



UNIVERSIDAD TÉCNICA DE COTOPAXI
FACULTAD DE CIENCIAS DE LA INGENIERÍA Y
APLICADAS

CARRERA DE INGENIERÍA HIDRÁULICA

**“DESARROLLO DE UN MODELO DE PREDICCIÓN
METEOROLÓGICA PARA EVENTOS EXTREMOS”**

PROYECTO DE INVESTIGACIÓN PRESENTADO PREVIO A LA
OBTENCIÓN DEL TÍTULO DE INGENIERO HIDRÁULICO

Autores:

Dayana Monserrate Ruiz Tubón

Roberth Anderson Hoyos Yanangómez

Tutor:

Ing. Xiomara Alejandra Zambrano Navarrete MSc.

LATACUNGA, FEBRERO, 2025

Latacunga, febrero 21 de 2025

DECLARACIÓN DE AUTORÍA

Yo Hoyos Yanangomez Roberth Anderson y Ruiz Tubon Dayana Monserrate, declaramos ser autores del proyecto de titulación "Desarrollo de un modelo de predicción meteorológica para eventos extremos", siendo la Ing. Xiomara Alejandra Zambrano Navarrete tutora del presente trabajo de titulación; y eximimos expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

Además, certificamos que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo de titulación, son de nuestra exclusiva responsabilidad.



Hoyos Yanangomez Roberth Anderson

CC.1105116345



Ruiz Tubon Dayana Monserrate

CC.1728930023

CONTRATO DE CESIÓN NO EXCLUSIVA DE DERECHOS DE AUTOR

Comparecen a la celebración del presente instrumento de cesión no exclusiva de obra, que celebran de una parte **RUIZ TUBON DAYANA MONSERRATE**, identificado con cédula de ciudadanía No. 1728930023, de estado civil soltero, a quien en lo sucesivo se denominará **LA CEDENTE**; y, de otra parte, la Doctora Idalia Eleonora Pacheco Tigselema, en calidad de Rectora, y por tanto representante legal de la Universidad Técnica de Cotopaxi, con domicilio en la Av. 5 de Junio y Darquea, Sector La Merced, a quien en lo sucesivo se le denominará **LA CESIONARIA** en los términos contenidos en las cláusulas siguientes:

ANTECEDENTES: CLÁUSULA PRIMERA. - **LA CEDENTE** es una persona natural estudiante de la carrera de Hidráulica, titular de los derechos patrimoniales y morales sobre el trabajo de grado: **“DESARROLLO DE UN ESCENARIO DE PREDICCIÓN METEOROLÓGICA PARA EVENTOS EXTREMOS”**, la cual se encuentra elaborada según los requerimientos académicos propios de la Facultad; y, las características que a continuación se detallan:

Historial Académico

Inicio de la carrera: Abril 2021 - Agosto 2021

Finalización de la carrera: Octubre 2024 - Marzo 2025

Aprobación en Consejo Directivo: 21 de febrero del 2025

Tutor: Ing. Xiomara Alejandra Zambrano Navarrete Mg.

Tema: **“DESARROLLO DE UN MODELO DE PREDICCIÓN METEOROLÓGICA PARA EVENTOS EXTREMOS”**

CLÁUSULA SEGUNDA. - **LA CESIONARIA** es una persona jurídica de derecho público creada por ley, cuya actividad principal está encaminada a la educación superior, formando profesionales de tercer y cuarto nivel normada por la legislación ecuatoriana. La misma establece como requisito obligatorio para publicación de trabajos de investigación de grado en su repositorio institucional, hacerlo en formato digital de la presente investigación.

CLÁUSULA TERCERA. - Por el presente contrato, **La CEDENTE** autoriza a **LA CESIONARIA** a explotar el trabajo de grado en forma exclusiva dentro del territorio de la República del Ecuador.

CLÁUSULA CUARTA - OBJETO DEL CONTRATO: Por el presente contrato, **LA CEDENTE** transfiere definitivamente a **LA CESIONARIA** y en forma exclusiva los siguientes derechos patrimoniales; pudiendo, a partir de la firma del contrato, realizar, autorizar o prohibir:

- a) La reproducción parcial del trabajo de grado por medio de su fijación en el soporte informático conocido como repositorio institucional que se ajuste a ese fin.
- b) La publicación del trabajo de grado.
- c) La traducción, adaptación, arreglo u otra transformación del trabajo de grado con fines académicos y de consulta.
- d) La importación al territorio nacional de copias del trabajo de grado hechas sin autorización del titular del derecho por cualquier medio incluyendo mediante transmisión.

e) Cualquier otra forma de utilización del trabajo de grado que no está contemplada en la ley como excepción al derecho patrimonial.

CLÁUSULA QUINTA. - El presente contrato se lo realiza a título gratuito, por lo que LA CESIONARIA no se halla obligada a reconocer pago alguno. En igual sentido, EL CEDENTE declara que no existe obligación pendiente a su favor.

CLÁUSULA SEXTA. - El presente contrato tendrá una duración indefinida, contados a partir de la firma del presente instrumento por ambas partes.

CLÁUSULA SÉPTIMA - CLÁUSULA DE EXCLUSIVIDAD. - Por medio del presente contrato, se cede en favor de LA CESIONARIA el derecho a explotar la obra en forma exclusiva, dentro del marco establecido en la cláusula cuarta, lo que implica que ninguna otra persona, incluyendo EL CEDENTE, podrá utilizarla.

