



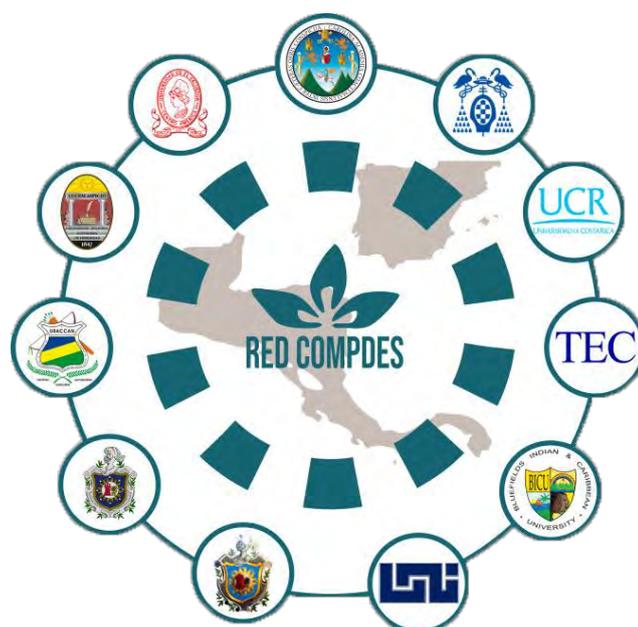
**COMPUTACIÓN  
PARA EL  
DESARROLLO  
XVII CONGRESO**

OBRAS COLECTIVAS  
TECNOLOGÍA 39

UAH

Luis Bengochea  
Daniel Meziat  
Luis E. Amaya  
(Editores)

# ***Computación para el Desarrollo XVII Congreso***



Obras Colectivas de Tecnología 39

*Luis Bengochea Martínez  
Daniel Meziat Luna  
Luis Eduardo Amaya Briceño  
(Editores)*

 **Universidad  
de Alcalá**

EDITORIAL  
UNIVERSIDAD DE ALCALÁ

# *Computación para el Desarrollo – XVII Congreso*

*Actas del XVII Congreso Iberoamericano de Computación para  
el Desarrollo (COMPDES 2024)*



**Universidad de Costa Rica (Sede de Guanacaste)  
Liberia (Costa Rica)  
17 al 19 de julio de 2024**

Editores:

Luis Bengochea Martínez (*Universidad de Alcalá - España*)

Daniel Meziat Luna (*Universidad de Alcalá – España*)

Luis Eduardo Amaya Briceño (*Universidad de Costa Rica*)



El libro “**Computación para el Desarrollo – XVII Congreso**” en el que se recogen las Actas del *XVII Congreso Iberoamericano de Computación para el Desarrollo (COMPDES2024)*, editado por Luis Bengochea, Daniel Meziat y Luis Eduardo Amaya, se publica bajo licencia Creative Commons 4.0 de reconocimiento – no comercial – compartir bajo la misma licencia. Se permite su copia, distribución y comunicación pública, siempre que se mantenga el reconocimiento de la obra y no se haga uso comercial de ella. Si se transforma o genera una obra derivada, sólo se puede distribuir con licencia idéntica a ésta. alguna de estas condiciones puede no aplicarse, si se obtiene el permiso de los titulares de los derechos de autor.

Editorial Universidad de Alcalá  
Plaza de San Diego, s/n  
28801 Alcalá de Henares (España)

Marzo 2025  
ISBN: 978-84-10432-69-7

Edición digital

Diseño de la portada: *Fotografía secuencial de luces azules - 373543*  
Licencia <https://www.pexels.com/license/>

*Los contenidos de esta obra son responsabilidad exclusiva de sus autores y no reflejan necesariamente la opinión oficial de la Universidad de Alcalá, la Universidad de Costa Rica, ni de ninguna de las instituciones que han colaborado en la organización del congreso.*

## *Organización del Congreso*

El congreso está organizado por:

### **Universidad de Costa Rica – Sede Guanacaste (Costa Rica)**

La Universidad de Costa Rica es una institución de educación superior y cultura, autónoma constitucionalmente y democrática, constituida por una comunidad de profesores y profesoras, estudiantes, funcionarias y funcionarios administrativos, dedicada a la enseñanza, la investigación, la acción social, el estudio, la meditación, la creación artística y la difusión del conocimiento.

La UCR aspira a ser una universidad pública referente en la educación superior internacional, inclusiva, innovadora, proactiva, sostenible y solidaria. Asimismo, se propone fortalecer la excelencia académica, la generación y la difusión del conocimiento, el diálogo de saberes con vocación transformadora, la internacionalización y la vinculación Universidad-Sociedad-Estado, siendo responsable y transparente en el uso de los recursos, a fin de promover la movilidad social ascendente, la búsqueda del bien común y el desarrollo territorial y nacional. [<https://www.ucr.ac.cr/>]

### **Universidad de Alcalá (España)**

Fue fundada en 1499 como avanzada en España de las corrientes renacentistas y humanistas de Europa. Durante los siglos XVI y XVII se convirtió en el gran centro de excelencia académica: en sus aulas enseñaron y estudiaron grandes maestros como Nebrija, Tomás de Villanueva, Ignacio de Loyola, Domingo de Soto, Juan de Mariana, Juan de la Cruz, Lope de Vega, Quevedo, etc. El prestigio de sus estudios, así como de sus maestros y sus constituciones fundacionales, sirvieron como modelo sobre el que se constituyeron las nuevas Universidades en América. En la actualidad es una Universidad moderna de tamaño medio con un Parque Científico y Tecnológico e importantes líneas de investigación, que la convierten en un elemento dinamizador de la actividad en la región y de gran proyección internacional. En 1998 fue declarada Patrimonio de la Humanidad por la UNESCO. [<https://www.uah.es/>]

### **Red COMPDES**

Red Universitaria de Computación para el Desarrollo, formada por las siguientes universidades: Universidad Nacional Autónoma de Nicaragua – León (UNAN-León), Universidad de El Salvador (UES), Universidad Nacional de Ingeniería – Nicaragua (UNI), Universidad Nacional Autónoma de Nicaragua – Managua (UNAN-Managua), Bluefields Indian and Caribbean University (BICU), Tecnológico de Costa Rica (TEC), Universidad de las Regiones Autónomas de la Costa Caribe Nicaragüense (URACCAN), Universidad de San Carlos de Guatemala (USAC), Universidad Nacional Autónoma de Honduras (UNAH), Universidad de Costa Rica (UCR) y Universidad de Alcalá – España (UAH). [<https://www.compdes.org/>]



## Comité Científico

Meziat Luna, Daniel. *Universidad de Alcalá (España)* – Presidente

Amaya Briceño, Luis Eduardo. *Universidad de Costa Rica*

Arco, José Manuel. *Universidad de Alcalá (España)*

Bengochea, Luis. *Universidad de Alcalá (España)*

Calero, Coral. *Universidad de Castilla-La Mancha (España)*

Carballo Ruiz, Elmer Arturo. *Universidad de El Salvador*

de la Fuente, Pablo. *Universidad de Valladolid (España)*

de la Mata Moratilla, Sergio. *Universidad de Alcalá (España)*

de Vicente Rodríguez, Antonio J. *Universidad de Alcalá (España)*

Díaz, Bladimir. *Universidad de El Salvador*

Domínguez Alda, M<sup>a</sup> José. *Universidad de Alcalá (España)*

Fernández del Castillo, José Raúl. *Universidad de Alcalá (España)*

García Astete, Margarita. *Universidad de La Serena (Chile)*

García Herráiz, Antonio. *Universidad de Alcalá (España)*

González Enríquez, José. *Universidad de Sevilla (España)*

Guasch, Daniel. *Universitat Politècnica de Catalunya (España)*

Gutiérrez Martínez, José María. *Universidad de Alcalá (España)*

Gutiérrez de Mesa, José Antonio. *Universidad de Alcalá (España)*

Hernández Ramírez, Oscar Guillermo. *Universidad Nacional Autónoma de Honduras*

Jaillier, Erika. *Universidad Pontificia Bolivariana (Colombia)*

López Poveda, Anayanci. *Universidad Nacional de Ingeniería (Nicaragua)*

López Quiroa, Christian Alberto. *Universidad de San Carlos (Guatemala)*

López Villegas, Óscar. *Instituto Tecnológico de Costa Rica*

Mejía, Guillermo. *Universidad de El Salvador*

Oyarzo, Jaime. *Universidad de Alcalá (España)*

Palma Mendoza, Raúl José. *Universidad Nacional Autónoma de Honduras*

Población, Óscar. *Universidad de Alcalá (España)*

Restrepo Bustamante, Félix Andrés. *Universidad de Santander (Colombia)*

Romero Peláez, Audrey. *Universidad Técnica Particular de Loja (Ecuador)*

Sambola, Dexon. *Bluefields Indian and Caribbean University (Nicaragua)*

Sánchez Prieto, Sebastián. *Universidad de Alcalá (España)*

Sarasa Cabezuelo, Antonio. *Universidad Complutense de Madrid (España)*

Vegas, Jesús. *Universidad de Valladolid (España)*

Velasco, Juan Ramón. *Universidad de Alcalá (España)*



## **Comité Organizador**

Beyker Obando, *Universidad de Costa Rica - Presidente*

Luis Eduardo Amaya Briceño, *Universidad de Costa Rica*

Luis Fernando Charpentier, *Universidad de Costa Rica*

Hazel Bustos, *Universidad de Costa Rica*

Óscar López, *Tecnológico de Costa Rica*

Daniel Meziat, *Universidad de Alcalá (España)*

Luis Bengochea, *Universidad de Alcalá (España)*

## **Comisión permanente Red COMPDES**

López Villegas, Óscar *Tecnológico de Costa Rica (Costa Rica)*

Meziat Luna, Daniel *Universidad de Alcalá (España)*

Bengochea Martínez, Luis *Universidad de Alcalá (España)*

## **Representantes de la Red COMPDES**

López Villegas, Oscar. *Tecnológico de Costa Rica – Presidente*

Meziat Luna, Daniel. *Universidad de Alcalá (España) – Presidente de Honor*

Alarcón, Francisco. *Universidad de El Salvador*

Amaya, Luis Eduardo. *Universidad de Costa Rica*

Bárceñas Lezama, Miguel Ángel. *UNAN – León (Nicaragua)*

Bengochea Martínez, Luis. *Universidad de Alcalá (España)*

Carol Hernández, Víctor. *CUNOC-USAC (Guatemala)*

Contreras Mercado, Arnoldo José. *UNAN-León (Nicaragua)*

Chávez Mairena, Luis Eduardo. *Universidad Nacional de Ingeniería (Nicaragua)*

Chicas, Rudy. *Universidad de El Salvador*

Esquivel Vega, Gaudy. *Tecnológico de Costa Rica*

Gross, Eduardo. *Universidad Nacional Autónoma de Honduras*

Juárez, Nelson. *Universidad Nacional de Ingeniería (Nicaragua)*

López, Christian. *CUNOC-USAC (Guatemala)*

López, Roy. *Bluefields Indian & Caribbean University (Nicaragua)*

López Poveda, Anayanci. *Universidad Nacional de Ingeniería (Nicaragua)*

Mejía Quiroz, Álvaro. *UNAN-Managua (Nicaragua)*

Palma Mendoza, Raúl. *Universidad Nacional Autónoma de Honduras*

Portillo, Julio. *Universidad de El Salvador*

Sambola, Dexon-Mckensy. *Bluefields Indian & Caribbean University (Nicaragua)*

Sánchez, José María. *Universidad de El Salvador*

Sierra Pac, Oliver. *CUNOC-USAC (Guatemala)*

Vásquez, Rodrigo. *Universidad de El Salvador*



## *Prólogo*

En este año 2024, el Congreso COMPDES2024 se ha celebrado en modalidad presencial y virtual, bajo la organización de la Universidad de Costa Rica, una institución de educación superior reconocida por su autonomía constitucional, su carácter democrático y su compromiso con la enseñanza, la investigación, la acción social, la creación artística y la difusión del conocimiento.

