance of Students in an Academic Environment. *Saudi Journal of Engineering and Technology*, 327-334. doi:<https://doi.org/10.36348/sjet.2022.v07i06.008>
- Chavez, H., Chavez-Arias, B., Contreras-Rosas, S., Alvarez-Rodríguez, J., & Raymundo, C. (2023). Artificial neural network model to predict student performance using nonpersonal information. *Frontiers in Education*, 11. doi:<https://doi.org/10.3389/educ.2023.1106679>
- Chen, C.-H., Yang, S., Weng, J.-X., Ogata, H., & Su, C.-Y. (2021). Predicting at-risk university students based on their e-book reading behaviours by using machine learning classifiers. *Australasian Journal of Educational Technology*, 15. doi:<https://doi.org/10.14742/ajet.6116>
- Contreras Bravo, L., Fuentes López, H., & Rivas Trujillo, E. (2021). Análisis del rendimiento académico mediante técnicas de aprendizaje automático con métodos de ensamble. *Revista Boletín REDIP*, 10(13), 171-190. Obtenido de <https://revista.redipe.org/index.php/1/article/view/1737/1652>
- Contreras, L., Fuentes, H., & Rodríguez, J. (2020). Predicción del rendimiento académico como indicador de éxito/fracaso de los estudiantes de

ingeniería, mediante aprendizaje automático. *Formación universitaria*, 13(5), 233-246. Obtenido de https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-50062020000500233

Contreras, L., Nieves, N., & Gonzalez, K. (2023). Predicción del rendimiento académico universitario mediante mecanismos de aprendizaje automático y métodos supervisados. *Ingeniería*, 28. doi:<https://doi.org/10.14483/23448393.19514>

Contreras, L., Tarazona, G., & Alemán, A. (2023). *Machine Learning aplicado al rendimiento académico en educación superior: factores, variables y herramientas*. Bogotá: Editorial Universidad Distrital Francisco José de Caldas.

Cruz, E., González, M., & Rangel, J. (2022). Técnicas de machine learning aplicadas a la evaluación del rendimiento y a la predicción de la deserción de estudiantes universitarios, una revisión. *Prisma Tecnológico*, 13(1), 77-87. Obtenido de <https://doi.org/10.33412/pri.v13.1.3039>

Díaz Ramírez, J. (2021). Aprendizaje Automático y Aprendizaje Profundo. *Ingeniare. Revista chilena de ingeniería*, 29(2), 180-181. Obtenido de https://www.scielo.cl/scielo.php?pid=S0718-33052021000200180&script=sci_arttext

Díaz, B., Meleán, R., & Marín, W. (2021). Rendimiento académico de estudiantes en Educación Superior: predicciones de factores influyentes a partir de árboles de decisión. *Telos*, 23(3). Obtenido de <https://dialnet.unirioja.es/servlet/articulo?codigo=8133982>

Ekubo, E., & Esiefarienrhe, B. (2022). Using machine learning to predict low academic performance at a Nigerian university. *The African Journal of Information and Communication*, 33. doi:<https://doi.org/10.23962/ajic.i30.14839>

El-Keiey, S., ElMenshawy, D., & Hassanein, E. (2022). Student's Performance Prediction based on Personality Traits and Intelligence Quotient using Machine Learning. *International Journal of Advanced Computer Science and Applications*, 8.

Enoughwure, A., & Ogbise, M. (2020). Application of Machine Learning Methods to Predict Student Performance: A Systematic Literature Review. *International Research Journal of Engineering and Technology (IRJET)*, 3405-3415.

Espejel García, M., & Jiménez García, M. (2019). Nivel educativo y ocupación de los padres: Su influencia en el rendimiento académico de estudiantes universitarios. *RIDE. Revista Iberoamericana para la Investigación y el Desarrollo Educativo.*, 10(19). Obtenido de

https://www.scielo.org.mx/scielo.php?pid=S2007-74672019000200026&script=sci_arttext

- Fonseca, A., & López Hernández, D. (2014). Criterios para publicar artículos de revisión sistemática. *Revista de Especialidades Médico-Quirúrgicas*, 19(3), 393-399.
- Gamboa Unsihuay, J. E., & Salinas Flores, J. W. (2022). Predicción de la situación académica en estudiantes de pregrado utilizando algoritmos de aprendizaje automático. *Perfiles*, 1(27), 4-10. Obtenido de <http://ceaa.esPOCH.edu.ec:8080/revista.perfiles/faces/Articulos/Perfiles27Art1.pdf>
- García Peredo, L. J. (2020). Revisión sistemática sobre la predicción del rendimiento académico en estudiantes: técnicas y algoritmos. Chiclayo, Lambayeque, Perú. Recuperado el 5 de septiembre de 2023, de https://tesis.usat.edu.pe/bitstream/20.500.12423/3635/1/TIB_GarciaPeredoLuisJesus.pdf
- Gerón, A. (2020). *Aprende Machine Learning con Scikit-Learn, Keras y TensorFlow* (segunda edición ed.). Madrid: Anaya Multimedia.
- Gerson Yovanni, O. M. (2019). Aplicación de Data Science para la Predicción del Rendimiento Académico de los Estudiantes de la Facultad de Ingeniería de Sistemas de la Universidad Nacional del Centro del Perú. Huancayo, Junín, Perú. Obtenido de <https://repositorio.uncp.edu.pe/handle/20.500.12894/5837>
- Ghazal, A. (2020). Using Machine Learning to Support Students' Academic Decisions. *Journal of Theoretical and Applied Information Technology*.
- Ghosh, S., J. F., & Ahmad, I. (2022). Application of the Classification Algorithms on the Prediction of Student's Academic Performance. *Trends in Sciences*, 16. doi:<https://doi.org/10.48048/tis.2022.5070>
- González, L. (3 de Agosto de 2018). *AprendeIA*. Recuperado el 30 de mayo de 2023, de Todo sobre aprendizaje supervisado en Machine Learning: <https://aprendeia.com/todo-sobre-aprendizaje-supervisado-en-machine-learning/>
- González, L. (15 de Junio de 2018). *AprendeIA*. Recuperado el 9 de Diciembre de 2023, de Diferencia entre aprendizaje supervisado y no supervisado: <https://aprendeia.com/diferencia-entre-aprendizaje-supervisado-y-no-supervisado/>
- González, L. (11 de Febrero de 2020). *AprendeIA*. Recuperado el 5 de Junio de 2023, de Aprendizaje no Supervisado: <https://aprendeia.com/aprendizaje-no-supervisado-machine-learning/>