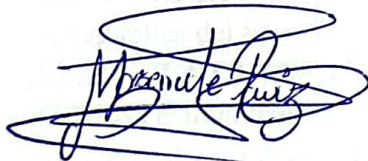
CLÁUSULA OCTAVA - LICENCIA A FAVOR DE TERCEROS. - LA CESIONARIA podrá licenciar la investigación a terceras personas, siempre que cuente con el consentimiento de EL CEDENTE en forma escrita.

CLÁUSULA NOVENA. - El incumplimiento de la obligación asumida por las partes en la cláusula cuarta constituirá causal de resolución del presente contrato. En consecuencia, la resolución se producirá de pleno derecho cuando una de las partes comunique, por carta notarial, a la otra que quiere valerse de esta cláusula.

CLÁUSULA DÉCIMA. - En todo lo no previsto por las partes en el presente contrato, ambas se someten a lo establecido por la Ley de Propiedad Intelectual, Código Civil y demás normativas jurídicas que resulten aplicables.

CLÁUSULA UNDÉCIMA. - Las controversias que pudieran suscitarse en torno al presente contrato serán sometidas a mediación, mediante el Centro de Mediación del Consejo de la Judicatura en la ciudad de Latacunga. La resolución adoptada será definitiva e inapelable, así como de obligatorio cumplimiento y ejecución para las partes y, en su caso, para la sociedad. El costo de tasas judiciales por este concepto será cubierto por la parte del estudiante que lo solicite.

En señal de conformidad, las partes suscriben este documento en dos ejemplares de igual valor y tenor en la ciudad de Latacunga, a los 19 días del mes de febrero del 2025.



Ruiz Tubon Dayana Monserrate
EL CEDENTE

Ing. Idalia Pacheco Tigselema Ph.D.
LA CESIONARIA

CONTRATO DE CESIÓN NO EXCLUSIVA DE DERECHOS DE AUTOR

Comparecen a la celebración del presente instrumento de cesión no exclusiva de obra, que celebran de una parte **HOYOS YANANGÓMEZ ROBERTH ANDERSON**, identificado con cédula de ciudadanía No. 1105116345, de estado civil soltero, a quien en lo sucesivo se denominará **EL CEDENTE**; y, de otra parte, la Doctora Idalía Eleonora Pacheco Tigselema, en calidad de Rectora, y por tanto representante legal de la Universidad Técnica de Cotopaxi, con domicilio en la Av. 5 de Junio y Darquea, Sector La Merced, a quien en lo sucesivo se le denominará **LA CESIONARIA** en los términos contenidos en las cláusulas siguientes:

ANTECEDENTES: CLÁUSULA PRIMERA. -**EL CEDENTE** es una persona natural estudiante de la carrera de Hidráulica, titular de los derechos patrimoniales y morales sobre el trabajo de grado: **“DESARROLLO DE UN ESCENARIO DE PREDICCIÓN METEOROLÓGICA PARA EVENTOS EXTREMOS”**, la cual se encuentra elaborada según los requerimientos académicos propios de la Facultad; y, las características que a continuación se detallan:

Historial Académico

Inicio de la carrera: Abril 2021 - Agosto 2021

Finalización de la carrera: Octubre 2024 - Marzo 2025

Aprobación en Consejo Directivo: 21 de febrero del 2025

Tutor: Ing. Xiomara Alejandra Zambrano Navarrete Mg.

Tema: **“DESARROLLO DE UN ESCENARIO DE PREDICCIÓN METEOROLÓGICA PARA EVENTOS EXTREMOS”**

CLÁUSULA SEGUNDA. - **LA CESIONARIA** es una persona jurídica de derecho público creada por ley, cuya actividad principal está encaminada a la educación superior, formando profesionales de tercer y cuarto nivel normada por la legislación ecuatoriana. La misma establece como requisito obligatorio para publicación de trabajos de investigación de grado en su repositorio institucional, hacerlo en formato digital de la presente investigación.

CLÁUSULA TERCERA. - Por el presente contrato, **EL CEDENTE** autoriza a **LA CESIONARIA** a explotar el trabajo de grado en forma exclusiva dentro del territorio de la República del Ecuador.

CLÁUSULA CUARTA - OBJETO DEL CONTRATO: Por el presente contrato, **EL CEDENTE** transfiere definitivamente a **LA CESIONARIA** y en forma exclusiva los siguientes derechos patrimoniales; pudiendo, a partir de la firma del contrato, realizar, autorizar o prohibir:

- a) La reproducción parcial del trabajo de grado por medio de su fijación en el soporte informático conocido como repositorio institucional que se ajuste a ese fin.
- b) La publicación del trabajo de grado.
- c) La traducción, adaptación, arreglo u otra transformación del trabajo de grado con fines académicos y de consulta.
- d) La importación al territorio nacional de copias del trabajo de grado hechas sin autorización del titular del derecho por cualquier medio incluyendo mediante transmisión.

e) Cualquier otra forma de utilización del trabajo de grado que no está contemplada en la ley como excepción al derecho patrimonial.

CLÁUSULA QUINTA. - El presente contrato se lo realiza a **título gratuito**, por lo que **LA CESIONARIA** no se halla obligada a reconocer pago alguno. En igual sentido, **EL CEDENTE** declara que no existe obligación pendiente a su favor.