La Red COMPDES, desde su fundación en 2006, ha fomentado la cooperación entre universidades de Centroamérica y España, incluyendo al Instituto Tecnológico de Costa Rica (ITCR), la Universidad de Costa Rica (UCR), la Universidad de El Salvador (UES), la Universidad de San Carlos de Guatemala (USAC), la Universidad Nacional Autónoma de Honduras (UNAH), así como varias instituciones en Nicaragua (UNAN-León, URACCAN, BICU, UNI-Managua y UNAN-Managua) y la Universidad de Alcalá en España (UAH). Su objetivo principal es impulsar el desarrollo de los países centroamericanos mediante sinergias de colaboración, el desarrollo de proyectos conjuntos y el intercambio de experiencias, con el Congreso anual como uno de sus principales pilares.

El Congreso COMPDES2024 ha sido un espacio invaluable para el intercambio académico e investigativo entre profesionales, académicos y estudiantes de Iberoamérica. Este foro ha permitido compartir inquietudes, publicaciones y avances en investigaciones relacionadas con aplicaciones informáticas y su impacto en sectores como la industria, la agricultura, los servicios y los recursos naturales. Así, las universidades de la Red COMPDES refuerzan sus principios fundamentales y comparten los resultados de sus investigaciones, fortaleciendo el conocimiento regional y global.

En esta XVII edición del Congreso, además de las líneas temáticas tradicionales, se han incorporado áreas de especial interés, tales como:

1. **Inteligencia artificial generativa:** Aplicaciones en educación y negocios, análisis de riesgos y oportunidades.
2. **DevOps:** Agilización y automatización de procesos, versionado de código y monitorización de infraestructura.
3. **Virtualización educativa:** Laboratorios virtuales, realidad virtual y realidad aumentada.
4. **Transformación digital:** Gobernanza de datos, comercio electrónico, revolución 5R y competencias digitales.
5. **Red 5G y tendencias futuras:** Internet de las cosas y tecnologías emergentes como Open RAN.
6. **Ética y responsabilidad social en computación:** Privacidad, responsabilidad algorítmica, impacto ambiental y ética en IA.
7. **Ciencias de datos:** Modelos predictivos, análisis de series de tiempo y herramientas para análisis y visualización de datos.

Este libro de actas presenta una selección destacada de las ponencias, junto con las reseñas de las tres conferencias magistrales que enriquecieron este encuentro. De los 38 trabajos

presentados, el comité científico, mediante un riguroso proceso de revisión por pares, seleccionó los 16 más sobresalientes para su publicación en esta obra.

Expresamos nuestro más sincero agradecimiento a los autores, revisores y conferencistas cuya dedicación y excelencia han hecho posible este libro, que refleja la relevancia y calidad académica de COMPDES2024. Su contribución no solo enriquece este Congreso, sino también el desarrollo del conocimiento en nuestra región.

Liberia (Costa Rica), julio de 2024

Oscar López Villegas  
Presidente de la Red COMPDES  
Tecnológico de Costa Rica  
[olopez@tec.ac.cr](mailto:olopez@tec.ac.cr)

# Índice de Contenidos

## **Prólogo**

*Óscar López Villegas* 8

## **Conferencias Invitadas**

Conferencia inaugural del Congreso: Ciencia de datos 13  
*Oldemar Rodríguez Rojas*

La inteligencia artificial en la educación disruptiva 14  
*Jaime Oyarzo Espinosa*

Desafíos y oportunidades para el mejor aprovechamiento de la Inteligencia Artificial en Centroamérica 15  
*Saúl Calderón Ramírez*

## **Ponencias**

Aprendizaje de Máquinas aplicado a la predicción de la radiación solar 17  
*Victor Daniel Gil-Vera and Catalina Quintero-López*

Predicción de precipitaciones en Madrid: modelos tradicionales de series temporales 21  
*Jesús Cáceres Tello and Jose Javier Galán Hernández*

Virtualización de procesos educativos: Entorno Gamificado Colaborativo en Telegram con Bots, NFC y QR 30  
*Sergio de la Mata Moratilla, Inés López Baldominos and Diego Ortiz Martínez*

Capacidades de liderazgo digital: resultados del análisis de un clúster de turismo en Costa Rica 37  
*Efraín Ortiz Pabón, Lady Fernández Mora and Nestor Armando Nova Arévalo*

Gestión de la continuidad de infraestructuras tecnológicas en la Industria 4.0. Contribución a la resiliencia de sistemas digitales 45  
*Francisco Vicente Poza, Jose María Gutiérrez Martínez and Salvador Otón Tortosa*

Computación cuántica y big data <i>Luzarait Cañas Quintero, Francisco Javier Moreno Arboleda and Jaime Alberto Guzmán Luna</i>	53
Conocimiento del impacto de la tecnología en el ambiente <i>Iyubanit Rodríguez and James Mcintosh</i>	62
Integration of a ChatGPT-based chatbot as a tool for optimizing administrative management processes at Inblen SA <i>Manuel Mojica and Walter Blandon</i>	67
Inteligencia artificial generativa, gestión y educación superior en México <i>Juan Jesus Vega Mejia, Juan Manuel Ramos Quiroz and Maria Del Carmen Trejo Cazares</i>	75
La inteligencia artificial y la auto publicación editorial con Amazon Kindle Direct Publishing <i>Jossué Henríquez</i>	83
Modelo de políticas de seguridad y gestión de la información, basados en la ISO 27001, aplicables a las Cooperativas de Ahorro y Crédito del municipio de San Vicente, departamento de San Vicente, El Salvador <i>Eliseo Eulises Romero Ayala</i>	87
Una Aplicación de la Metodología CRISP-DM para minería de datos. <i>Guillermo Mejia</i>	95
Análisis exploratorio de datos mediante Graphext: un caso de estudio <i>Fabio Garcia Ramirez</i>	103
BlitzSight: Un prototipo para la detección de objetos y paredes en entornos interiores utilizando realidad aumentada para personas con discapacidad visual <i>Martin Fuentes and Elyam López</i>	111
Desarrollo de una aplicación para la predicción y recomendación de tratamiento para el cáncer de vejiga <i>Antonio Sarasa Cabezuelo</i>	118
Aplicación de TICs para la Difusión de Información Climática y Meteorológica de las Estaciones del Centro Universitario de Occidente USAC <i>Christian Alberto López Quiroa</i>	126

# *Conferencias Invitadas*



## *Conferencia invitada*

### *Ciencia de datos*

Oldemar Rodríguez Rojas  
Universidad de Costa Rica

#### CONFERENCIANTE

Catedrático de la Universidad de Costa Rica y de la Universidad Nacional, es especialista en Matemática Aplicada e Informática.

Tiene un Doctorado en Ciencias del U.F.R. Mathématique de la Décision en la Universidad de París IX, una Maestría en Ciencias de la Computación del Instituto Tecnológico de Costa Rica y una Licenciatura en Matemática Pura de la Universidad de Costa Rica.

En 1985 inició su labor como profesor en la Escuela de Matemática de la UCR, donde se ha desempeñado, también, como investigador del Centro de Investigación en Matemática Pura y Aplicada (CIMPA); además, fue director del Programa de Maestría en Matemática y ocupó los cargos de Vicedecano y Decano de la Facultad de Ciencias.

También, ha desempeñado funciones en la Escuela de Informática de la Universidad Nacional, donde es docente desde 1995; fue profesor del Departamento de Matemática en el ITCR en 1989, director de Investigación de Predisoft Internacional S. A. y Gerente General de esta misma empresa (2003-2005).

El Dr. Rodríguez cuenta con una amplia experiencia en el desarrollo de sistemas de cómputo en el campo de la estadística matemática, ha realizado más de 50 publicaciones y gracias a su trabajo ha recibido múltiples distinciones, entre las que destacan el Premio "Clodomiro Picado Twilight", por su trabajo de investigación Classification et Modèles Linéaires en Analyse des Données Symboliques y el software "PIMAD-Symbolique y la condecoración con la Medalla de Oro para el Inventor Destacado del año 2004 de la Organización Mundial de Propiedad Intelectual (OMPI).

Desde el Consejo Universitario trabajó en la flexibilización de las políticas de investigación, promovió una reforma integral de las políticas de reconocimiento de títulos y materias, que permitiera una mayor integración de las universidades públicas, incentivó un mayor trabajo de fiscalización de este Órgano Colegiado y buscó el fortalecimiento de las sedes regionales, entre otras acciones.

## Conferencia invitada

# *La inteligencia artificial en la educación disruptiva*

Jaime Oyarzo Espinosa  
Universidad de Alcalá (España)  
jaime.oyarzo@uah.es

**Resumen** — Una de las razones de por la que la Inteligencia Artificial IA ha tenido un reducido impacto en la educación superior está relacionada con el retraso en la integración de nuevas tecnologías en la práctica educativa. La falta de voluntad para asumir riesgos o adoptar nuevas innovaciones, así como la falta de financiación para todo lo que se aparte de los métodos tradicionales de enseñanza, operan en contra de la adopción de nuevas tecnologías en la educación, el aprendizaje y el desarrollo.

Debemos considerar, además, que muchas de las aplicaciones de IA en la enseñanza y el aprendizaje se concentran en la presentación de contenidos y evaluación de la comprensión y entendimiento. Investigadores señalan que parte importante de la investigación y desarrollos de IA para la enseñanza y el aprendizaje es producto del trabajo de informáticos, no de educadores. No es extraño que estos desarrollos tienden a utilizar y reproducir modelos de aprendizaje basados en el funcionamiento de ordenadores o de redes informáticas, reproduciendo un modelo de aprendizaje muy conductista.

Esta conferencia explora y analiza los retos y oportunidades que presentan las tecnologías digitales y argumenta que los educadores deben adaptar sus estrategias de enseñanza para preparar a los estudiantes para la universidad y el mercado laboral del futuro. El análisis se basa en estudios de casos de prácticas educativas innovadoras y propone un replanteamiento de la profesión docente en la era digital.

### CONFERENCIANTE

Jaime Oyarzo Espinosa es un distinguido académico y experto en ciencias de la computación, actualmente asociado con la Universidad de Alcalá en España. Con una sólida formación académica y una notable trayectoria en investigación, el Dr. Oyarzo ha hecho contribuciones significativas en el campo de la tecnología y la innovación.

El Dr. Oyarzo ha centrado su investigación en áreas como la inteligencia artificial, el aprendizaje automático y la ingeniería de software. Sus trabajos han sido ampliamente publicados en revistas científicas y presentados en conferencias internacionales, consolidando su reputación como un investigador de alto calibre. Su enfoque en la aplicación práctica de teorías complejas ha llevado a avances importantes en su campo, beneficiando tanto a la academia como a la industria.

En su rol en la Universidad de Alcalá, Jaime Oyarzo Espinosa se dedica no solo a la investigación, sino también a la enseñanza y mentoría de estudiantes de diversas disciplinas tecnológicas. Su pasión por la educación y su compromiso con la formación de la próxima generación de científicos y profesionales tecnológicos son evidentes en su enfoque pedagógico y su participación activa en proyectos colaborativos.