- Gutiérrez Villaverde, H. E., Linares Barbero, M., Agüero Correa, Á. A., & Pérez Nuñez, J. R. (2022). Predicción de rendimiento académico de alumnos usando machine learning. Lima: Repositorio Institucional Universidad de Lima. Obtenido de <https://repositorio.ulima.edu.pe/handle/20.500.12724/16703>
- IBM. (2023). *¿Qué es el aprendizaje no supervisado?* Recuperado el 30 de mayo de 2023, de https://www.ibm.com/mx-es/topics/unsupervised-learning?mhsrc=ibmsearch_a&mhq=aprendizaje%20supervisado
- IBM. (2023). *¿Qué es el aprendizaje supervisado?* Recuperado el 30 de mayo de 2023, de https://www.ibm.com/es-es/topics/supervised-learning?mhsrc=ibmsearch_a&mhq=aprendizaje%20supervisado
- Incio Flores, F., Capuñay Sanchez, D., & Estela Urbina, R. (2023). Modelo de red neuronal artificial para predecir resultados académicos en la asignatura Matemática II. *Revista Electrónica Educare*, 27(1), 338-359. Obtenido de https://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S1409-42582023000100338&lang=es
- Issah, I., Appiah, O., Appiahene, P., & Inusah, F. (2023). A systematic review of the literature on machine learning application of determining the attributes influencing academic performance. *Decision Analytics Journal*. doi:<https://doi.org/10.1016/j.dajour.2023.100204>
- Jiménez García, M. (2018). Análisis cuantitativo de las variables que influyen en el rendimiento universitario. *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 9(17), 623-638.
- Lagares, J. A., Díaz, N., & Barranco, C. (2022). Aprendizaje profundo: una nueva vía para convertir el dato en conocimiento. *Economía industrial*(423), 25-38.
- Lunghi, C. G. (8 de Noviembre de 2022). *Repositorio Institucional de la UNLP*. Recuperado el 15 de agosto de 2023, de <http://sedici.unlp.edu.ar/handle/10915/145726>
- Meghji, A., Mahoto, N., Asiri, Y., Alshahrani, H., Sulaiman, A., & Shaikh, A. (2023). Early detection of student degree-level academic performance using educational data mining. *PeerJ Computer Science*, 29. doi:<http://doi.org/10.7717/peerj-cs.1294>
- Miranda, M., & Guzmán, J. (2017). Análisis de la Deserción de Estudiantes Universitarios usando Técnicas de Minería de Datos. *Formación universitaria*, 10(3), 61-68. Obtenido de https://www.scielo.cl/scielo.php?pid=S0718-50062017000300007&script=sci_arttext&tlng=pt
- Mora García, R. (2015). Factores que intervienen en el rendimiento académico universitario: Un estudio de caso. *Opción*, 31(6), 1041-1063.

- Moreno, A., Armengol, E., Béjar L. Belanche, E., Cortés, U., Gavaldá, R., López, B., & M. Sánchez, M. (1994). *Aprendizaje automático*. Barcelona: Edicions UPC.
- Norman, A. (2019). *Aprendizaje Automático en acción: Un libro para el lego, guía paso a paso para los novatos*. Litres.
- Ojajuni, O., Ayeni, F., Akodu, O., Ekanoye, F., Adewole, S., Ayo, T., . . . Mbarika, V. (2021). Predicting Student Academic Performance Using Machine Learning. *Computational Science and Its Applications – ICCSA*, 481-491. doi:https://doi.org/10.1007/978-3-030-87013-3_36
- Oliver, J. (2007). Factores asociados al rendimiento académico. *Educación*, 31(1), 43-63.
- Pineda Pertuz, C. (2022). *Aprendizaje automático y profundo en Python*. Bogotá: Ra-Ma.
- Ponce Guizabalo, S. (1 de Abril de 2024). Modelo de aprendizaje automático para la predicción del rendimiento académico de los alumnos ingresantes en la facultad de Ingeniería en Industrias Alimentarias de la UNAS. Tingo María, Leoncio Prado, Perú. Obtenido de <https://repositorio.unas.edu.pe/items/d92d7ad5-89d4-4ba7-af91-c8c963bcc421>
- Preciado, G., Huerta, J., Vera, Á., & Corral, A. (2022). Causas Asociadas a La Deserción Escolar en Educación Superior. Una Revisión Sistemática Del 2010 Al 2020. *Ra Ximhai*, 18(1), 83-101. Obtenido de <https://doi.org/10.35197/rx.18.01.2022.04.jp>
- Rico Páez, A. (2022). Modelos predictivos progresivos del rendimiento académico de estudiantes universitarios. *Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 12(24).
- Rico Páez, A., & Gaytán Ramírez, N. D. (2022). Predicción del rendimiento académico utilizando las primeras actividades académicas de estudiantes universitarios y técnicas de aprendizaje automático. *Revista Dilemas Contemporáneos: Educación, Política y Valores*(3). doi:<https://doi.org/10.46377/dilemas.v9i3.3177>
- Rico Páez, A., Gaytán Ramírez, N. D., & Sánchez Guzmán, D. (2019). Construcción e implementación de un modelo para predecir el rendimiento académico de estudiantes. *Diálogos sobre educación. Temas actuales en investigación educativa*, 10(19).
- Saltos Mero, J., & Cruz Felipe, M. (2024). Análisis del rendimiento académico de estudiantes de las carreras Economía y Turismo con Power BI en los periodos (2021). *593 Digital Publisher CEIT*, 9(1), 762-772. Obtenido de https://www.593dp.com/index.php/593_Digital_Publisher/article/view/2162