CLÁUSULA SEXTA. - El presente contrato tendrá una **duración indefinida**, contados a partir de la firma del presente instrumento por ambas partes.

CLÁUSULA SÉPTIMA - CLÁUSULA DE EXCLUSIVIDAD. - Por medio del presente contrato, se cede en favor de **LA CESIONARIA** el derecho a explotar la obra en **forma exclusiva**, dentro del marco establecido en la cláusula cuarta, lo que implica que ninguna otra persona, incluyendo **EL CEDENTE**, podrá utilizarla.

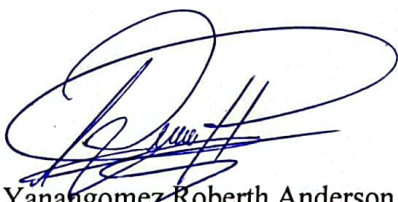
CLÁUSULA OCTAVA - LICENCIA A FAVOR DE TERCEROS. - **LA CESIONARIA** podrá licenciar la investigación a **terceras personas**, siempre que cuente con el consentimiento de **EL CEDENTE** en forma escrita.

CLÁUSULA NOVENA. - El incumplimiento de la obligación asumida por las partes en la cláusula cuarta constituirá causal de resolución del presente contrato. En consecuencia, la resolución se producirá de pleno derecho cuando una de las partes comunique, por carta notarial, a la otra que quiere valerse de esta cláusula.

CLÁUSULA DÉCIMA. - En todo lo no previsto por las partes en el presente contrato, ambas se someten a lo establecido por la Ley de Propiedad Intelectual, Código Civil y demás normativas jurídicas que resulten aplicables.

CLÁUSULA UNDÉCIMA. - Las controversias que pudieran suscitarse en torno al presente contrato serán sometidas a mediación, mediante el Centro de Mediación del Consejo de la Judicatura en la ciudad de Latacunga. La resolución adoptada será definitiva e inapelable, así como de obligatorio cumplimiento y ejecución para las partes y, en su caso, para la sociedad. El costo de tasas judiciales por este concepto será cubierto por la parte del estudiante que lo solicite.

En señal de conformidad, las partes suscriben este documento en dos ejemplares de igual valor y tenor en la ciudad de Latacunga, a los 19 días del mes de febrero del 2025.



Hoyos Yanangomez Roberth Anderson
EL CEDENTE

Ing. Idalia Pacheco Tigselema Ph.D.
LA CESIONARIA

Latacunga, febrero 21 de 2025

AVAL DEL TUTOR DEL PROYECTO DE INVESTIGACIÓN

En calidad de Tutor del Trabajo de Investigación sobre el título: "Desarrollo de un modelo de predicción meteorológica para eventos extremos", propuesto por los estudiantes Hoyos Yanangomez Roberth Anderson y Ruiz Tubon Dayana Monserrate de la Carrera de Ingeniería Hidráulica, considero que dicho proyecto de titulación cumple con los requerimientos metodológicos y aportes científico-técnicos suficientes para ser sometidos al tribunal de lectores.



Ing. Xiomara Alejandra Zambrano Navarrete, MSc.
C.C. 1313058453
TUTOR

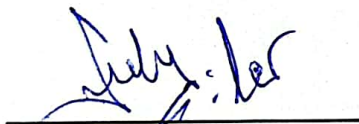
Latacunga, febrero 21 de 2025

AVAL DE APROBACIÓN DE LECTORES

Cumpliendo con el Reglamento de Titulación de la Universidad Técnica de Cotopaxi, en calidad de Lectores de Tribunal de Proyecto de Investigación con el Título "Desarrollo de un modelo de predicción meteorológica para eventos extremos", propuesto por los estudiante Hoyos Yanangomez Roberth Hoyos y Ruiz Tubon Dayana Monserrate de la Carrera de Ingeniería Hidráulica, me permito indicar que los estudiantes ha concluido todas las observaciones y realizado las correcciones señaladas por el Tribunal de Lectores, además de validar el funcionamiento de la propuesta (aplica para propuesta tecnológica), por lo cual presentamos el Aval de aprobación del Proyecto de Titulación correspondiente a la modalidad Proyecto de Titulación en virtud de lo cual los postulantes pueden presentarse a la Defensa de su Proyecto de Titulación.

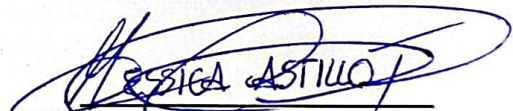
Particular que pongo en su conocimiento para los fines legales pertinentes.

Atentamente,



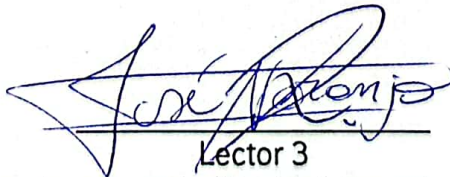
Lector 1 (Presidente)

Ing. Giler Ormazabal Andy Miguel, MSc.
CC: 1312820325



Lector 2

Ing. Castillo Fiallos Jessica Nataly, MSc.
CC: 0604590216



Lector 3

Ing. Naranjo Robalino José Ezequiel, MSc.
CC: 1804710463

AGRADECIMIENTO

Agradezco en primer lugar a Dios, por ser mi luz y mi fuerza a lo largo de este camino, por darme la fortaleza y la paz necesarias en los momentos más difíciles.