Además de su labor académica, el Dr. Oyarzo es conocido por su capacidad para integrar conocimientos interdisciplinarios, facilitando así soluciones innovadoras a problemas complejos. Su correo electrónico de contacto es [jaime.oyarzo@uah.es](mailto:jaime.oyarzo@uah.es), donde está disponible para consultas y colaboraciones.

Jaime Oyarzo Espinosa es profesor Honorífico de Investigación Universidad de Alcalá, España, Profesor Maestría Cs Experimentales y Tecnología, Universidad Nacional de Córdoba, Argentina y miembro de la Cátedra UNESCO Educación Científica para América Latina y El Caribe EDUCALYC.

Es creador de los espacios web: Blog Inteligencia Artificial: <https://bit.ly/3U0BO1A> ; Blog eLearning: <https://jaimeoyarzo.blogspot.com> y Boletín de noticias eLearning <https://edunet.uah.es/wp/noticias/>

## *Conferencia invitada*

# *Desafíos y oportunidades para el mejor aprovechamiento de la Inteligencia Artificial en Centroamérica*

Saúl Calderón Ramírez  
PARMA-Group  
Instituto Tecnológico de Costa Rica

### CONFERENCIANTE

EL Dr. Saúl Calderón Ramírez es un destacado académico y profesional en el campo de la inteligencia artificial y el aprendizaje automático. Con una sólida formación en ciencias de la computación y una trayectoria impresionante en investigación y desarrollo tecnológico, el Dr. Calderón ha contribuido significativamente al avance de estas disciplinas en Costa Rica y más allá.

Es miembro activo del Pattern Recognition and Machine Learning Group (PARMA-Group) del Instituto Tecnológico de Costa Rica (TEC), donde ha liderado numerosos proyectos de investigación que abordan problemas complejos mediante técnicas avanzadas de reconocimiento de patrones y aprendizaje automático. Su trabajo no solo ha sido reconocido en la comunidad académica, sino que también ha tenido un impacto práctico en diversas industrias, desde la salud hasta la agricultura.

El Dr. Calderón ha publicado extensamente en revistas científicas y ha presentado sus investigaciones en conferencias internacionales de renombre. Además, es un ferviente defensor de la educación y la capacitación en tecnología, dedicando tiempo a enseñar y mentorizar a estudiantes en todos los niveles. Su pasión por la ciencia y la tecnología se refleja en su compromiso por fomentar el desarrollo del talento local y promover la adopción de tecnologías emergentes en la región.

# *Ponencias*



# *Aprendizaje de Máquinas aplicado a la predicción de la radiación solar*

## *Machine learning applied to solar radiation prediction*

Víctor Daniel Gil-Vera

Universidad Católica Luis Amigó (Colombia)

Grupo de Investigación SISCO

[victor.gilve@amigo.edu.co](mailto:victor.gilve@amigo.edu.co)

Catalina Quintero-López

Universidad Católica Luis Amigó (Colombia)

Grupo de Investigación en Neurociencias Básicas y Aplicadas

[catalina.quinterolo@amigo.edu.co](mailto:catalina.quinterolo@amigo.edu.co)

*Resumen* — El Machine Learning (ML) permite predecir la radiación solar en un lugar geográfico específico, lo cual facilita la ubicación estratégica de plantas de energía solar. El uso de este tipo de energía renovable fomenta la preservación ambiental, reduce la dependencia a fuentes de energía no renovables y la emisión de gases de efecto invernadero. Este trabajo tuvo como objetivo la construcción de un modelo predictivo de radiación solar, empleando la técnica de Regresión Lineal Múltiple (RLM) en el lenguaje de programación Python. El modelo obtuvo un buen desempeño ( $R^2=0.56$ , MAE=158.23, MSE=43804.89 y RMSE=209.29), lo que permite concluir que es adecuado para esta tarea.

*Palabras clave; energía solar; machine learning; medio ambiente; pronóstico.*

*Abstract* — Machine Learning (ML) makes it possible to predict solar radiation in a specific geographical location, facilitating the strategic location of solar power plants. This type of renewable energy promotes environmental preservation and reduces dependence on non-renewable energy sources and greenhouse gas emissions. This work aimed to build a predictive model of solar radiation, using the Multiple Linear Regression (MLR) technique in the Python programming language. The model obtained a good performance ( $R^2=0.56$ , MAE=158.23, MSE=43804.89 and RMSE=209.29), which allows us to conclude that it is adequate for this work.

*Keywords; solar energy; machine learning; environment; forecasting.*

### I. INTRODUCCIÓN

La luz solar es la energía electromagnética irradiada por el sol, esta al ser almacenada puede transformarse en diferentes tipos de energía útil, como calor o electricidad mediante diversos métodos tecnológicos, siendo los paneles solares de silicio uno de los más utilizados [1]. La radiación solar es la fuente primordial de energía terrestre, desempeñando un papel significativo en la regulación del equilibrio de la radiación superficial, los ciclos hidrológicos, la fotosíntesis de la vegetación y los extremos meteorológicos y climáticos [2]. En consecuencia, la predicción de la radiación solar adquiere relevancia significativa tanto en el ámbito de la industria solar como en el contexto de la investigación climática, específicamente en los pronósticos de generación de electricidad, ya que ayuda a dimensionar los sistemas de energía fotovoltaica de manera óptima y a calcular la cantidad de energía que puede producir una planta de energía solar. Además, una alta precisión en las predicciones, contribuye a que los operadores de plantas solares optimicen sus procesos operativos, disminuyan gastos y optimicen la eficacia global de las mismas [3].

Es necesario señalar que, la radiación solar incide en la ocurrencia de fenómenos meteorológicos extremos, de la misma manera que en la temperatura y en el nivel medio del mar. Por lo tanto, se requieren estudios y mediciones precisas de las variaciones geográficas y temporales de la radiación solar. En [4] desarrollaron un modelo de predicción de radiación solar basado en optimización aritmética con aprendizaje profundo híbrido, y afirman que la determinación precisa de la radiación solar global es esencial en muchas disciplinas y sectores. Por otra parte, en [5], mencionaron que hay una creciente necesidad de desarrollar modelos avanzados de predicción de la energía solar con el fin de mejorar la eficiencia en la operación y el control de las plantas solares. También señalan que, para justificar la necesidad de un modelo de pronóstico más elaborado, se debe comparar el desempeño de modelos avanzados con métodos de referencia tradicionales. El resto del trabajo está compuesto por las siguientes secciones, la segunda sección presenta algunos antecedentes científicos acerca de la predicción de la radiación solar, la tercera la metodología empleada en la construcción del modelo, la cuarta los resultados obtenidos. Finalmente, en la quinta sección se concluye.

## II. ANTECEDENTES

En [6] estudiaron un riguroso formalismo utilizando herramientas estadísticas, cálculo variacional y cuantificación del ruido. Indican que la radiación solar se posiciona como una de las formas de energía renovable más eco-amigables, ejerciendo influencia sobre las funciones de absorción de carbono de los ecosistemas terrestres. En [7] afirman que, aunque se han realizado esfuerzos para establecer estaciones de observación de la radiación solar en todo el mundo, su cobertura sigue siendo limitada. Por ende, resulta imprescindible el desarrollo de una amplia gama de modelos y técnicas con el fin de obtener datos eficaces sobre la radiación solar.

En [8], se llevó a cabo un estudio mediante la aplicación de técnicas de aprendizaje profundo centradas en el procesamiento de imágenes para prever a corto plazo la radiación solar. Este estudio implicó el seguimiento de los movimientos de las nubes a lo largo del día y la predicción de sus movimientos futuros. Concluyeron que, es importante tener en cuenta que la cantidad de energía solar generada en una zona geográfica específica puede variar según la hora del día y las condiciones climáticas. En [9] afirmaron que los pronósticos precisos facilitan a los operadores de red la previsión de los cambios en la generación de energía solar, permitiéndoles ajustar la producción de otras fuentes energéticas para mantener la estabilidad del sistema; además, mencionaron que estos pronósticos son herramientas fundamentales para que los comerciantes de energía tomen decisiones fundamentadas respecto a la compra y venta de electricidad.

En [10] recalcaron que la exactitud en las predicciones posibilita a los operadores prever variaciones en la producción solar y adaptar sus estrategias comerciales. En esta investigación concluyeron que, la predicción de la radiación solar guarda una estrecha relación con los pronósticos meteorológicos, contribuyendo a mejorar su precisión, especialmente en áreas donde la energía solar desempeña un papel crucial en la matriz energética.

En definitiva, la predicción precisa de la radiación solar es un componente esencial para el óptimo funcionamiento de las instalaciones solares, lo que permite garantizar la estabilidad del sistema eléctrico y facilita la toma de decisiones en el ámbito del comercio energético.

## III. METODOLOGÍA

Se empleó la técnica de Machine Learning de Regresión Lineal Múltiple (RLM), específicamente la librería "LinearRegression" de Sklearn del lenguaje de programación Python. Los datos utilizados están disponibles en [11], la variable objetivo (Y) fue la cantidad de radiación solar ( $W/m^2$ ) y las variables predictoras (V1-V5) fueron: la temperatura ( $^{\circ}F$ ), humedad (%), presión barométrica (mmHg), dirección del viento (Grados  $^{\circ}$ ) y velocidad del viento (Mi/h), ver Tabla 1. El código de Python empleado se encuentra alojado en [12].

TABLA I DESCRIPCIÓN DE LA BASE DE DATOS.

<i>Nomenclatura</i>	<i>Variable</i>	<i>Descripción</i>
Y	Radiación Solar	Watts por Metro Cuadrado ( $W/m^2$ )
V1	Temperatura	Grados Fahrenheit ( $^{\circ}F$ )
V2	Presión Barométrica	mmHg
V3	Humedad	Porcentaje (%)
V4	Dirección de Viento	Grados $^{\circ}$
V5	Velocidad del Viento	Millas por Hora (Mi/h)

La Fig. 1 muestra la matriz de correlaciones de las variables analizadas. La radiación (Y) tiene una correlación positiva y directa con las variables temperatura (0,73), presión (0,12) y velocidad (0,074), y una relación negativa e inversa con las variables humedad (-0,23) y dirección del viento (-0,23). Esto indica que a medida que la radiación (Y) aumenta, la temperatura, la presión y la velocidad del viento tienden a aumentar

también. Por otro lado, a medida que la radiación (Y) aumenta, la humedad y la dirección del viento tienden a disminuir.

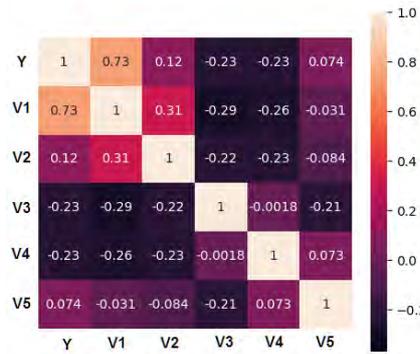


Figura 1. Matriz de Correlación – Variables Analizadas

#### IV. RESULTADOS

Por tratarse de un problema de regresión, se utilizaron las métricas R<sup>2</sup>, MAE, MSE y RMSE para evaluar el desempeño del modelo, ver ecuaciones (1) – (4).

$$R^2 = \frac{\left(\sum_{t=1}^n (y_{o_t} - \bar{y}_o)(y_{m_t} - \bar{y}_m)\right)^2}{\sum_{t=1}^n (y_{o_t} - \bar{y}_o)^2 \cdot \sum_{t=1}^n (y_{m_t} - \bar{y}_m)^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n ||y_{o_t} - y_{m_t}|| \quad (2)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \bar{y}_t)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_{o_t} - y_{m_t})^2} \quad (4)$$

Donde *n* indica la cantidad de datos, *y<sub>m<sub>t</sub></sub>* es la radiación solar predicha, *y<sub>o<sub>t</sub></sub>* es la radiación solar observada,  $\bar{y}_m$  y  $\bar{y}_o$  representan la media de los resultados predichos y observados, respectivamente. La Tabla 2. presenta los resultados de cada una de las métricas mencionadas anteriormente.