- Sandoval, L. J. (2018). Algoritmos de Aprendizaje Automático para Análisis y Predicción de Datos. *Revista Tecnológica*(11), 36-40. Obtenido de <http://redicces.org.sv/jspui/handle/10972/3626>
- Sandra, L., Lumbangaol, F., & Matsuo, T. (2021). Machine Learning Algorithm to Predict Student's Performance: A Systematic Literature Review. *TEM Journal*, 1919-1927. doi:<https://doi.org/10.18421/TEM104-56>
- Santamaría, T., Patiño, D., González, V., & Flores, L. (2023). Implementación de técnicas de machine learning y creación de una red neuronal artificial para la predicción del rendimiento académico de estudiantes en ambientes universitarios que usan e-learning y streaming. *DYNA - Ingeniería e Industria*, 98(3), 282-287. Obtenido de <https://web.s.ebscohost.com/ehost/pdfviewer/pdfviewer?vid=1&sid=51437559-d08c-4cff-82e6-2b1c30a9437c%40redis>
- Serrato, C. (25 de marzo de 2021). *INMEDIATUM*. Recuperado el 5 de junio de 2023, de <https://inmediatum.com/blog/estrategia/diferencia-entre-aprendizaje-supervisado-y-no-supervisado/>
- Soria Olivas, E., Sánchez, M., Gamero Cruz, R., Castillo Caballero, B., & Cano Michelena, P. (2023). *Sistemas de Aprendizaje Automático*. Madrid: RA-MA.
- Urteaga, I., Siri, L., & Garófalo, G. (2020). Predicción temprana de deserción mediante aprendizaje automático en cursos profesionales en línea. *RIED. Revista Iberoamericana de Educación a Distancia*, 23(2), 147–167. Obtenido de <https://www.redalyc.org/journal/3314/331463171008/>
- Valero, J., Navarro, Á., Larios, A., & Julca, J. (2022). Deserción universitaria evaluación de diferentes algoritmos de Machine Learning para su predicción. *Revista de ciencias sociales*, 28(3), 362-375. Obtenido de <https://dialnet.unirioja.es/servlet/articulo?codigo=8526463>
- Yagci, M. (2022). Educational data mining: prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 19. doi:<https://doi.org/10.1186/s40561-022-00192-z>
- Yepes Piqueras, V. (2022). El aprendizaje profundo (deep learning) en la optimización de estructuras. Valencia: Universitat Politècnica de València. Obtenido de <https://victoryepes.blogs.upv.es/2020/09/15/el-aprendizaje-profundo-deep-learning-en-la-optimizacion-de-estructuras/>
- Zhang, Y., Yun, Y., An, R., Cui, J., Dai, H., & Shang, X. (2021). Educational Data Mining Techniques for Student Performance Prediction: Method Review and Comparison Analysis. *Frontiers in Psychology*.

IoT y la amenaza de Amazon Sidewalk: protegiendo tu hogar y tu privacidad

IoT and the Amazon Sidewalk threat: protecting your home and privacy

Jenny I. Ríos Z.

Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación.
Panamá.

jenny.rios@up.ac.pa <https://orcid.org/0000-0002-1134-7945>

Recibido: 31-1-2024, Aceptado: 8-5-2024

DOI <https://doi.org/10.48204/3072-9696.6362>

RESUMEN

Amazon Sidewalk es una nueva función que conecta dispositivos inteligentes de Amazon (como Echo y Ring) entre sí y con los de los vecinos, creando una red de internet comunitaria. Si bien esto puede aumentar la conectividad y la seguridad de los dispositivos, también ha generado preocupaciones sobre la privacidad. Los defensores de la privacidad señalan que Amazon recopila datos sobre el uso de la red y que los dispositivos se optan automáticamente por el servicio sin el consentimiento explícito del usuario (*El Español*, 2021, 17 de junio). Además, existen posibles vulnerabilidades de seguridad que podrían ser explotadas por actores maliciosos. Es importante ser consciente de los riesgos y beneficios de IoT antes de usar dispositivos como Amazon Sidewalk. Los usuarios deben tomar medidas para proteger su privacidad, como usar contraseñas seguras, mantener los dispositivos actualizados y ser proactivos con la configuración de seguridad. En última instancia, la decisión de usar o no Amazon Sidewalk es personal. Es importante sopesar los beneficios potenciales de la comodidad y la conectividad con los riesgos potenciales para la privacidad y la seguridad.

PALABRAS CLAVE:

Dispositivos inteligentes; IoT; vulnerabilidades; seguridad; privacidad.

ABSTRACT

Amazon Sidewalk is a new feature that connects Amazon smart devices (like Echo and Ring) to each other and to neighbors' devices, creating a community internet network. While this can increase the connectivity and security of devices, it has also

raised privacy concerns. Privacy advocates point out that Amazon collects data on network usage and that devices automatically opt into the service without explicit user consent. Additionally, there are potential security vulnerabilities that could be exploited by malicious actors. It is important to be aware of the risks and benefits of IoT before using devices like Amazon Sidewalk. Users should take steps to protect their privacy, such as using strong passwords, keeping devices updated, and being proactive with security settings.

KEYWORDS.

Smart devices, IoT, vulnerabilities, security, privacy.

INTRODUCCIÓN

En el mundo actual, cada vez más dispositivos están conectados a Internet, lo que da lugar a la Internet de las cosas (IoT). Si bien esto ofrece comodidad y conveniencia, también genera preocupaciones sobre la privacidad y la seguridad (*Gartner. 2021, 3 de agosto*). Un ejemplo de esto es Amazon Sidewalk, una nueva función que conecta los dispositivos inteligentes de Amazon entre sí y con los de los vecinos para crear una red comunitaria de Internet (*Amazon. (2022)*).

Si bien Sidewalk tiene el potencial de mejorar la conectividad y la seguridad de los dispositivos, ha sido criticado por sus posibles riesgos de privacidad. Los defensores de la privacidad (*Centro de Información de Privacidad Electrónica. 2021*), señalan que Amazon recopila datos sobre el uso de la red y que los dispositivos se optan automáticamente por el servicio sin el consentimiento explícito del usuario (*Electronic Frontier Foundation. 2021, 22 de junio*). Además, existen posibles vulnerabilidades de seguridad que podrían ser explotadas por actores maliciosos.

Este artículo explora los riesgos y beneficios de IoT, utilizando Amazon Sidewalk como ejemplo. También proporciona consejos sobre cómo usar dispositivos IoT de manera segura y proteger su privacidad.

Puntos clave:

Amazon Sidewalk es una nueva función que conecta dispositivos inteligentes de Amazon para crear una red comunitaria de Internet.

- Si bien Sidewalk ofrece beneficios potenciales, también ha generado preocupaciones sobre la privacidad y la seguridad.
- Es importante ser consciente de los riesgos y beneficios de IoT antes de usar dispositivos como Amazon Sidewalk.

- Los usuarios deben tomar medidas para proteger su privacidad, como usar contraseñas seguras, mantener los dispositivos actualizados y ser proactivos con la configuración de seguridad.