A mis padres, cuyo amor, apoyo y enseñanzas han iluminado cada paso de mi vida. Este logro les pertenece también, porque su dedicación y esfuerzo fueron el pilar que me permitió alcanzarlo. Gracias por ser mi guía y mi mayor ejemplo.

A mis hermanos, por la compañía, las risas y la fortaleza compartida en cada desafío. Su presencia constante ha hecho que este viaje sea más significativo y alegre.

A quienes me brindaron su amistad y compañerismo a lo largo de este camino. Su apoyo incondicional y su energía positiva fueron clave para superar cada etapa. Gracias por caminar a mi lado y hacer de este proceso una experiencia inolvidable.

Y esa persona especial que conocí en esta aventura y que ha estado a mi lado desde entonces. Gracias por tu cariño y apoyo constante, por ayudarme a superar mis límites y por recordarme, con tu presencia, que siempre es posible avanzar un paso más.

Este logro no es solo el resultado de mi esfuerzo personal, sino también del apoyo, cariño y el amor de aquellos que han caminado a mi lado. A todos ustedes, les agradezco profundamente.

Monserate Ruiz

AGRADECIMIENTO

A Dios, por ser mi guía y fortaleza en cada paso de este camino, por darme las fuerzas necesarias para continuar incluso en los momentos más difíciles, y por iluminar mi mente y corazón durante este proceso.

A mis padres, cuyo amor incondicional, apoyo constante y sacrificios silenciosos han sido la base sobre la que he construido cada logro. Gracias por creer en mí cuando las dudas me acechaban y por enseñarme el verdadero significado del esfuerzo y la dedicación.

A mi enamorada, por ser mi compañera en esta travesía, por su paciencia, palabras de aliento y por estar a mi lado brindándome inspiración y motivación para seguir adelante.

A mis compañeros de carrera, con quienes compartí incontables horas de estudio, debates, risas y desvelos. Juntos hemos crecido no solo como futuros profesionales, sino también como amigos, construyendo recuerdos que siempre llevaré conmigo.

A mi tutora de tesis, por su valiosa orientación, paciencia infinita y consejos certeros. Su dedicación y experiencia han sido fundamentales para culminar este proyecto, guiándome con firmeza y amabilidad en cada etapa del proceso.

A todos ustedes, gracias. Esta tesis no es solo el resultado de mi esfuerzo, sino también de todo el amor, la amistad y el conocimiento que me han rodeado.

Roberth Hoyos

DEDICATORIA

*A mi abuelito,
Quien, aunque ya no está físicamente a
mi lado, sigue presente en cada paso que
doy.*

*Hoy, con el corazón lleno de gratitud y
nostalgia, dedico este logro a tu
memoria, porque cada página de este
trabajo lleva impreso el cariño que
siempre me brindaste.*

*Nunca imaginé que la vida pudiera ser
tan efímera. Tu partida me hizo
comprender que cada minuto cuenta, que
cada palabra, cada gesto y cada
momento compartido son tesoros que
muchas veces no valoramos hasta que es
demasiado tarde. Me duele tu ausencia,
pero tu recuerdo me impulsa a seguir
adelante, superar cada obstáculo y
alcanzar todas mis metas.*

*Hoy, abuelito, lo he logrado.
Te extrañaré eternamente y siempre
llevaré en mi corazón el recuerdo de tu
incansable esfuerzo, tu espíritu luchador
y ese carácter noble que jamás se rindió
ante las dificultades.*

*Ahora entiendo que honrar tu memoria
no es solo recordarte, sino también
luchar por aquello que tanto anhelabas
para mí.*

*Gracias por ser mi fuerza, aún en la
eternidad.*

Monserate Ruiz

DEDICATORIA

*A mis queridos padres,
Este logro es tanto mío como suyo,
porque cada paso que he dado en este
camino ha sido guiado por el amor, el
esfuerzo y los valores que me han
inculcado desde el primer día.*

*A ustedes, que con sacrificio y dedicación
inquebrantable me enseñaron el
verdadero significado del trabajo duro,
la honestidad y la perseverancia. Aunque
la distancia nos separaba, su apoyo
siempre estuvo presente, en cada llamada
llena de palabras de aliento, en cada
mensaje que me recordaba que no estaba
solo, y en cada oración silenciosa que
hicieron por mí.*

*Gracias por confiar en mí, por darme la
fuerza para seguir adelante cuando las
noches se hacían largas y la nostalgia
pesaba. La distancia nunca fue un
obstáculo para sentir su amor y su
constante presencia en mi vida.*

*Este logro académico es un reflejo de
todo lo que ustedes me han dado: su fe
inquebrantable en mí, su amor infinito y
su guía silenciosa.*

*Hoy, con humildad y orgullo, les dedico
esta tesis como un pequeño homenaje a
todo lo que han hecho por mí. Porque sin
ustedes, nada de esto habría sido posible.*

*Con todo mi amor y gratitud, hoy y
siempre.*

Robert H Hoyos

UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERIA Y APLICADAS

TEMA: DESARROLLO DE UN ESCENARIO DE PREDICCIÓN METEOROLÓGICA PARA EVENTOS EXTREMOS.