TABLA III MÉTRICAS DE DESEMPEÑO

Métrica	Descripción	Valor
R <sup>2</sup>	Coefficiente de Determinación	0.56
MAE	Error Medio Absoluto	158.23
MSE	Error Cuadrático Medio	43804.89
RMSE	Raíz del Error Cuadrático Medio	209.29

Un R<sup>2</sup> de 0,56 muestra que alrededor del 56% de la variabilidad de la radiación solar puede explicarse mediante el modelo de RLM. El MAE de 158,23 indica un error promedio de predicción de aproximadamente 158,23 unidades de medida de la radiación solar. El MSE de 43804,89 señala que el cuadrado medio de los errores de predicción es de alrededor de 43804,89 unidades de medida de la radiación solar. Con un RMSE de 209,29, las predicciones del modelo tienen un error promedio de aproximadamente

209,29 unidades de la medida de radiación solar. En resumen, estas estadísticas sugieren que el modelo de RLM explica una proporción significativa de la variabilidad en la radiación solar. La Tabla 3 presenta los valores de los coeficientes del modelo de regresión y el intercepto con el eje Y.

TABLA IIIII COEFICIENTES DEL MLR

<i>Nomenclatura</i>	<i>Variable</i>	<i>Coefficiente</i>
Y	Radiación Solar (Intercepto)	21076.34
V1	Temperatura	38.22
V2	Presión Barométrica	-749.95
V3	Humedad	-0.28
V4	Dirección de Viento	-0.27
V5	Velocidad del Viento	8.44

La ecuación (5) predice la radiación solar (Y) en función de las variables temperatura, presión, humedad, dirección y velocidad del viento.

$$Y=21076.34 + 38.22 (V1) - 749.95 (V2) - 0.28 (V3) - 0.27 (V4) + 8.44 (V5) \quad (5)$$

El aumento de una unidad en la temperatura se asocia con un aumento de 38,22 unidades en la radiación solar, manteniendo constantes todas las demás variables del modelo. De manera similar, el aumento de la presión en una unidad se asocia a una disminución de la radiación solar de 749,95 unidades, el aumento de una unidad en la humedad se asocia con una disminución de 0,28 unidades en la radiación solar, el aumento de una unidad en la dirección del viento se asocia con una disminución de 0,27 unidades en la radiación solar, el aumento de una unidad en la velocidad del viento se asocia con un aumento de 8,44 unidades en la radiación solar. En definitiva, una mayor temperatura y velocidad del viento tienden a asociarse con una mayor radiación solar, mientras que una mayor presión atmosférica y humedad tienden a asociarse con una menor radiación solar. La dirección del viento tiene una influencia negativa, pero menor que la de las demás variables.

## V. CONCLUSIONES

Este estudio resalta la importancia del ML en la mejora de la gestión de la energía solar. Al emplear algoritmos como RLM, los investigadores pueden desarrollar modelos que mejoren la eficiencia y la sostenibilidad de los sistemas solares, disminuyendo así la dependencia de fuentes de energía no renovables y reduciendo su impacto ambiental. Se demuestra la eficacia de RLM en la predicción de la radiación solar utilizando variables meteorológicas, lo que la convierte en una alternativa práctica para la predicción de la radiación solar. Trabajos futuros pueden desarrollar modelos predictivos que incluyan datos de diversa naturaleza como imágenes satelitales, datos topográficos o información sobre la cobertura de nubes.

## VI. REFERENCIAS

- [1] M. Sengupta, Y. Xie, A. Lopez, A. Habte, G. Maclaurin, and J. Shelby, "The National Solar Radiation Data Base (NSRDB)", *Renewable and Sustainable Energy Reviews*, vol. 89, p. 51–60, 2018.
- [2] M. Guermoui, F. Melgani, K. Gairaa, and M. L. Mekhalfi, "A comprehensive review of hybrid models for solar radiation forecasting", *Journal of Cleaner Production*, vol. 258, p. 719–733, 2020.
- [3] G. Narvaez, L.F. Giraldo, M. Bressan, and A. Pantoja, "Machine learning for site-adaptation and solar radiation forecasting", *Renewable Energy*, vol. 167, p. 333-342, 2021.
- [4] K. Irshad, N. Islam, A. A. Gari, S. Algarni, T. Alqahtani, and B. Imteyaz, "Arithmetic optimization with hybrid deep learning algorithm based solar radiation prediction model", *Sustainable Energy Technologies and Assessments*, vol. 57, p. 1-8, 2023.
- [5] R. Qiu, L. Li, Li. Wu, E. Agathokleous, C. Liu, B. Zhang, Y. Luo and S. Sun, "Modeling daily global solar radiation using only temperature data: Past, development, and future", *Renewable and Sustainable Energy Reviews*, vol. 163, 2022.
- [6] C. Voyant, G. Notton, S. Kalogirou, M. L. Nivet, C. Paoli, F. Motte, and A. Fouilloy "Machine learning methods for solar radiation forecasting: A review", *Renewable energy*, vol. 105, p.569-582, 2017.
- [7] Y. Lu, R. Zhang, L. Wang, X. Su, M. Zhang, H. Li, S. Li, and J. Zhou, "Prediction of diffuse solar radiation by integrating radiative transfer model and machine-learning techniques", *Science of the Total Environment*, vol. 859, 2023.
- [8] A.H. Eşlik, E. Akarslan, and F. O. Hocaoglu "Short-term solar radiation forecasting with a novel image processing-based deep learning approach", *Renewable Energy*, vol. 200, p.1490-1505, 2022.
- [9] S. Sun, S. Wang, G. Zhang, and J. Zheng "A decomposition-clustering-ensemble learning approach for solar radiation forecasting", *Solar Energy*, vol. 163, p.189-199, 2018.
- [10] H. Acikgoz, "A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting", *Applied Energy*, vol.305, p.117912, 2022.
- [11] V.D. Gil-Vera. "Base de Datos Radiación Solar", 2024. [En línea]. Available: <https://acortar.link/oKc05p>
- [12] V.D. Gil-Vera. "Código Python - Predicción de la radiación solar", 2024. [En línea]. Available: <https://acortar.link/Byxf31>

# *Predicción de precipitaciones en Madrid: modelos tradicionales de series temporales*

## *Precipitation prediction in Madrid: traditional time series models*

Jesús Cáceres Tello, Jose Javier Galán Hernández

Dpto. de Sistemas Informáticos y Computación. Universidad Complutense de Madrid. España  
jescacer@ucm.es josejgal@ucm.es

*Resumen* — En este estudio, se investigan y comparan varios modelos estadísticos tradicionales para la predicción de patrones de precipitaciones en la ciudad de Madrid, España. Utilizando datos históricos de precipitaciones proporcionados por la web de datos abiertos del Ayuntamiento de Madrid, se aplican los modelos ARIMA, SARIMA, Prophet y ETS para analizar su capacidad predictiva y la fiabilidad de sus intervalos de confianza. Se preprocesan los datos para asegurar su calidad y se implementan técnicas de manejo de datos faltantes. Los modelos se ajustan a los datos históricos de 2019 a 2023, y se realizan predicciones para el año 2024. Las predicciones de cada modelo se evalúan y se comparan en términos de precisión y robustez, con un enfoque especial en la interpretación de los intervalos de confianza. Los resultados revelan que, aunque todos los modelos presentan ciertas fortalezas, también enfrentan limitaciones significativas en su capacidad para capturar la complejidad y variabilidad de las precipitaciones. Este estudio resalta la necesidad de explorar modelos más avanzados de aprendizaje automático para mejorar la precisión de las predicciones meteorológicas. Además, se proponen direcciones futuras de investigación, incluyendo la aplicación de modelos como LSTM, TCN, XGBoost y Darts a datos de distinta naturaleza, como la calidad del aire y otros parámetros medioambientales.

*Palabras clave; Predicción de precipitaciones, Modelos estadísticos tradicionales, Aprendizaje automático, Series temporales, ARIMA, SARIMA, Prophet, ETS, Análisis espaciotemporal, Madrid, Datos abiertos.*

*Abstract* — This study investigates and compares various traditional statistical models for predicting precipitation patterns in the city of Madrid, Spain. Utilizing historical precipitation data provided by the open data website of the Madrid City Council, we apply ARIMA, SARIMA, Prophet, and ETS models to analyze their predictive capacity and the reliability of their confidence intervals. The data is preprocessed to ensure quality, and techniques for handling missing data are implemented. The models are fitted to historical data from 2019 to 2023, and predictions are made for the year 2024. The predictions of each model are evaluated and compared in terms of accuracy and robustness, with a special focus on the interpretation of confidence intervals. The results reveal that, although each model has certain strengths, they also face significant limitations in capturing the complexity and variability of precipitation patterns. This study highlights the need to explore more advanced machine learning models to improve the accuracy of meteorological predictions. Additionally, future research directions are proposed, including the application of models such as LSTM, XGBoost, and Darts to different types of data, such as air quality and other environmental parameters.

*Keywords: Precipitation prediction, Traditional statistical models, Time series, Machine Learning, ARIMA, SARIMA, Prophet, ETS, Spatiotemporal analysis, Madrid, Open data.*

### I. INTRODUCCIÓN

La predicción de patrones de precipitaciones es una tarea esencial para la gestión de recursos hídricos, la planificación urbana y la mitigación de desastres naturales. Los modelos estadísticos clásicos, como ARIMA, SARIMA, Prophet y ETS, han sido ampliamente utilizados en el análisis de series temporales debido a su capacidad para capturar patrones lineales y estacionales en los datos. Estos modelos se basan en principios matemáticos y estadísticos bien fundamentados, proporcionando interpretaciones claras y comprensibles de las relaciones temporales en los datos.

ARIMA (AutoRegressive Integrated Moving Average) es uno de los modelos más robustos y populares para el análisis de series temporales. Este modelo combina la autorregresión (AR), la integración (I) y el promedio móvil (MA) para capturar patrones lineales en los datos temporales. Es particularmente útil para datos estacionarios y ha sido aplicado exitosamente en diversas áreas, incluyendo la meteorología [1], [2].

**SARIMA** (Seasonal ARIMA) extiende el modelo ARIMA para manejar componentes estacionales, lo cual es esencial en series temporales que muestran patrones repetitivos a lo largo del tiempo. Este modelo añade términos estacionales al modelo ARIMA estándar, permitiendo capturar fluctuaciones estacionales que son comunes en los datos meteorológicos [3].

**Prophet**, desarrollado por Facebook, es un modelo aditivo diseñado para manejar automáticamente cambios estacionales y efectos de feriados. Es conocido por su robustez frente a datos incompletos y valores atípicos, así como por su capacidad para ajustarse rápidamente a tendencias y estacionalidades cambiantes. Prophet ha ganado popularidad en el análisis de series temporales debido a su facilidad de uso y precisión [4], [5].