En este artículo, discutiremos:

- Los pros y contras de Amazon Sidewalk
- Los riesgos y beneficios generales de IoT
- Consejos para usar dispositivos IoT de manera segura
- La amenaza de los ataques DDoS y cómo se relacionan con IoT (*Wikipedia, 2024. Ataques DDoS*)

Esperamos que este artículo le brinde una mejor comprensión de IoT y cómo usarlo de manera responsable.

MATERIALES Y MÉTODOS

Para llevar a cabo esta investigación, se utilizarán los siguientes materiales:

- Este artículo servirá como base fundamental para la investigación, proporcionando información esencial sobre Amazon Sidewalk, sus características, funcionamiento y las implicaciones que conlleva.
- Fuentes adicionales: Se consultarán fuentes adicionales relevantes para obtener una perspectiva más amplia del tema. Estas fuentes pueden incluir:
 - Artículos de noticias: Se revisarán artículos de noticias de fuentes confiables para obtener información actualizada sobre Amazon Sidewalk, sus desarrollos recientes y las opiniones de expertos y usuarios.
 - Informes de investigación: Se analizarán informes de investigación de organizaciones académicas, gubernamentales y de la industria para obtener datos y análisis en profundidad sobre los aspectos técnicos, sociales y económicos de Amazon Sidewalk.
 - Sitios web de organizaciones relevantes: Se consultarán los sitios web de organizaciones (*Pedro Santamaria, 2024*) que trabajan en temas relacionados con IoT, privacidad y seguridad para obtener información sobre las mejores prácticas, recomendaciones y posibles riesgos asociados con Amazon Sidewalk.

Para analizar los materiales recopilados y alcanzar los objetivos de la investigación, se emplearán los siguientes métodos:

- Análisis de contenido: Se realizará un análisis exhaustivo del artículo principal y las fuentes adicionales para identificar los temas principales,

argumentos, conclusiones y perspectivas relevantes. Se prestará especial atención a las discusiones sobre los riesgos y beneficios de Amazon Sidewalk, así como a las implicaciones para la privacidad y la seguridad.

- Síntesis de investigación: Se sintetizará la información obtenida de las diversas fuentes para crear una comprensión cohesiva y completa del tema. Esto implicará identificar puntos en común, discrepancias y tendencias clave en la investigación existente sobre Amazon Sidewalk.
- Evaluación crítica: Se evaluarán críticamente los argumentos y conclusiones presentados en el artículo principal y las fuentes adicionales. Esto implicará considerar la confiabilidad de las fuentes, la metodología utilizada y la validez de los hallazgos. Se identificarán posibles sesgos o limitaciones en la investigación existente.

RESULTADOS

- Se espera obtener una comprensión completa de las características técnicas de Amazon Sidewalk, incluyendo su funcionamiento, protocolo de comunicación, alcance y requisitos de seguridad.
- Se identificarán claramente los beneficios potenciales de Amazon Sidewalk, como la mejora de la conectividad de dispositivos IoT en áreas con cobertura limitada, la extensión de la duración de la batería de los dispositivos y la habilitación de nuevas aplicaciones y servicios.
- Se analizarán en profundidad los riesgos potenciales de Amazon Sidewalk, incluyendo las preocupaciones de privacidad y seguridad relacionadas con la recopilación y el uso de datos de ubicación y uso de dispositivos, la posibilidad de ataques cibernéticos (*Wikipedia, 2024. La botnet Mirai*) y la vulnerabilidad a la explotación por parte de actores maliciosos.

Análisis crítico de los impactos:

- Se evaluarán críticamente los impactos potenciales de Amazon Sidewalk en la privacidad individual, la seguridad cibernética y la sociedad en general.
- Se examinarán las implicaciones de Amazon Sidewalk para la vigilancia gubernamental, la discriminación algorítmica y la concentración de poder en manos de grandes empresas tecnológicas.
- Se considerarán las perspectivas éticas y sociales relacionadas con el uso de Amazon Sidewalk (*Amazon 2022*), incluyendo la autonomía individual, la equidad y la responsabilidad.

Recomendaciones para consumidores:

- Se elaborarán recomendaciones prácticas para los consumidores sobre cómo usar dispositivos IoT, como Amazon Sidewalk (*UAD by Hispasec. 2021, 2 de junio*), de manera segura y responsable.
- Se proporcionarán consejos sobre cómo proteger la privacidad y la seguridad al usar Amazon Sidewalk, incluyendo la selección de configuraciones de seguridad adecuadas, la limitación de la recopilación de datos y el uso de prácticas de seguridad sólidas.
- Se discutirán alternativas a Amazon Sidewalk que puedan ofrecer una mejor protección de la privacidad y la seguridad, o que satisfagan mejor las necesidades específicas de los usuarios.

Contribución al conocimiento:

- La investigación proporcionará una visión general completa y actualizada de Amazon Sidewalk, sus características, riesgos y beneficios.
- Se ofrecerá un análisis crítico de los impactos potenciales de Amazon Sidewalk en la privacidad, la seguridad y la sociedad.
- Se generarán recomendaciones prácticas para los consumidores sobre cómo usar dispositivos IoT de manera segura y responsable.
- La investigación contribuirá a un debate informado sobre el futuro de IoT y su impacto en la sociedad.

Además de los resultados mencionados anteriormente, la investigación también puede arrojar luz sobre:

- Las opiniones y actitudes del público sobre Amazon Sidewalk.
- Las prácticas de las empresas tecnológicas en cuanto a la recopilación, el uso y la protección de datos de IoT.
- Los esfuerzos regulatorios y de políticas públicas relacionados con IoT y la privacidad.
- Las oportunidades y desafíos para el desarrollo responsable de tecnologías IoT.

En general, la investigación propuesta tiene el potencial de proporcionar un conocimiento valioso sobre Amazon Sidewalk y su impacto en la sociedad. Los resultados de la investigación pueden ser utilizados por consumidores, empresas, legisladores y otros interesados para tomar decisiones informadas sobre el uso y la regulación de IoT.

CONCLUSIÓN

Amazon Sidewalk presenta una propuesta innovadora para mejorar la conectividad de dispositivos IoT en áreas con cobertura limitada. Si bien ofrece beneficios

potenciales como la extensión de la duración de la batería y la habilitación de nuevas aplicaciones, también genera preocupaciones sobre la privacidad y la seguridad.