Autores:

**Ruiz Tubon Dayana Monserrate
Hoyos Yanangómez Roberth Anderson**

RESUMEN

La creciente variabilidad climática, influenciada por factores globales y regionales, afecta la seguridad hídrica y la planificación agrícola en zonas vulnerables, como la provincia de Cotopaxi. En este contexto, la previsión de sequías basada en la influencia acumulada de precipitaciones, temperatura y evaporación es clave para mitigar impactos en sectores sensibles al agua, como la agricultura, los ecosistemas, la vida silvestre y la ingeniería hidráulica. Los modelos predictivos permiten evaluar la escasez de agua, identificar sequías e inundaciones. Esta investigación propone un enfoque basado en algoritmos de Machine Learning para mejorar la predicción de precipitaciones y la gestión de recursos hídricos. Se utilizaron datos del INAMHI y la NASA (2005-2017), aplicando técnicas de imputación (PMM y Missforest) y normalización de variables clave, como precipitación, temperatura, temperatura superficial del mar, humedad relativa, dirección del viento, velocidad del viento, humedad relativa y humedad específica. Los modelos fueron entrenados mediante redes neuronales en R Studio y árboles de decisión en Python, evaluados con métricas estándar: MAE, RMSE y R^2 . El estudio evaluó cuatro escenarios predictivos, destacando el Escenario 3, desarrollado con datos completos de la NASA, como el de mejor desempeño, con un MAE de 0.79, un RMSE de 1.01 y un R^2 de 0.70. Este escenario superó a los modelos basados en datos del INAMHI y mostró mayor capacidad para generalizar patrones climáticos. Su implementación representa un avance significativo en la gestión hídrica y la planificación de infraestructuras, optimizando la operación de embalses, canales de riego y la protección contra inundaciones, fortaleciendo la resiliencia comunitaria ante el cambio climático.

Palabras clave: R Studio, Python, Machine Learning, Redes Neuronales, Árbol de Decisiones.

UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERIA Y APLICADAS

TITLE: DEVELOPMENT OF A METEOROLOGICAL PREDICTION MODEL FOR EXTREME EVENTS

Authors:

**Dayana Monserrate Ruiz Tubon
Roberth Anderson Hoyos Yanangómez**

ABSTRACT

The increasing climate variability, influenced by global and regional factors, affects water security and agricultural planning in vulnerable areas such as the Cotopaxi province. In this context, drought forecasting based on the accumulated influence of precipitation, temperature, and evaporation is key to mitigating impacts on water-sensitive sectors such as agriculture, ecosystems, wildlife, and hydraulic engineering. Predictive models allow for assessing water scarcity and identifying droughts and floods. This research proposes an approach based on Machine Learning algorithms to improve rainfall prediction and water resource management. INAMHI and NASA data (2005-2017) were used, applying imputation techniques (PMM and MissForest) and normalization of key variables, such as precipitation, temperature, sea surface temperature, relative humidity, wind direction, wind speed, relative humidity, and specific humidity. The models were trained using neural networks in R Studio and decision trees in Python, and evaluated with standard metrics: MAE, RMSE, and R^2 . The study evaluated four predictive scenarios, highlighting Scenario 3, developed with complete NASA data, as the best-performing one, with an MAE of 0.79, an RMSE of 1.01, and an R^2 of 0.70. This scenario outperformed models based on INAMHI data and showed a greater ability to generalize weather patterns. Its implementation represents a significant advance in water management and infrastructure planning, optimizing the operation of reservoirs, irrigation canals, and flood protection, thereby strengthening community resilience to climate change.

Keywords: R Studio, Python, Machine Learning, Neural Networks, Decision Trees

ÍNDICE

1.	INFORMACIÓN GENERAL.....	1
1.1.	Tema del proyecto.....	1
1.2.	Modalidad de Titulación.....	1
1.3.	Carrera.....	1
1.4.	Trabajo de Titulación Vinculado al Proyecto.....	1
1.5.	Equipo de Trabajo del Trabajo de Titulación.....	1
1.5.1.	Investigadores.....	1
1.5.2.	Tutor.....	1
1.6.	Área de Conocimiento.....	1
1.7.	Línea de investigación.....	1
1.8.	Sublíneas de investigación.....	1
2.	INTRODUCCIÓN.....	2
2.1.	Situación problemática.....	3
2.2.	Formulación del problema.....	3
2.3.	Objeto y campo de acción.....	3
2.3.1.	Objeto de Investigación.....	3
2.3.2.	Campo de Acción.....	3
2.4.	Beneficiarios.....	3
2.4.1.	Directos.....	3
2.4.2.	Indirectos.....	4
2.5.	Justificación.....	4
2.6.	Objetivos.....	4
2.6.1.	General.....	4
2.6.2.	Específicos.....	4
2.6.3.	Sistemas de Tareas.....	5
3.	FUNDAMENTACIÓN TEÓRICA.....	8
3.1.	Antecedentes.....	8
4.	MARCO REFERENCIAL.....	9
4.1.	Meteorología.....	9
4.2.	Variables Meteorológicas Fundamentales.....	10