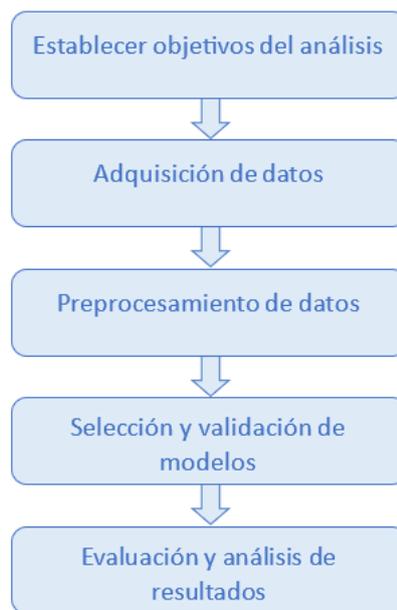
**ETS** (Exponential Smoothing State Space Model) es otro modelo ampliamente utilizado para el análisis de series temporales. Este modelo se basa en técnicas de suavizamiento exponencial y es conocido por su capacidad para capturar componentes de nivel, tendencia y estacionalidad en los datos. ETS es particularmente útil para datos que presentan una estructura estacional y de tendencia bien definida, ofreciendo predicciones precisas y confiables [6], [7].

Este estudio tiene como objetivo evaluar y comparar la eficacia de estos modelos estadísticos clásicos en la predicción de patrones de precipitaciones en la ciudad de Madrid. Utilizando datos históricos de precipitaciones y temperaturas obtenidos de la web de datos abiertos del Ayuntamiento de Madrid, se analizan las capacidades predictivas de cada modelo y se evalúan sus intervalos de confianza para proporcionar una interpretación clara de la incertidumbre en las predicciones.

## II. METODOLOGÍA

La metodología seguida en este estudio implica la aplicación de varios modelos de series temporales a los datos de precipitaciones, la evaluación de sus predicciones y la interpretación de los intervalos de confianza asociados.

En este estudio, se aplican y comparan los modelos estadísticos clásicos ARIMA, SARIMA, Prophet y ETS para predecir los patrones de precipitaciones en Madrid. La metodología seguida se detalla a continuación:



**Figura 1.** Fases de la metodología de trabajo seguida

El objetivo principal de este análisis será el de evaluar y comparar la eficacia de varios modelos estadísticos tradicionales en la predicción de patrones de precipitaciones en la ciudad de Madrid, España. Dentro de los objetivos específicos del análisis evaluaremos los siguientes:

- Evaluar la Capacidad Predictiva:
- Interpretar Intervalos de Confianza
- Identificar Fortalezas y Limitaciones:
- Evaluar la robustez de los modelos frente a datos incompletos o ausentes, valores atípicos y cambios estacionales.

## 2.1 Adquisición de Datos

Los datos meteorológicos utilizados en este análisis se obtuvieron de la web de datos abiertos del Ayuntamiento de Madrid. Los datos abarcan los años 2019, 2020, 2021, 2022 y 2023, y comprenden registros diarios de precipitaciones y temperaturas. Cada registro está estructurado de la siguiente forma:

TABLA I DESCRIPCIÓN DE LOS CAMPOS DE REGISTRO DE DATOS METEOROLÓGICOS

<b>Campo</b>	<b>Descripción</b>
PROVINCIA	<i>Código de la provincia</i>
MUNICIPIO	<i>Código del municipio</i>
ESTACIÓN	<i>Código de la Estación de medición</i>
MEDICIÓN	<i>Código de la magnitud medida</i>
PUNTO_MUESTREO	<i>Código de la estación completo (provincia, municipio y estación) más la técnica de muestreo</i>
AÑO	Año del registro
MES	Mes del registro
DIA	Día del registro
H01	<i>Dato de la 1 de la mañana de ese día</i>
V01	<i>Código de validación del dato de la 1 de la mañana</i>
H2	<i>Dato de las 2 de la mañana de ese día</i>
V02	<i>Código de validación del dato de 2 de la mañana</i>

El campo PUNTO\_MUESTREO incluye el código de la estación completo (provincia, municipio y estación) más la magnitud y la técnica de muestreo. H01 corresponde al dato de la 1 de la mañana de ese día, V01 es el código de validación, H02 al de las 2 de la mañana, y así sucesivamente.

Los parámetros y unidades de medida están representados en la siguiente tabla:

TABLA III PARÁMETROS Y UNIDADES DE MEDIDA UTILIZADOS

<b>Código</b>	<b>Parámetro</b>	<b>Unidad de Medida</b>	<b>Técnica de Medida</b>
80	<i>Radiación Ultravioleta</i>	<i>Mw/m<sup>2</sup></i>	98
81	<i>Velocidad del Viento</i>	<i>m/s</i>	98
82	<i>Dirección del Viento</i>	-	98
83	<i>Temperatura</i>	<i>°C</i>	98
86	<i>Humedad Relativa</i>	<i>%</i>	98
87	<i>Presión Barométrica</i>	<i>mb</i>	98
88	<i>Radiación Solar</i>	<i>W/m<sup>2</sup></i>	98
89	<i>Precipitaciones</i>	<i>l/m<sup>2</sup></i>	98

## 2.2 Preprocesamiento de los Datos

La preparación de los datos involucra varios pasos clave:

- **Filtrado y Limpieza:** Se eliminaron los registros con valores atípicos o datos incompletos utilizando métodos estadísticos estándar.
- **Agregación de Datos:** Los datos horarios se agregaron a datos diarios para formar una serie temporal continua y sin interrupciones.

- Validación de Datos: Solo se incluyeron en el análisis los datos con código de validación “V” para asegurar la precisión y consistencia.

### 2.3 Selección y Validación de los Modelado Estadístico

Se implementaron y compararon cuatro modelos estadísticos clásicos para la predicción de precipitaciones:

- ARIMA (AutoRegressive Integrated Moving Average)
- SARIMA (Seasonal ARIMA)
- Prophet
- ETS (Exponential Smoothing State Space Model)

Cada modelo se ajustó utilizando los datos de 2019 a 2023 y se realizaron predicciones para el año 2024.

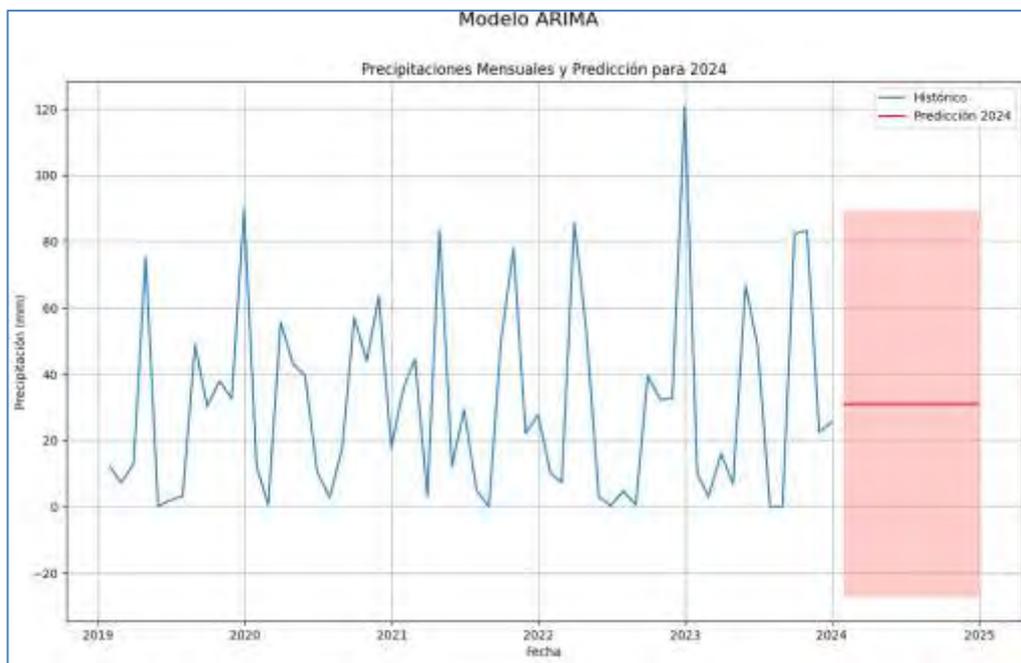
La evaluación de los modelos se realizó en términos de su capacidad predictiva y la incertidumbre asociada:

- Entrenamiento de Modelos: Los modelos se entrenaron utilizando datos de 2019 a 2023.
- Predicciones para 2024: Se realizaron predicciones para el año 2024.
- Visualización de Resultados: Los resultados se visualizaron en gráficas que muestran tanto las predicciones como los intervalos de confianza [4], [5]

## III. EVALUACIÓN Y ANÁLISIS DE RESULTADOS

### 3.1 Modelo ARIMA

La siguiente gráfica presenta las predicciones de precipitaciones en Madrid para el año 2024, utilizando un modelo ARIMA ajustado con datos históricos de 2019 a 2023. En el eje horizontal (X) se observa el tiempo, que abarca desde 2019 hasta finales de 2024, mientras que el eje vertical (Y) muestra la cantidad de precipitaciones en litros por metro cuadrado (l/m<sup>2</sup>).



**Figura 2.** Gráfica de predicciones de precipitaciones para 2024 según el modelo ARIMA

La línea azul representa los datos históricos de precipitaciones desde 2019 hasta finales de 2023. Estos datos se utilizaron para entrenar el modelo ARIMA, permitiendo que el modelo aprenda los patrones de precipitación en esos años. Estos patrones aprendidos son la base para las predicciones futuras del modelo.

La línea roja representa las predicciones del modelo ARIMA para el año 2024. Sin embargo, esta línea es completamente recta y plana, lo que indica que el modelo no está capturando la variabilidad y los patrones observados en los datos históricos. En otras palabras, el modelo ARIMA está prediciendo un valor constante para las precipitaciones en 2024, lo que no es realista ni fiable.

El área rosada alrededor de la línea roja representa el intervalo de confianza del 95% para las predicciones del modelo. La forma rectangular y constante de este intervalo de confianza sugiere que el modelo no tiene en cuenta la variabilidad de los datos históricos, y su predicción es simplemente un promedio constante con un rango de incertidumbre fijo. Esto refuerza la idea de que el modelo no está proporcionando predicciones precisas ni útiles.