Privacidad: La recopilación y el uso de datos de ubicación y uso de dispositivos por parte de Amazon Sidewalk plantean interrogantes sobre la vigilancia y la discriminación algorítmica. Los consumidores deben ser conscientes de las prácticas de datos de Amazon y tomar medidas para proteger su privacidad.

Seguridad: La posibilidad de ataques cibernéticos y la vulnerabilidad a la explotación por parte de actores maliciosos son riesgos asociados con Amazon Sidewalk. Es crucial implementar medidas de seguridad sólidas, como contraseñas seguras y actualizaciones regulares, para mitigar estos riesgos (*Sensity. 2021, 12 de julio*).

Responsabilidad: Las grandes empresas tecnológicas como Amazon tienen la responsabilidad de desarrollar e implementar tecnologías IoT de manera ética y responsable *Forbes. (2021, 24 de junio)*. Es necesario un mayor escrutinio regulatorio y marcos de políticas para garantizar que la privacidad y la seguridad de los usuarios estén protegidas.

Recomendaciones:

- **Consumidores:** Investigar dispositivos IoT, elegir aquellos con seguridad robusta, utilizar contraseñas seguras, mantener el software actualizado, ser proactivo con la configuración de seguridad y considerar desactivar funciones inteligentes cuando sea necesario.
- **Empresas:** Desarrollar e implementar tecnologías IoT de manera ética y responsable, priorizar la privacidad y la seguridad, ser transparentes en las prácticas de datos y colaborar con reguladores y expertos.
- **Reguladores:** Establecer marcos de políticas claros para la privacidad y la seguridad de IoT, supervisar las prácticas de las empresas tecnológicas y hacer cumplir las regulaciones (*Instituto Nacional de Estándares y Tecnología. 2022*).

En definitiva, Amazon Sidewalk representa una innovación tecnológica con un potencial significativo tanto para el bien como para el mal. Es crucial un enfoque equilibrado que aproveche sus beneficios mientras se mitigan sus riesgos. *Gadget Dominicana.com (2024, 04 de abril)*. La colaboración entre consumidores, empresas y reguladores es esencial para garantizar un futuro de IoT responsable y seguro.

REFERENCIAS BIBLIOGRÁFICAS

- Amazon (2022). **Consideraciones éticas y sociales de la tecnología Amazon Sidewalk: Un análisis crítico.** <https://www.amazon.com/Amazon-Sidewalk/b?ie=UTF8&node=21328123011>
- Amazon. (2022). *El impacto de Amazon Sidewalk en la conectividad de dispositivos IoT en áreas con cobertura limitada: Un estudio de caso.* <https://www.amazon.com/Amazon-Sidewalk/b?ie=UTF8&node=21328123011>
- Centro de Información de Privacidad Electrónica. (2021). *Amazon Sidewalk.* <https://epic.org/>
- Electronic Frontier Foundation. (2021). *Amazon Sidewalk.* <https://www.eff.org/deeplinks/2021/06/understanding-amazon-sidewalk>
- Electronic Frontier Foundation. (2021, 22 de junio). *Entendiendo la acera de Amazon* <https://www.eff.org/deeplinks/2021/06/understanding-amazon-sidewalk>
- Electronic Frontier Foundation. (2022). *Amazon Sidewalk: Una evaluación de la privacidad y la seguridad en la red mesh.* <https://www.eff.org/issues/security>
- Forbes. (2021, 24 de junio). *Amazon Sidewalk: ¿La red mesh definitiva o una pesadilla para la privacidad?* <https://www.forbes.com/sites/zakdoffman/2020/11/25/why-you-should-stop-dangerous-update-to-amazon-echo-speakers-and-ring-cameras-using-alexa-app/>
- Gadget Dominicana.com (2024, 04 de abril). *La próxima amenaza a tu privacidad es Amazon Sidewalk ¿Qué es y por qué debería desactivarlo?* <https://gadgetdominicana.com/2024/04/la-proxima-amenaza-a-tu-privacidad-es-amazon-sidewalk-que-es-y-por-que-deberia-desactivarlo/>
- Gartner. (2021, 3 de agosto). *El impacto de Amazon Sidewalk en la conectividad y la privacidad de IoT.* <https://www.gartner.com/document/3989487>
- Instituto Nacional de Estándares y Tecnología. (2022). *Internet de las cosas (IoT).* <https://www.nist.gov/internet-things-iot>
- Santamaria, P. (2024). *El Output.com* <https://eloutput.com/productos/domotica/sidewalk-red-amazon-compartir-wifi/>

Sensity. (2021, 12 de julio). *La seguridad de Amazon Sidewalk: Un análisis técnico*. <https://www.sensity.com/seguridad-amazon-sidewalk>

UAD by Hispasec. (2021, 2 de junio). *Amazon Sidewalk: ¿Una nueva amenaza a la privacidad?* <https://unaaldia.hispasec.com/2021/06/sidewalk-la-funcionalidad-con-la-que-tus-dispositivos-de-amazon-comparten-wifi-con-dispositivos-de-desconocidos.html>

Wikipedia (2024). **Ataques DDoS: ¿Qué son y cómo protegerse?**
https://es.wikipedia.org/wiki/Ataque_de_denegaci%C3%B3n_de_servicio

Wikipedia (2024). **La botnet Mirai: Un caso de estudio de un ataque DDoS devastador**. https://es.wikipedia.org/wiki/Mirai_%28malware%29

Uso de prototipo de generación de energía eólica; como método de aprendizaje alternativo de las Leyes de Lenz y Faraday

Use of a prototype for the generation of eolic energy, as an alternative learning method of Lenz and Faraday laws

Javier Fernández Pájaro
Universidad de Panamá, Panamá
Javier.fernandez@up.ac.pa <https://orcid.org/0009-0009-4659-0476>

Denis E. Rubin Edwards
Universidad de Panamá, Panamá
denis.rubin@up.ac.pa <https://orcid.org/0009-0003-0092-5046>

Recibido: 21-2-2023, Aceptado: 21-3-2024

DOI <https://doi.org/10.48204/3072-9696.6363>

RESUMEN

En la actualidad son varias las técnicas utilizadas para generar energía eléctrica, fundamentadas principalmente en las leyes de Lenz y Faraday vinculadas a la generación de energía eléctrica, por lo antes expuesto este ensayo genera una metodología de aprendizaje alternativa, la cual permite al estudiante comprender desde sus experiencias los fundamentos teóricos relacionados con todo el proceso de generación, almacenamiento y distribución de energía eléctrica, para ello se construye un prototipo de generador eólico experimental utilizando imanes, una bobina y un diodo LED, que demuestra la generación de energía eléctrica a través de la rotación de los imanes y la inducción electromagnética.