4.2.1.	Temperatura	10
4.2.2.	Presión Atmosférica.....	10
4.2.3.	Velocidad del viento	10
4.2.4.	Dirección del viento.....	10
4.2.5.	Precipitación	10
4.2.6.	Humedad Relativa.....	10
4.2.7.	Humedad Especifica	11
4.2.8.	Nubosidad	11
4.2.9.	Temperatura Superficial del Mar	11
4.3.	Predicción Meteorológica	11
4.3.1.	Tipos De Predicciones Meteorológicas	12
4.4.	Machine Learning	13
4.5.	Tipos De Aprendizaje	13
4.5.1.	Aprendizaje Supervisado	13
4.5.2.	Aprendizaje No Supervisado	15
4.5.3.	Aprendizaje por Refuerzo	16
4.5.4.	Underfitting y Overfitting.....	17
5.	Escenarios De Predicción	17
5.1.	Lenguajes de Programación.....	17
5.1.1.	Python	18
5.1.2.	R Studio	18
5.2.	Árbol de Decisión	19
5.3.	Redes Neuronales.....	20
5.3.1.	Tipos de Red Neuronal	20
5.4.	Algoritmos	22
5.4.1.	Algoritmo de Ensamble	22
5.4.2.	Algoritmo de retro-propagación	23
5.5.	Fases de proceso de Aprendizaje de los Algoritmos	23
5.5.1.	Fase de entrenamiento.....	23
5.5.2.	Fase de prueba.....	23
5.5.3.	Fase de Predicción	23

5.5.4.	Evaluación y Exactitud	23
5.5.5.	Ventajas y limitaciones de los Escenarios	24
6.	MÉTODOS Y PROCEDIMIENTOS	24
6.1.	Área de Estudio.....	24
6.2.	Esquema Metodológico	26
6.2.1.	Fase 1	26
6.2.2.	Fase 2	27
6.2.3.	Fase 3	28
6.2.4.	Fase 4	29
6.2.5.	Fase 5	30
7.	ANÁLISIS DE RESULTADOS.....	32
7.1.	Identificación de Datos Faltantes.....	32
7.1.1.	Datos INAMHI	32
7.1.2.	Datos NASA	38
7.1.3.	Escenario 1 de Predicción con Redes Neuronales Basados en Datos del INAMHI con Imputación de Datos Faltantes con pmm. match	43
7.1.4.	Escenario 2 de Predicción con Redes Neuronales Basados en datos del INAMHI con imputación de datos faltantes con Missforest	44
7.1.5.	Escenario 3 de Predicción con Redes Neuronales basada en datos de la NASA .	45
7.2.	Análisis de Rendimiento y Evaluación de Escenarios.....	46
7.2.1.	Comparación de Predicciones y Valores Reales.....	46
7.2.2.	Métricas de Evaluación en R Studio.....	52
7.2.3.	Métricas de Evaluación en Python.....	53
7.2.4.	Matriz De Correlación	53
8.	CONCLUSIONES	55
9.	RECOMENDACIONES.....	56
10.	BIBLIOGRAFIA	57
11.	ANEXOS	¡Error! Marcador no definido.
ANEXO 1.	¡Error! Marcador no definido.
ANEXO 2.	¡Error! Marcador no definido.
ANEXO 3.	¡Error! Marcador no definido.

ANEXO 4..... ¡Error! Marcador no definido.

ÍNDICE DE FIGURAS

Figura. 1 Atlas meteorológico de 1987	9
Figura. 2 Importancia relativa de las condiciones iniciales y de contorno para las predicciones según las diferentes escalas temporales	12
Figura. 3 Fuentes de datos del Machine Learning	13
Figura. 4 Aprendizaje supervisado	14
Figura. 5 Aprendizaje no supervisado	15
Figura. 6 Conjunto de datos sin valores asignados	16
Figura. 7 Conjunto de datos divididos en cuatro grupos	16
Figura. 8 Gráfico de un Escenario de Árbol	19
Figura. 9 Gráfico de Redes Neuronales	20
Figura. 10 Mapa de Ubicación Zona de Estudio.....	25
Figura. 11 Esquema Metodológico Fase 1.....	26
Figura. 12 Esquema Metodológico Fase 2.....	27
Figura. 13 Esquema Metodológico Fase 3.....	28
Figura. 14 Esquema Metodológico Fase 4.....	29
Figura. 15 Esquema Metodológico Fase 5.....	30
Figura. 16 Precipitación Mensual con Datos Incompletos	32
Figura. 17 Precipitación Mensual con Imputación de Datos utilizando Pmm.match.....	33
Figura. 18 Precipitación Mensual con Imputación de Datos utilizando Missforest	33
Figura. 19 Temperatura Mensual con Datos Incompletos.....	34
Figura. 20 Temperatura Mensual con Imputación de Datos utilizando Pmm.match.....	34
Figura. 21 Temperatura Mensual con Imputación de Datos utilizando Missforest.....	35
Figura. 22 Humedad Relativa Mensual con Datos Incompletos.....	35
Figura. 23 Humedad Relativa Mensual con Imputación de Datos utilizando Pmm.match.....	36
Figura. 24 Humedad Relativa Mensual con Imputación de Datos utilizando Missforest	36
Figura. 25 Nubosidad Mensual con Datos Incompletos	37
Figura. 26 Nubosidad Mensual con Imputación de Datos utilizando Pmm.match.....	37
Figura. 27 Nubosidad Mensual con Imputación de Datos utilizando Missforest	38
Figura. 28 Dirección del Viento Mensual según Datos de la NASA.....	39
Figura. 29 Humedad Especifica Mensual según Datos de la NASA.....	39