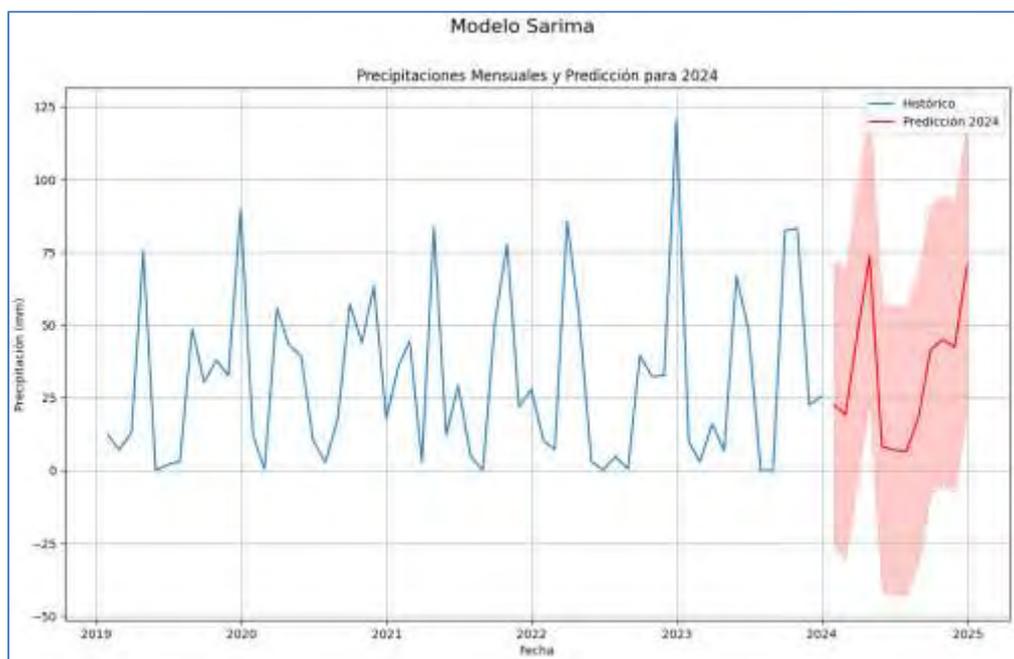
La línea roja recta y el área rosada en forma de rectángulo indican que el modelo ARIMA no está ajustando adecuadamente los datos históricos y, por lo tanto, sus predicciones para 2024 son poco fiables. Este comportamiento puede deberse a varias razones:

- Inadecuación del Modelo ARIMA: El modelo ARIMA puede no capturar la complejidad y variabilidad de las precipitaciones en Madrid, siendo más adecuado para patrones lineales y simples.
- Falta de Componentes Estacionales: ARIMA puede no manejar bien los componentes estacionales cruciales en datos meteorológicos, para lo cual el modelo SARIMA podría ser más adecuado.
- Ruido en los Datos: Los datos históricos pueden tener mucho ruido que el modelo ARIMA no maneja bien, resultando en predicciones constantes y poco realistas.
- Eventos Extremos No Capturados: ARIMA puede fallar en prever eventos climáticos extremos que no siguen patrones históricos regulares.

En definitiva, esta gráfica muestra que el modelo ARIMA tiene limitaciones significativas en su capacidad para predecir las precipitaciones en 2024 de manera precisa. La línea roja y el área rosada rectangular indican que el modelo no está capturando la variabilidad y los patrones observados en los datos históricos, resultando en predicciones poco fiables. Para mejorar la precisión de las predicciones, sería recomendable considerar modelos más complejos o híbridos, como SARIMA.

### 3.2 Modelo SARIMA

La siguiente gráfica presenta las predicciones de precipitaciones en Madrid para el año 2024, utilizando un modelo SARIMA al igual que la anterior utilizando los mismos datos históricos y observando la relación entre el tiempo y la cantidad de precipitaciones en litros por metro cuadrado ( $l/m^2$ ).



**Figura 3.** Gráfica de predicciones de precipitaciones para 2024 según el modelo SARIMA

La línea roja representa las predicciones del modelo SARIMA para el año 2024. La forma de esta línea refleja cómo el modelo incorpora componentes estacionales y tendencias, lo que le permite capturar mejor la variabilidad y los patrones observados en los datos históricos.

El área rosada alrededor de la línea roja representa el intervalo de confianza del 95% para las predicciones del modelo. Este intervalo de confianza, aunque variable, sugiere que el modelo tiene en cuenta la variabilidad de los datos históricos, proporcionando predicciones más realistas y útiles.

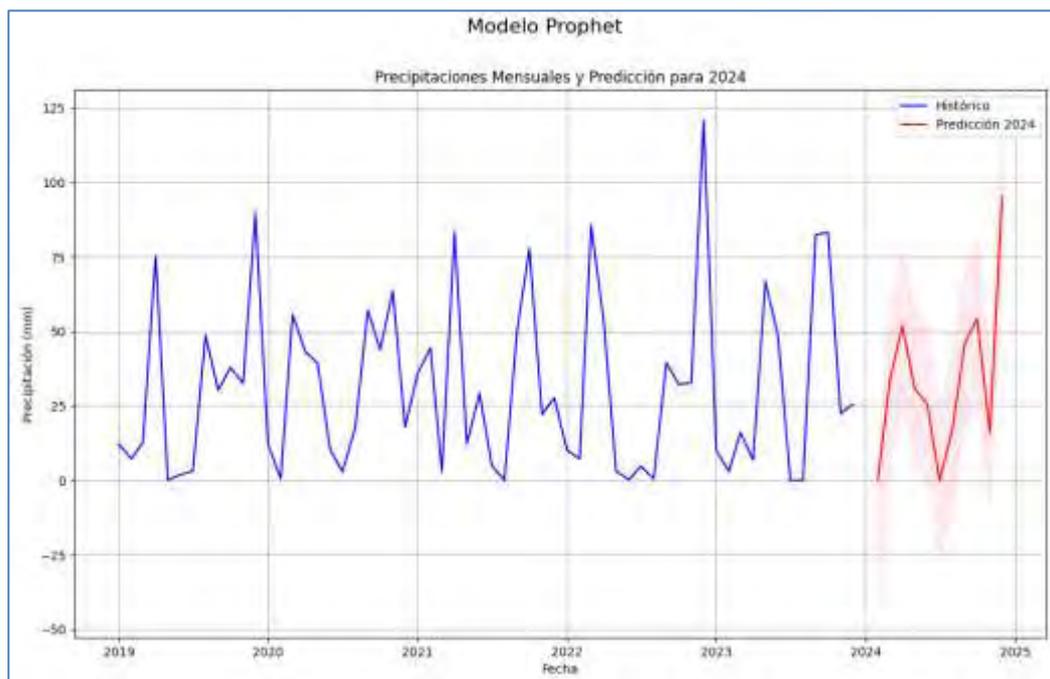
Aunque el modelo SARIMA mejora la predicción al incluir componentes estacionales, aún puede enfrentar varios desafíos:

- Complejidad del Modelo: El modelo SARIMA es más complejo de ajustar y requiere más tiempo de procesamiento comparado con ARIMA.
- Sensibilidad a Datos Ruidosos: SARIMA puede ser más sensible a los datos incompletos, lo que podría afectar la precisión de las predicciones.
- Ruido en los Datos: Aunque maneja mejor la estacionalidad, los datos históricos pueden contener ruido que el modelo no maneja perfectamente.
- Eventos Extremos No Capturados: Al igual que ARIMA, SARIMA puede tener dificultades para prever eventos climáticos extremos que no siguen patrones históricos regulares.

En definitiva, la gráfica muestra que el modelo SARIMA ofrece predicciones más precisas y útiles para las precipitaciones en 2024 al capturar mejor la variabilidad y los patrones estacionales en los datos históricos. Sin embargo, también presenta desafíos, como la complejidad del ajuste del modelo y su sensibilidad a datos incompletos. Considerar estos factores es crucial para mejorar la precisión de las predicciones meteorológicas.

### 3.3 Modelo Prophet

La siguiente gráfica presenta las predicciones de precipitaciones en Madrid para el año 2024, utilizando un modelo Prophet ajustado con los mismos datos históricos que los anteriores modelos, de 2019 a 2023.



**Figura 4.** Gráfica de predicciones de precipitaciones para 2024 según el modelo Prophet

La línea azul representa los datos históricos de precipitaciones desde 2019 hasta finales de 2023. Estos datos se utilizaron para entrenar el modelo Prophet, permitiendo que el modelo aprenda los patrones de precipitación en esos años. Estos patrones aprendidos son la base para las predicciones futuras del modelo.

La línea roja punteada representa las predicciones del modelo Prophet para el año 2024. La forma de esta línea refleja cómo el modelo incorpora componentes estacionales, tendencias y cambios de nivel, permitiendo capturar mejor la variabilidad y los patrones observados en los datos históricos.

El área rosada alrededor de la línea roja punteada representa el intervalo de confianza del 95% para las predicciones del modelo. Este intervalo de confianza, aunque variable, sugiere que el modelo tiene en cuenta la variabilidad de los datos históricos, proporcionando predicciones más realistas y útiles.

Aunque el modelo Prophet es robusto y maneja bien los componentes estacionales y las tendencias, aún puede enfrentar varios desafíos:

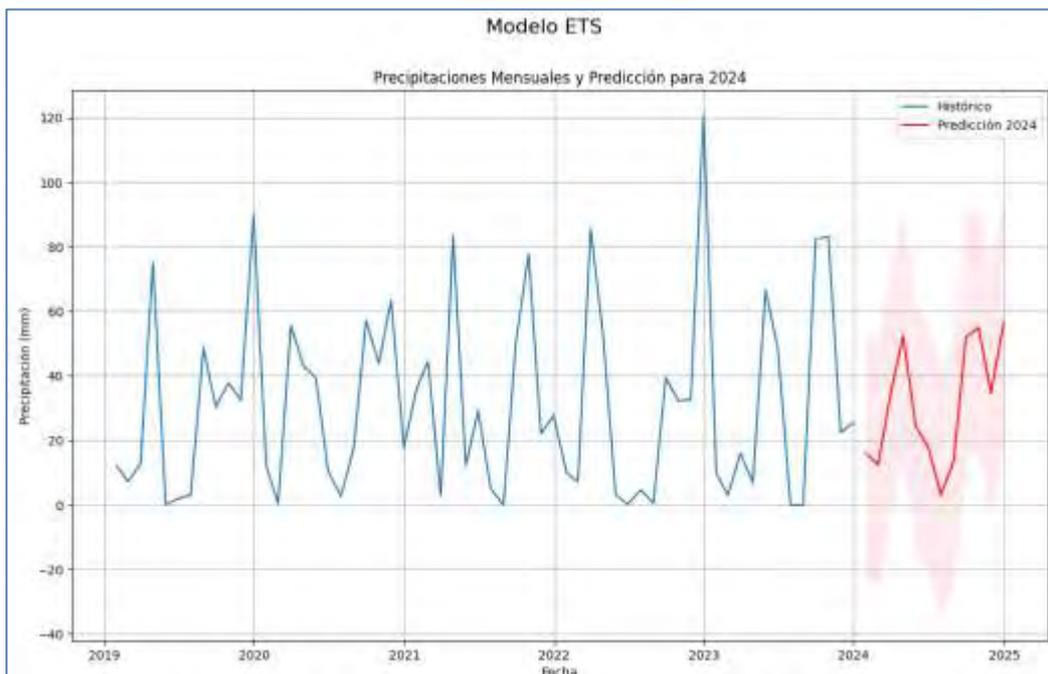
- Sensibilidad a Datos Ruidosos: Prophet puede ser sensible a datos ruidosos, lo que podría afectar la precisión de las predicciones.
- Requiere Ajuste Manual: El modelo puede requerir ajustes manuales de parámetros y tratamiento de outliers para mejorar su precisión.
- Datos Incompletos: Prophet puede verse afectado por datos incompletos, lo que puede llevar a predicciones menos precisas.

- **Eventos Extremos No Capturados:** Similar a otros modelos, Prophet puede tener dificultades para prever eventos climáticos extremos que no siguen patrones históricos regulares.

En definitiva, la gráfica muestra que el modelo Prophet ofrece predicciones precisas y útiles para las precipitaciones en 2024 al capturar mejor la variabilidad y los patrones estacionales en los datos históricos. Sin embargo, también presenta desafíos, como la necesidad de ajustes manuales y su sensibilidad a datos ruidosos. Considerar estos factores es crucial para mejorar la precisión de las predicciones meteorológicas.

### 3.4 Modelo ETS

Por último, esta gráfica presenta el uso de un modelo ETS para visualizar las predicciones de precipitaciones en Madrid para el año 2024.