PALABRAS CLAVES:

Educación, Teoría electromagnética, Generadores eléctricos, Generador eléctrico experimental, Almacenamiento de energía.

ABSTRACT

Nowadays there are several techniques used to generate electrical energy, based mainly on Lenz and Faraday laws related to the generation of electrical energy, for the reasons stated above this essay generates an alternative learning methodology, which allows the student to understand from their experiences the theoretical foundations related to the entire process of generation, storage and distribution of electrical energy, to achieve this purpose a prototype is built using the air force to generate electricity using magnets, a coil and an LED, which demonstrates the generation of electrical energy through the rotation of magnets and electromagnetic induction.

**KEY WORDS:**

Education, Electromagnetic theory, Power generators, Experimental electric generator, Energy storage.

INTRODUCCIÓN

Esta propuesta tiene entre sus objetivos, aportar al sistema educativo un método alternativo para la demostración de las leyes de Lenz y Faraday, en términos generales es demostrar de manera práctica los fundamentos teóricos que a diario se ofrece a los estudiantes (Guisasola, 1996).

Los molinos de viento siguen siendo empleados para bombear agua desde el subsuelo, y desde hace más de 5 décadas se utilizan como motores para accionar generadores eléctricos (Domínguez, A. B, 2010).

Las leyes aplicadas al desarrollo de los generadores de potencia ofrecen diversas alternativas que permiten diseñar distintos equipos generadores de energía (Arraña, 2021). Estos equipos son esenciales para demostrar los fundamentos teóricos. Este ensayo pretende despertar el interés del lector por el debate de las teorías electromagnéticas y sus aplicaciones.

MARCO TEÓRICO

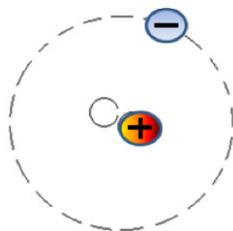
La teoría electromagnética desde el punto de vista de la física es una ciencia compleja, requiere para su comprensión de un profundo análisis matemático para demostrar la generación de energía. Con las leyes básicas de la física se puede explicar la teoría del campo magnético (Michael Faraday en la primera mitad del siglo XIX).

Este ensayo tiene la finalidad de demostrar de manera sencilla pero contundente el principio de la generación eléctrica. Este principio puede ser utilizado en la construcción de un Generador Eléctrico experimental impulsado por la fuerza del viento; Ahora bien, este principio lo aplicó (Faraday), dando como resultado que un campo magnético cambiante puede inducir una corriente eléctrica en un conductor cercano. Este ensayo es una propuesta académica, para facilitar la comprensión de los fundamentos electromagnéticos e iniciar el desarrollo de tecnologías propias, además el proceso de impartir conocimiento debe ir acompañado de demostraciones prácticas.

Este ensayo inicia con la descripción de la partícula del átomo que se encuentra en todos los materiales que nos rodean (John Dalton, siglo XIX). Es esta composición el fundamento del presente ensayo.

Figura 1

Estructura Atómica (Ernest Rutherford, 1911)



La estructura atómica, está formado por tres partículas electrón, protón y neutrón. Estas se caracterizan por estar eléctricamente cargadas, el electrón con cargas negativas (-) circula alrededor del núcleo, el protón con cargas positivas (+) se encuentra en el núcleo al igual que el neutrón con cargas neutras (J.J. Thomson en 1897).

Según John Dalton, siglo XIX, los átomos están presentes en todos los materiales que nos rodean. Los átomos están cargados eléctricamente con las mismas polaridades y que al distinguir las cargas que estos mayoritariamente poseen, tienen comportamientos distintos, por lo que de su interacción según la *ley de Coulomb de 1785*, son atraídos o repelen entre sí con una fuerza que es directamente proporcional al producto de sus cargas e inversamente proporcional al cuadrado de la distancia que las separa. Esto se representa la siguiente expresión matemática:

$$F = K \frac{q_1 q_2}{d^2}, \quad (\text{ecuación 1})$$

Donde,

F - es la fuerza de atracción o repulsión, expresada en newtons.

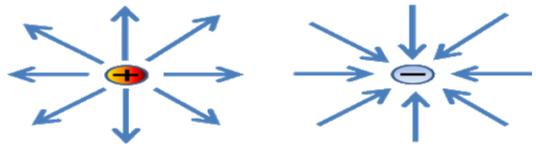
q₁, q₂ - son las cargas de los cuerpos, expresados en coulombios.

d - es la distancia entre ellos, expresados en metros.

K - es una constante de proporcionalidad que depende del medio en el que estén inmerso los cuerpos.

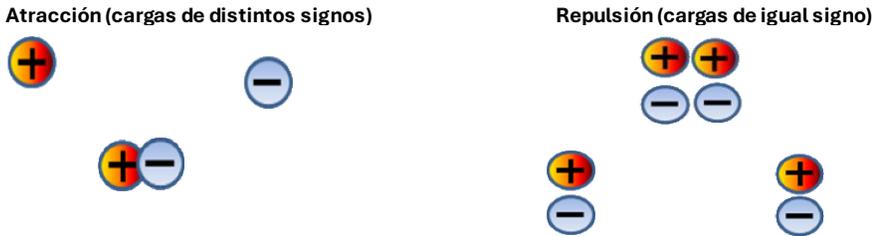
Figura 2

Proceso de Atracción y Repulsión de la Cargas. (Coulomb de 1785)



Este fenómeno es posible debido a que alrededor de las cargas existe un denominado campo eléctrico y al introducir otra carga según Coulomb la primera se afectara porque de esta salen o entran en forma de líneas, campos eléctricos, dependiendo de la polaridad de las cargas.

Figura 3
Disposición de las Líneas de Fuerza del Campo Eléctrico



El campo eléctrico (James Clerk Maxwell, el siglo XIX), que se muestra en la figura 3, se describe según la siguiente ecuación. (Charles-Augustin de Coulomb, siglo XVIII):

$$E = \frac{F}{q} \quad \text{(ecuación 2)}$$

expresión de la ley de la fuerza eléctrica en presencia de un campo eléctrico, donde la fuerza eléctrica es igual a la carga multiplicada por la intensidad del campo eléctrico. y refleja el punto en que la fuerza actúa sobre la unidad de carga.