Figura. 30 Humedad Relativa Mensual según Datos de la NASA	40
Figura. 31 Presión Atmosférica Mensual según Datos de la NASA	40
Figura. 32 Precipitación Mensual según Datos de la NASA	41
Figura. 33 Temperatura Mensual según Datos de la NASA.....	41
Figura. 34 Temperatura Superficie del Mar Mensual según Datos de la NASA.....	42
Figura. 35 Velocidad del Viento Mensual según Datos de la NASA.....	42
Figura. 36 Estructura de la Red Neuronal con 3 Variables de Entrada (Pmm.match)	43
Figura. 37 Estructura de la Red Neuronal con 3 Variables de Entrada (Missforest).....	44
Figura. 38 Estructura de la Red Neuronal con 6 Variables de Entrada	45
Figura. 39 Comparación de Predicciones INAMHI (Pmm.match).....	47
Figura. 40 Comparación de Predicciones INAMHI (Missforest)	49
Figura. 41 Comparación de Predicciones NASA	50
Figura. 42 Comparación de Predicciones NASA	52
Figura. 43 Matriz de Correlación entre Variables Climáticas y Precipitación	54

ÍNDICE DE TABLAS

Tabla 1 Campos de la Ciencia y Tecnología UNESCO	1
Tabla 2 Campos de Acción	3
Tabla 3 Sistema de Tareas del Plan de Titulación	5
Tabla 4 Coordenadas estación meteorológica.....	25
Tabla. 5 Datos Meteorológicos INAMHI	26
Tabla. 6 Datos Meteorológicos NASA	27
Tabla 7 Configuraciones de una Red Neuronal 3 Inputs	43
Tabla 8 Configuraciones de una Red Neuronal 3 Inputs	44
Tabla 9 Configuraciones de una Red Neuronal 6 Inputs	45
Tabla 10 Valores de Precipitación INAMHI (Pmm.match)	46
Tabla 11 Comparación entre Valores de Precipitación INAMHI (Missforest)	48
Tabla 12 Comparación entre Valores de Precipitación NASA.....	49
Tabla 13 Valores de Precipitación NASA	51
Tabla 14 Métricas de Evaluación en R Studio.....	52
Tabla 15 Métricas de Evaluación en Python.....	53
Tabla 16 Interpretación de la Matriz de Correlación en Relación con la Precipitación	54
Tabla 17 Resumen de Métodos y Funciones para Imputación de Datos	¡Error! Marcador no definido.
Tabla 18 Evaluación de la Red Neuronal con 3 Inputs (INAMHI- Pmm.match).....	¡Error! Marcador no definido.
Tabla 19 Evaluación de la Red Neuronal con 3 Inputs (INAMHI-Missforest) .	¡Error! Marcador no definido.
Tabla 20 Evaluación de la Red Neuronal con 6 Inputs (NASA) ..	¡Error! Marcador no definido.

ÍNDICE DE ECUACIONES

Ecuación (1) Regresión	14
Ecuación (2) Clasificación Binaria	14
Ecuación (3) Multiclase	15
Ecuación (4) Estructura de Red Neuronal	28
Ecuación (5) Árbol de Decisiones	28
Ecuación (6) Ajuste de Temporada	29
Ecuación (7) Análisis Estacional	29
Ecuación (8) Normalización de Datos	30
Ecuación (9) Error Absoluto Medio	31
Ecuación (10) Error Cuadrático Medio.....	31
Ecuación (11) Coeficiente de Determinación.....	31
Ecuación (12) Escenario 1	43
Ecuación (13) Escenario 2	44
Ecuación (14) Escenario 3	45

1. INFORMACIÓN GENERAL

1.1.Tema del proyecto: Desarrollo de un Escenario de predicción meteorológica para eventos extremos.

1.2.Modalidad de Titulación:

Propuestas Tecnológicas

Proyectos de Investigación

1.3.Carrera: Hidráulica

1.4.Trabajo de Titulación Vinculado al Proyecto:

Gestión y uso del agua: Soluciones para Comunidades de la Zona 3

1.5.Equipo de Trabajo del Trabajo de Titulación:

1.5.1. Investigadores: Dayana Monserrate Ruiz Tubón

Roberth Anderson Hoyos Yanangómez

1.5.2. Tutor: Ing. Xiomara Alejandra Zambrano Navarrete MSc.

1.6.Área de Conocimiento:

La tabla 1 presenta los campos de la ciencia y tecnología de la UNESCO

Tabla 1 Campos de la Ciencia y Tecnología UNESCO

25 Ciencias de la Tierra y del Espacio	2508 Hidrología	2509 Meteorología	2509.04 Hidrometeorológica
			2509.09 Predicción Numérica Meteorológica
			2509.11 Predicción Operacional Meteorológica

1.7.Línea de investigación: Meteorología, hidrología, mecánica de fluidos, sistemas y obras hidráulicas.

1.8. Sublíneas de investigación: Modelación experimental y Simulación Computacional de fluidos.

2. INTRODUCCIÓN

Desde el surgimiento de la Meteorología como ciencia, ha intentado explicar el proceso de conversión de la lluvia en escorrentía a través de varias técnicas [1], todas ellas centradas en efectuar una predicción precisa de las inundaciones provocadas por las crecidas y en tratar de atenuar sus impactos negativos [2]. Pese a la variedad de métodos, los Escenarios conceptuales distribuidos son una herramienta perfecta para la simulación de sucesos de crecimiento, ya que consideran la variabilidad espacial y temporal en los distintos procesos que forman parte del ciclo del clima meteorológico [3].