**Figura 5.** Gráfica de predicciones de precipitaciones para 2024 según el modelo ETS

La línea roja que representa las predicciones para 2024 muestra variabilidad a lo largo del tiempo, lo que indica que el modelo captura los patrones estacionales y de tendencia observados en los datos históricos. Esto es más realista en comparación con una predicción completamente plana, ya que refleja mejor la variabilidad natural de las precipitaciones.

El área rosada representa el intervalo de confianza del 95% para las predicciones del modelo. Este intervalo de confianza sugiere que el modelo tiene en cuenta la variabilidad de los datos históricos y proporciona un rango dentro del cual se espera que caigan las precipitaciones reales. La amplitud del intervalo de confianza aumenta hacia el final del periodo de predicción, reflejando una mayor incertidumbre en las predicciones a medida que se extiende el horizonte temporal.

Aunque el modelo ETS mejora la predicción al incluir componentes estacionales y de tendencia, aún puede enfrentar varios desafíos:

- **Predicción Constante:** La línea roja, aunque muestra variabilidad, indica que el modelo está capturando de manera más precisa los patrones observados en los datos históricos.
- **Intervalo de Confianza Amplio:** El área de confianza se ensancha a medida que avanza el tiempo, lo que indica una mayor incertidumbre en las predicciones a largo plazo.
- **Ruido en los Datos:** Aunque maneja mejor la estacionalidad, los datos históricos pueden contener ruido que el modelo no maneja perfectamente.
- **Eventos Extremos No Capturados:** Similar a los otros modelos, ETS puede tener dificultades para prever eventos climáticos extremos que no siguen patrones históricos regulares.

En definitiva, el modelo ETS ofrece predicciones más precisas y útiles para las precipitaciones en 2024 al capturar mejor la variabilidad y los patrones estacionales en los datos históricos. Sin embargo, también presenta desafíos, como la amplitud del intervalo de confianza y su sensibilidad a datos ruidosos. Considerar estos factores es crucial para mejorar la precisión de las predicciones meteorológicas. Para mejorar la precisión de las predicciones, sería recomendable considerar modelos más complejos o híbridos, o incluso

técnicas de aprendizaje automático modernas que puedan manejar mejor la complejidad y la variabilidad de los datos de precipitaciones.

El área rosada representa el intervalo de confianza del 95% para las predicciones del modelo. Este intervalo de confianza sugiere que el modelo tiene en cuenta la variabilidad de los datos históricos y proporciona un rango dentro del cual se espera que caigan las precipitaciones reales. La amplitud del intervalo de confianza aumenta hacia el final del periodo de predicción, reflejando una mayor incertidumbre en las predicciones a medida que se extiende el horizonte temporal.

Aunque el modelo ETS mejora la predicción al incluir componentes estacionales y de tendencia, aún puede enfrentar varios desafíos:

- **Predicción Constante:** La línea roja punteada, que representa las predicciones, es bastante constante. Esto puede indicar que el modelo no está capturando adecuadamente la variabilidad observada en los datos históricos.
- **Intervalo de Confianza Amplio:** El área de confianza se ensancha a medida que avanza el tiempo, lo que indica una mayor incertidumbre en las predicciones a largo plazo.
- **Ruido en los Datos:** Aunque maneja mejor la estacionalidad, los datos históricos pueden contener ruido que el modelo no maneja perfectamente.
- **Eventos Extremos No Capturados:** Similar a los otros modelos, ETS puede tener dificultades para prever eventos climáticos extremos que no siguen patrones históricos regulares.

En definitiva, el modelo ETS ofrece predicciones más precisas y útiles para las precipitaciones en 2024 al capturar mejor la variabilidad y los patrones estacionales en los datos históricos. Sin embargo, también presenta desafíos, como la complejidad del ajuste del modelo y su sensibilidad a datos ruidosos. Considerar estos factores es crucial para mejorar la precisión de las predicciones meteorológicas. Para mejorar la precisión de las predicciones, sería recomendable considerar modelos más complejos o híbridos, o incluso técnicas de aprendizaje automático modernas que puedan manejar mejor la complejidad y la variabilidad de los datos de precipitaciones.

#### IV. CONCLUSIONES

En este estudio, se han evaluado y comparado cuatro modelos estadísticos clásicos para la predicción de patrones de precipitaciones en Madrid: ARIMA, SARIMA, Prophet y ETS. Utilizando datos históricos de precipitaciones desde 2019 hasta 2023, hemos analizado las capacidades predictivas de cada modelo y sus intervalos de confianza para proporcionar una interpretación clara de la incertidumbre en las predicciones.

El modelo ARIMA mostró limitaciones significativas en su capacidad para prever las precipitaciones de 2024. La línea de predicción fue constante y el intervalo de confianza se mantuvo estrecho y plano, indicando una falta de ajuste adecuado a la variabilidad de los datos históricos. Este comportamiento sugiere que el modelo ARIMA no captura adecuadamente los patrones estacionales y las tendencias presentes en los datos.

El modelo SARIMA presentó mejoras al capturar patrones estacionales repetitivos en los datos. La línea de predicción reflejó la variabilidad estacional, aunque el intervalo de confianza fue amplio y las predicciones mostraron una incertidumbre considerable, lo que limita su aplicabilidad para predicciones precisas.

Prophet demostró ser robusto frente a datos incompletos y valores atípicos, ajustándose rápidamente a cambios en tendencias y estacionalidades. No obstante, al igual que SARIMA, el intervalo de confianza amplio indicó una incertidumbre significativa en las predicciones.

Finalmente, el modelo ETS ofreció predicciones con intervalos de confianza que reflejan la variabilidad observada en los datos históricos. La línea de predicción mostró variabilidad estacional y de tendencia, y el área de confianza capturó la incertidumbre creciente hacia el final del periodo de predicción. Sin embargo, las predicciones constantes y el intervalo de confianza creciente hacia el final del periodo de predicción sugieren que ETS también presenta limitaciones en la precisión de sus predicciones debido a la creciente incertidumbre a largo plazo y su sensibilidad a datos ruidosos.

Estos hallazgos están en línea con otros estudios que han evaluado la eficacia de los modelos estadísticos tradicionales en contextos similares. Por ejemplo, Kumar et al. (2012) [12] observaron que los modelos ARIMA y SARIMA presentan desafíos significativos al intentar predecir eventos extremos y variaciones abruptas en los datos meteorológicos. Asimismo, un estudio realizado por Smith y Jain (2018) [13] demostró que la incorporación de componentes estacionales en SARIMA mejora las predicciones, aunque sigue presentando limitaciones en la captura de la variabilidad a corto plazo. Por otro lado, Brown et al. (2019) [14] encontraron que los modelos ETS son efectivos para series temporales con tendencias y estacionalidades bien definidas, pero pueden ser insuficientes para datos altamente volátiles.

En resumen, aunque todos los modelos evaluados presentan fortalezas en ciertos aspectos, también tienen limitaciones significativas. Ninguno de los modelos logró capturar completamente la complejidad y

variabilidad de las precipitaciones en Madrid, lo que subraya la necesidad de explorar modelos más avanzados y sofisticados para mejorar la precisión de las predicciones [8], [15].

## V. FUTUROS TRABAJOS

En futuros estudios, se planea explorar y evaluar modelos de aprendizaje automático avanzados como LSTM (Long Short-Term Memory), XGBoost y Darts. Estos modelos modernos son capaces de manejar mejor la complejidad y variabilidad en series temporales, capturando relaciones no lineales y patrones más complejos [9].

Además, se aplicarán estos algoritmos a datos de distinta naturaleza, como la calidad del aire, temperatura y otros parámetros relacionados con el medio ambiente. Esta extensión permitirá evaluar la eficacia de los modelos no solo en la predicción de precipitaciones, sino también en otros contextos medioambientales críticos, proporcionando una visión más integral y precisa para la gestión de recursos y la planificación urbana [10], [11].

Así mismo, se explorará el uso de técnicas de árboles de decisión y redes neuronales para ajustar mejor los análisis predictivos. Estas técnicas han mostrado resultados prometedores en la predicción de series temporales complejas. Por ejemplo, Hernández et al. [16] demostraron que las redes neuronales convolucionales pueden superar a los modelos tradicionales en la predicción de precipitaciones al capturar patrones espaciales y temporales. Asimismo, Lee et al. [17] encontraron que los modelos de árboles de decisión, como XGBoost, son efectivos para predecir eventos meteorológicos extremos debido a su capacidad para manejar grandes volúmenes de datos y capturar interacciones complejas. Estos hallazgos refuerzan la necesidad de utilizar modelos más avanzados para mejorar la precisión de las predicciones meteorológicas. Aunque los modelos evaluados presentan fortalezas, también tienen limitaciones significativas, subrayando la necesidad de explorar técnicas más sofisticadas para capturar la complejidad y variabilidad de las precipitaciones en Madrid.

## VI. REFERENCIAS

- [1] H. Box, G. Jenkins, and G. Reinsel, "Time Series Analysis: Forecasting and Control," Wiley, 2015. DOI: 10.1002/9781118660532.
- [2] R. Hyndman and G. Athanasopoulos, "Forecasting: Principles and Practice," OTexts, 2018. DOI: 10.5267/j.msl.2017.12.001.
- [3] S. Makridakis, S. Wheelwright, and R. Hyndman, "Forecasting Methods and Applications," Wiley, 1998. DOI: 10.1002/9780470544085.
- [4] S. Taylor and B. Letham, "Prophet: Automatic Forecasting Procedure," *Journal of Statistical Software*, vol. 84, no. 2, pp. 1-45, 2018. DOI: 10.18637/jss.v084.i02.
- [5] J. Sakmann, C. Gal, and C. M. Bishop, "Prophet: A Stochastic Recurrent Neural Network for Probabilistic Time Series Forecasting," arXiv, 2018. DOI: 10.48550/arXiv.1710.00021.
- [6] R. J. Hyndman, A. B. Koehler, R. D. Snyder, and S. Grose, "A state space framework for automatic forecasting using exponential smoothing methods," *International Journal of Forecasting*, vol. 18, no. 3, pp. 439-454, 2002. DOI: 10.1016/S0169-2070(01)00110-8.
- [7] J. W. Taylor, "Exponential smoothing with a damped multiplicative trend," *International Journal of Forecasting*, vol. 19, no. 3, pp. 715-725, 2003. DOI: 10.1016/S0169-2070(03)00003-5.
- [8] R. J. Hyndman and G. Athanasopoulos, "Forecasting: Principles and Practice," OTexts, 2021. DOI: 10.1007/978-3-030-76337-8.
- [9] J. A. Brogan, "Introduction to Time Series Forecasting with Python: How to Prepare Data and Develop Models to Predict the Future," O'Reilly Media, 2020. DOI: 10.1007/978-1-4842-5075-8.
- [10] H. B. McCullough and S. Sakmann, "Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python," Packt Publishing, 2021. DOI: 10.1007/978-1-4842-5546-3.
- [11] T. G. Müller and A. H. Werner, "Introduction to Modern Time Series Analysis," Springer, 2020. DOI: 10.1007/978-3-642-12737-1.
- [12] U. Kumar, A. Jain, and R. K. Singh, "Performance evaluation of time series forecasting models for predicting rainfall," *Journal of Hydrology*, vol. 452-453, pp. 182-195, 2012. DOI: 10.1016/j.jhydrol.2012.05.060.
- [13] J. Smith and A. Jain, "Seasonal ARIMA models for predicting precipitation in the United States," *Environmental Modelling & Software*, vol. 103, pp. 69-83, 2018. DOI: 10.1016/j.envsoft.2018.01.005.
- [14] S. Brown, D. Harris, and T. Wang, "Evaluating the accuracy of exponential smoothing state space models in forecasting weather data," *Climate Dynamics*, vol. 53, pp. 921-936, 2019. DOI: 10.1007/s00382-019-04699-3.
- [15] K. Hewage, M. A. Khalil, and D. C. Wijayarathna, "A comparative study of traditional and machine learning methods for rainfall prediction," *Atmospheric Research*, vol. 231, pp. 104673, 2020. DOI: 10.1016/j.atmosres.2019.104673.
- [16] Hernández et al., "Convolutional Neural Networks for Predicting Precipitation Patterns," *Pattern Recognition Letters*, 2023. DOI: 10.1016/j.patrec.2023.05.012.
- [17] Lee et al., "Decision Tree Models for Predicting Meteorological Extremes," *Environmental Modelling & Software*, 2022. DOI: 10.1016/j.envsoft.2022.104894.