Cuando se encuentran dos cargas eléctricas las líneas inician en las cargas positivas y terminan en las negativas, eléctricamente hablando unas entran y otras salen de la carga, además de que el número de líneas de fuerza debe ser proporcional a la carga y estas nunca se cortan.

Veamos el dispositivo construido para comprender con claridad el cálculo de las fuerzas del campo eléctrico, para lo cual inicialmente hablemos un poco de la corriente eléctrica, no es más que el desplazamiento de los electrones a través de un material conductor que se mueven siempre del polo (-) al polo (+) de la fuente.



Aunque convencionalmente se ha tomado que la circulación de la corriente eléctrica ocurre del polo (+) al polo (-), criterio que se toma debido a que en la época en que se determinó el sentido del recorrido de la corriente eléctrica por los conductores no se sabía que existían los electrones, aunque en la práctica, ese error no influye para nada en lo que al estudio de la corriente eléctrica se refiere.

Concepto de bobinas

Una bobina es un elemento constituido por un arrollamiento alrededor de un núcleo. Esta se representa esquemáticamente como se muestra en la figura. 4. Y su unidad de medida es el Henry, la cual se representa con la letra H (Vega, 2015).

Figura 4.

Simbología de una bobina



Características

La bobina se caracteriza por su capacidad de almacenar energía en forma de campo magnético.

Un conductor simple por el que circula una corriente tiene a su alrededor un campo magnético generado por la corriente que lo atraviesa, siendo el sentido de flujo del campo magnético el que establece la ley de la mano derecha.

En el contexto de un conductor con corriente eléctrica y un campo magnético externo, la ley de la mano derecha establece que si colocas el pulgar de tu mano derecha en la dirección de la corriente eléctrica y los dedos en la dirección del campo magnético, entonces el dedo extendido restante apuntará en la dirección de la fuerza magnética que actúa sobre el conductor. (Boylestad, R. L. & Nashelsky, L., 2018).

Al estar la bobina hecha de espiras, el campo magnético circula por el centro de la bobina y cierra su camino por su parte exterior, formando así lo que conocemos como la característica fundamental de un circuito eléctrico (Cabanillas, 2019).

Otras características de las bobinas es que se oponen a los cambios bruscos de la corriente que circula por ellas. Esto significa que a la hora de modificar la corriente que circula por ellas, esta tratará de mantener su condición anterior, fundamento que utilizaremos para la construcción de una fuente de energía limpia.



Las bobinas se miden en Henrios (**H**) y por comodidad cuando estas poseen valores muy pequeños hacemos usos de los prefijos numéricos mili, micro, etc.

El valor una bobina depende de:

1. El número de espiras que tenga la bobina (a más vueltas mayor inductancia, o sea mayor valor en Henrios).
2. El diámetro de las espiras (a mayor diámetro, mayor inductancia, o sea mayor valor en Henrios).
3. La longitud del cable de que está hecha la bobina.
4. El tipo de material de que esta hecho el núcleo si es que lo tiene.

Aplicaciones

Entre las aplicaciones que tienen las bobinas:

- a. La más común es que de un par de bobinas podemos construir los
- b. transformadores cuya función es la reducir o elevar el Voltaje.
- c. En los sistemas de iluminación con tubos fluorescentes existe un elemento adicional que acompaña al tubo y que comúnmente se llama reactor.
- d. En las fuentes de potencia eléctrica de corriente directa también se usan
- e. bobinas para filtrar las componentes de corriente alterna y separar la componente de corriente directa que se refleja a la salida.
- f. También son utilizadas con la finalidad de utilizar su campo magnético para la generación de energía, activación de interruptores mecánicos y otros.

MATERIALES Y MÉTODOS

Materiales

- 2 imanes cóncavos
- Material aislante
- Sunchos o correa plástica
- 30mts de conductor calibre 28
- 1 clavo de 15 cm
- Pegamento silicon
- 1 diodo LED verde o rojo

Métodos

Se conecta los dos imanes al encuentro, pero separados entre sí por un dieléctrico, de tal forma que las líneas del campo eléctrico deberán moverse como se ha descrito arriba, para que quede claro veamos la figura 5.

En el prototipo la conexión de los imanes se observa en la figura 5.a y una vez aislados se fijan para evitar el desacomodo, cuando el prototipo se encuentre en movimiento.

Figura 4

- a. Disposición de los imanes en nuestro prototipo. b. Símil de la disposición de las fuerzas del campo eléctrico.

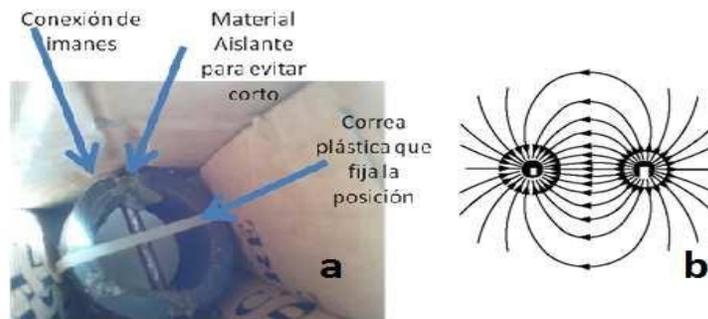


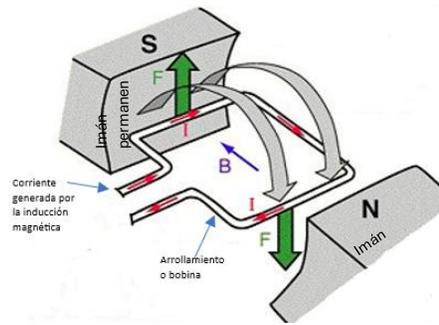
Figura 5

Disposición de la Bobina del Prototipo



Figura 6

Diagrama pictórico, funcionamiento del prototipo



Luego se procede con la construcción de la bobina, dándole vueltas circulares sobre el material que aísla los imanes de esta, el prototipo se muestra en la figura 6 y está compuesta de un conductor aislado calibre 28 de aproximadamente 30 m de longitud, lo cual hace alrededor de la carcasa 250 vueltas aproximadamente con un diámetro de alrededor de 10cm.