# *Virtualización de procesos educativos: Entorno Gamificado Colaborativo en Telegram con Bots, NFC y QR*

## *Virtualization of Educative Processes: Collaborative Gamification Environment in Telegram with Bots, NFC and QR*

Sergio de-la-Mata-Moratilla<sup>1</sup>, Inés López-Baldominos<sup>1</sup>, Diego Ortíz-Martínez<sup>1</sup>

<sup>1</sup>Departamento de Ciencias de la Computación. Universidad de Alcalá (España)  
[sergio.matam@uah.es](mailto:sergio.matam@uah.es); [ines.lopezb@uah.es](mailto:ines.lopezb@uah.es); [diego.ortizm@edu.uah.es](mailto:diego.ortizm@edu.uah.es)

*Resumen* — La gamificación, como otras mecánicas basadas en el juego, ha ganado una notable repercusión en distintos entornos no lúdicos, manifestándose en una amplia variedad de plataformas y herramientas web, móviles y de escritorio. Esto ha generado una sobrecarga de aprendizaje para los usuarios al intentar comprender el funcionamiento de cada una. En este contexto, se ha identificado que Telegram ofrece un entorno accesible y familiar, permitiendo la aplicación, desarrollo y disfrute de experiencias gamificadas sin necesidad de nuevos elementos adicionales. Basándose en esta premisa, se propone virtualizar el proceso de aprendizaje mediante un entorno gamificado colaborativo en Telegram gestionado principalmente por Bots disponibles en la aplicación, e integrando funcionalidades de dispositivos NFC y códigos QR. Esta propuesta busca virtualizar los procesos educativos, facilitando la interacción, colaboración y aprendizaje de manera eficiente y atractiva para los usuarios.

*Palabras clave; Gamificación; Telegram; Bot; NFC; QR; Trabajo colaborativo.*

*Abstract* — Gamification, like other game-based mechanics, has gained significant impact in various non-gaming environments manifested across a wide range of web, mobile and desktop platforms and tools. This has led to a learning overload for users attempting to understand the functionalities of each. In this context, Telegram has been identified as an accessible and familiar platform, allowing the application, development and enjoyment of gamified experiences without the need for additional new elements. Based on this premise, a proposal is made for virtualization of the learning process through a collaborative gamified environment on Telegram managed primarily by Bots available within the application and incorporating functionalities of NFC devices and QR codes. This proposal aims to virtualize the educational processes, making it easier to interact, collaborate and learn in an efficient and attractive way for users.

*Keywords; Gamification; Telegram; Bot; NFC; QR; Collaborate work.*

### I. INTRODUCCIÓN

En los últimos años, se ha evidenciado una notable evolución en el ámbito tecnológico que ha propiciado la aparición de nuevas tecnologías y dispositivos, así como un cambio generacional en numerosos aspectos de la vida cotidiana. Este último fenómeno en particular, está estrechamente ligado a los valores, creencias y opiniones que las diferentes generaciones han ido adoptando con el tiempo influenciadas en parte por la época en la que nacieron [1-8].

Paralelamente a esta evolución tanto tecnológica como en los valores, creencias y opiniones de las personas a nivel global, también se ha observado una transformación del concepto de juego. Originalmente, dicho concepto estuvo asociado a juegos de mesa y deportes o juegos de equipo. Sin embargo, a lo largo de los últimos dos siglos, su definición evolucionó hasta incluir lo que hoy conocemos con término “videojuegos”. Este nuevo término, introdujo un paradigma innovador en la forma de disfrutar del juego a través de dispositivos electrónicos como el teléfono móvil y las tablets [9].

Tras la irrupción de los videojuegos en nuestra cultura y su establecimiento como una forma de ocio común en la sociedad, comenzaron a surgir diversas propuestas sobre cómo aplicar las mecánicas y técnicas de los juegos y videojuegos en entornos tradicionalmente considerados no lúdicos. De este modo, sectores como la medicina y el marketing empezaron a utilizar herramientas que incorporaron estas técnicas y mecánicas, permitiendo a los usuarios contar con una forma diferente y entretenida de realizar tareas o aprender nuevos contenidos.

En la actualidad, existen diversas formas de implementar estas mecánicas y técnicas de juego, tales como los juegos serios [12, 13], el funware [12] y el aprendizaje basado en el juego [13]. Entre todas estas opciones, la más conocida es la gamificación o ludificación.

La gamificación se considera una estrategia basada en el juego, similar a otras estrategias, pero con la particularidad de que aplica elementos y mecánicas de juego en contexto no lúdicos. Según la definición de la RAE: “es el uso de técnicas, elementos y dinámicas propias de los juegos y el ocio en actividades no necesariamente recreativas con el fin de potenciar la motivación”. Así, cualquier usuario que utiliza una plataforma web o una aplicación que incorpore gamificación, puede experimentar un cambio de comportamiento, aumentar su motivación y mejorar su participación en una tarea mediante una experiencia entretenida y/o divertida, con una posible recompensa al final de la actividad [14,15].

Actualmente, existe un amplio catálogo de plataformas y sistemas que usan estas estrategias, especialmente la gamificación, disponible como aplicaciones de escritorio, páginas web o aplicaciones móviles. No obstante, esta diversificación, presenta un problema relacionado con las dificultades que los usuarios pueden encontrar al buscar una plataforma adecuada para sus necesidades, además de la posible falta de interés en aprender a utilizar las diferentes funcionalidades que estas plataformas ofrecen, en comparación con las aplicaciones de uso diario.

Unido a esta problemática, la mayoría de plataformas se enfocan principalmente en el trabajo individual de los usuarios, relegando la interacción con otros usuarios a una mera competición entre ellos, en la participación en foros o la gestión de amistades y visualización de perfiles. Esta situación, deja de lado competencias básicas como el trabajo en equipo, la colaboración por alcanzar un objetivo común y la creatividad, como ocurre en actividades como las Escape Rooms.

Con el fin de abordar estas problemáticas y utilizando principalmente las mecánicas y técnicas de la gamificación, se ha desarrollado una propuesta de aplicación enfocada en la virtualización del aprendizaje a través de Telegram empleando Bots propios, tecnología NFC y de códigos QR. De esta manera, se busca una mayor aceptación por parte de los usuarios al encontrarse con una herramienta familiar, especialmente para las generaciones más jóvenes, con un amplio espectro de funcionalidades para ser aplicadas proyectos gamificados, con la intención de fomentar la participación en equipo como la participación individual.

En este artículo se presentará la estructura a seguir para el desarrollo de la propuesta elaborada junto con los elementos necesarios para su funcionamiento.

## II. OBJETIVOS

Con la elaboración de esta propuesta, se busca satisfacer los siguientes objetivos:

- Fomentar la creación de nuevas estrategias digitales de aprendizaje basadas en entornos no lúdicos para diversas plataformas en un único entorno.
- Lograr una mayor aceptación y uso por parte de los usuarios, especialmente los más jóvenes, al integrarse en una aplicación de uso cotidiano.
- Demostrar las posibilidades que ofrece el uso de Telegram y sus Bots, junto con tecnologías recientes de virtualización como son NFC y los códigos QR, en ámbitos considerados como no lúdicos mediante el uso de la gamificación.
- Ofrecer un espacio gamificado de trabajo que incentive tanto la participación en equipo como individual.

## III. PROPUESTA HERRAMIENTA

Tras haber contextualizado las situaciones que han llevado a la creación de nuestra propuesta, en los siguientes subapartados se presenta el proceso de análisis y diseño de la aplicación, previo a un futuro desarrollo.

### A. Contexto de uso

Como se ha mencionado previamente, la gamificación, al igual que otras estrategias basadas en el juego, está cobrando relevancia en la actualidad con el objetivo de mejorar la participación y la motivación de los usuarios en entornos no lúdicos.

Teniendo esto en mente y con la idea de emplear herramientas gamificadas en un entorno de uso familiar por el usuario sin necesidad de desarrollar una nueva plataforma que se añadiría a la extensa lista ya disponibles en el mercado, se planteó el uso de Telegram.

Gracias al amplio catálogo de funcionalidades, su constante evolución y mantenimiento, y la libertad que ofrece a los usuarios para desarrollar sus propios Bots y proporcionar nuevos servicios a partir de dichas funcionalidades sin un gran desarrollo por detrás, se permite que el desarrollo de servicios gamificados sea posible. Además, se facilita la colaboración de los usuarios para superar los objetivos tanto individuales como en equipo.

Adicionalmente, el uso de tecnologías NFC y códigos QR, permite complementar estos servicios, permitiendo a los usuarios interactuar también con su entorno. Esto proporciona una experiencia gamificada más completa con una mayor involucración de los usuarios.

#### 1) *Ámbito y alcance*

Aunque esta propuesta podría emplearse para desarrollar servicios gamificados en cualquier entorno no lúdico, inicialmente se considera su uso en ámbito educativo con la intención de asentar conocimiento, en particular, dentro de la rama de ciencias de la computación y de las ingenierías. Lo que se busca con ello es facilitar la comprensión del funcionamiento de ciertos componentes y/o herramientas que va a tener que emplear en la jornada laboral.

Una vez se compruebe su compatibilidad y correcto uso en estos ámbitos, esta propuesta podría aplicarse en otros ámbitos no lúdicos, tales como la medicina y el marketing, para evaluar su compatibilidad y eficacia en los mismos.

### B. Requisitos y casos de uso

En esta propuesta, se consideran dos tipos de usuario: el administrador que gestionará el correcto funcionamiento de la experiencia gamificada desarrollada para los distintos usuarios, y los usuarios que realizarán esta experiencia ya sea de forma individual o en equipo.

Entre las funciones con las que podrá interactuar el administrador, se encuentran:

- Verificar en qué actividad se encuentran los usuarios, tanto trabajan individual como en equipos.
- Obtener el número de intentos necesarios para resolver una actividad.
- Comprobar cuántas veces han hecho uso de las pistas de cada tarea.
- Validar una respuesta del usuario en caso de que no coincida con la esperada para una tarea.
- Visualizar con cuántos y cuándo han interactuado por última vez con cada NFC o código QR.

Por su parte, el usuario o equipo de usuarios podrán:

- Inscribirse en un equipo.
- Responder a las tareas.
- Solicitar pistas para cada tarea.
- Interactuar con los NFC y códigos QR.
- Decidir saltar una tarea.
- Abandonar la actividad si lo considera oportuno.

En la Fig. 1, se presenta un diagrama de casos de uso que ilustra todas las acciones posibles consideradas para cada uno de los dos tipos de usuario.