Luego se realiza la conexión de los extremos de la bobina un dispositivo luminoso (LED), que detecta la generación de energía del prototipo o la inducción de las líneas de fuerza de los imanes en la bobina, o desplazamiento de los electrones a través de esta. Por último, tal como se observa en la *figura 8*. se coloca el clavo de hierro atravesando el material aislante, en forma de eje, que permite girar los imanes de manera tal que las líneas de fuerza del campo al inducirse en las bobinas puedan aumentar la intensidad de la corriente, al incrementar la velocidad de rotación de esta.

Figura 7

Eje metálico



Armado el dispositivo procedimos a realizar las pruebas respectivas.

DISCUSIÓN

La velocidad de rotación es aproximadamente de 10 vueltas por segundo.



Un diodo emisor de luz (LED), por sus siglas en inglés “*Light Emitting Diode*”, es un dispositivo semiconductor que permite el paso de la corriente eléctrica una vez superado el voltaje de umbral que 0,7 V siendo silicio el material de construcción, de la hoja de datos se conoce que los niveles de voltaje mínimos para encender el diodo LED de color verde inicia desde los 2,5 V. Con esta información podemos determinar el valor mínimo de voltaje generado por la bobina, esto si se logra el encendido del LED una vez en funcionamiento el montaje, entonces se puede deducir que por cada vuelta del aparato construido sobre su eje, la bobina produce alrededor de 10mV con los imanes utilizados, de los cuales no se tiene las características del campo magnético que generan, pero el campo generado es suficiente para encender un LED, por lo tanto la teoría arriba indicada queda demostrada (Gonçal, 2006).

Además, se realizó otra prueba a diferentes velocidades, pero sin poder medirlas, utilizando un drill de velocidad variable, aumentamos la velocidad de rotación y el brillo de la luz emitida por el diodo era más intenso, comprobando variación en el flujo magnético que atraviesa la bobina. (Heinrich Lenz en 1834).

La ley de Lenz establece que la corriente inducida en un circuito cerrado siempre será tal que su campo magnético se opondrá al cambio de campo magnético que la induce.

Esta ley se basa en la conservación de la energía, ya que el trabajo realizado para inducir la corriente se convierte en energía eléctrica en el circuito.

La ley de Lenz es una consecuencia de la ley de Faraday, ya que la bobina inducida produce una fuerza electromotriz, denominada FEM, misma que se determina a través de la ley de Faraday.

$$\varepsilon = -N \frac{d\phi}{dt} \quad (\text{ecuación 3})$$

Donde:

ε - *f.e.m. inducida*

N - *número de espiras de la bobina*

$d\Phi_B$ - *Variación del flujo*

dt - *Tiempo en que se produce la variación de flujo.*

CONCLUSIÓN

El prototipo desarrollado para generar electricidad a partir del viento y la inducción de magnetismo mediante el giro de los imanes ha demostrado ser una solución prometedora. A lo largo del ensayo, se ha evidenciado que la energía eólica, una



fuentes renovables y abundantes, pueden ser aprovechadas de manera eficaz mediante el diseño y la implementación de sistemas de generación de energía (Ovejero, 2007).

Más allá de su impacto tecnológico, este proyecto ha resaltado su valor como un método de aprendizaje alternativo. La construcción y experimentación con el prototipo permite a los participantes de una manera integrada aplicar los conocimientos teóricos, esto a su vez, permite tener una visión mucho más amplia de los principios de las leyes de Lenz y Faraday en el campo del electromagnetismo, ya que también se desarrollan habilidades críticas en resolución de problemas, pensamiento crítico y trabajo en equipo.

En definitiva, la experimentación y el desarrollo de este prototipo no solo han proporcionado valiosos conocimientos técnicos y científicos, sino que también han demostrado el potencial del aprendizaje alternativo basado en proyectos. La combinación de teoría y práctica en un contexto realista es fundamental para la formación de futuros profesionales capaces de enfrentar los desafíos del mundo actual, especialmente en la transición hacia un futuro energético más sostenible.

REFERENCIAS BIBLIOGRÁFICAS

- Arraña, I., Marino, E., Bertinat, P., Salerno, J., Chemes, J., Barone, M., & Saenz, J. (2021). *Estado del arte en el desarrollo de pequeños generadores eólicos*. *Avances En Energías Renovables Y Medio Ambiente - AVERMA*, 16, 41–48. Recuperado a partir de <https://portalderevistas.unsa.edu.ar/index.php/averma/article/view/2161>
- Boylestad, R. L., & Nashelsky, L. (Eds.). (2018). *Teoría de Circuitos y Dispositivos Electrónicos*. Ed. Pearson Prentice Hall
- Cabanillas, C., Valdez, L., Merino, C.; Cabrera, C.; Bentz, E., Pisarello, M., Provasi, P. (2019). *Campo magnético de una espira circular en un punto fuera del eje: análisis y enseñanza de las leyes de Faraday & Lenz y Biot & Savart*. Libro de resúmenes de la 104ª Reunión de la Asociación Física Argentina-CONICET DIGITAL,63. Recuperado a partir de <https://ri.conicet.gov.ar/handle/11336/130998#anchorAbstract>
- Domínguez, A. B. (2010). *Generadores eólicos de baja potencia: (ed.)*. ANI - Academia Nacional de Ingeniería. Recuperado a partir de <https://041020f6t-y-https-elibro-net.umip.metaproxy.org/es/ereader/umip/27291?page=7>

Gonçal Fernández Mills, J., & Julián Fernández Ferrer. (2006). *Teoría de Circuitos y Magnetismo*. Bogotá, Colombia: Edición UPC.

Guisasola, J. (1996): *Análisis crítico de la enseñanza de la electrostática en el Bachillerato y propuesta alternativa de orientación constructivista*. Tesis doctoral. Departamento de Física Aplicada. Universidad del País Vasco

Ovejero, M., Condorí, M. (2007). *Laboratorios sencillos para la enseñanza de las energías renovables en el nivel universitario básico*. *Avances en Energías Renovables y Medio Ambiente* Vol. 11, 2007., 39-46. Recuperado a partir de <https://sedici.unlp.edu.ar/handle/10915/93345>.

Vega Pérez, J. & Vega Pérez, S. (2015). *Electromagnetismo*: (ed.). Grupo Editorial Patria. Ciudad México, México