Ecuador ha presenciado sucesos extremos y catástrofes naturales que han dejado marcas a lo largo del tiempo, incluyendo aquellos con repercusiones a nivel mundial[4]. Principalmente, las carencias y excesos de agua que se reflejan en los sucesos universalmente reconocidos: sequías e inundaciones [5]. Principalmente, las escasez y sobreabundancia de agua que se manifiestan en los fenómenos universalmente reconocidos: sequías e inundaciones [6]. La modelación hidrológica y climática se ha transformado en un instrumento esencial para comprender la conducta de las cuencas hidrográficas [7]. Con ella, se puede anticipar la disponibilidad de agua, detectar peligros climáticos y elaborar tácticas para atenuar las consecuencias de catástrofes naturales [8].

El clima de la Región Interandina de Ecuador es complejo, caracterizado por dos estaciones de lluvia con intensidades variadas y un impacto considerable de la Zona de Convergencia Intertropical (ZCIT) [9]. Esta variabilidad, sumada a la presión atmosférica baja y las corrientes de aire continental, provoca precipitaciones complicadas de anticipar [10], particularmente en zonas que superan los 3,500 metros de altitud, donde predominan lluvias prolongadas y de baja intensidad [11], en la provincia de Cotopaxi, concretamente en el cantón Sigchos, en la parroquia San Francisco de las Pampas, lugar donde se ubica la estación meteorológica Las Pampas [12].

Es esencial desarrollar un Escenario de predicción de lluvias en la Región Interandina para enfrentar los retos que supone la variabilidad climática en este territorio [13]. Posibilitará predecir los patrones, lo que ayudará a la organización agrícola y asegurar el aprovechamiento eficaz de los recursos hídricos especialmente en zonas con escasa precipitación [14]. Además, ayudará a reducir los riesgos vinculados a sucesos extremos.

2.1. Situación problemática

Los impactos del cambio climático están alterando los patrones locales de agua, lo que aumenta la intensidad, así como la frecuencia de inundaciones y sequías extremas. Estos cambios están afectados por la Zona de Convergencia Intertropical (ZCIT) [9] por lo tanto, ocurre lo mismo con la elevación del aire que resulta en nubosidad y altas precipitaciones. En otras palabras, causa un impacto directo en la seguridad hídrica, los ecosistemas en las zonas circundantes y el sistema de vida y actividades económicas y agrícolas, haciendo vulnerables a las comunidades [15]. Es importante desarrollar herramientas predictivas que permitan anticipar eventos extremos de precipitaciones y diseñar estrategias preventivas para mitigar sus impactos.

2.2. Formulación del problema

El cambio climático modifica los patrones hidrológicos, lo que aumenta la incertidumbre sobre la disponibilidad de agua y la frecuencia de eventos extremos en el área de influencia de la estación M0362.

2.3. Objeto y campo de acción

2.3.1. Objeto de Investigación

Escenario de Predicción Hidrológica

2.3.2. Campo de Acción

La tabla 2 presenta los campos de acción.

Tabla 2 Campos de Acción

2508 Hidrología	
2508.10	Precipitación
2509	Meteorología
2509.04	Hidrometeorología
2509.09	Predicción Numérica Meteorológica

2.4. Beneficiarios

2.4.1. Directos

Proyecto Hidroeléctrico Toachi Pilatón y cantón Sigchos

2.4.2. Indirectos

Cantones Mejía, Santo Domingo de los Tsáchilas (Provincias de la zona 3, Pichincha, Santo Domingo de los Tsáchilas y Cotopaxi.

2.5. Justificación

La importancia y adecuación de un Escenario matemático radican en la necesidad urgente de comprender y abordar los efectos del cambio climático en el ciclo hidrológico [16], especialmente en regiones vulnerables como la interandina, donde los fenómenos de inundaciones y sequías afectan directamente la infraestructura, la seguridad hídrica y la calidad de vida de las comunidades locales. El proyecto responde a objetivos globales relacionados con la adaptación al cambio climático y la resiliencia frente a fenómenos climáticos extremos.

La utilidad de los resultados esperados será tangible en varios ámbitos. En el corto plazo, los Escenarios predictivos desarrollados permitirán anticipar eventos hidrológicos extremos [17], lo que contribuirá a la toma de decisiones informadas en la gestión del territorio, la infraestructura y la protección de comunidades vulnerables. La investigación generará una base científica y metodológica que permitirá fortalecer la capacidad de adaptación y mitigación ante el cambio climático en el corto plazo [18]. De esta forma, el proyecto no solo busca generar conocimiento, sino también soluciones prácticas y aplicables que beneficien directamente a las personas y al entorno ante eventos extremos.

2.6. Objetivos

2.6.1. General

- Desarrollar un Modelo de predicción meteorológico basado en algoritmos programados en Python y R Studio, para la prevención de eventos extremos.

2.6.2. Específicos

- Identificar valores faltantes en los datos meteorológicos del INAMHI y la NASA para aplicación de técnicas de imputación en las variables necesarias para la predicción.
- Diseñar Escenarios de predicción meteorológica en Python y R Studio a partir de bases de datos previamente tratadas, implementando algoritmos de Machine Learning para la predicción de eventos extremos.
- Seleccionar el Escenario con mejor desempeño mediante el uso de métricas estándar y

un análisis comparativo, para identificar la opción más adecuada en la predicción de eventos meteorológicos extremos.

2.6.3. Sistemas de Tareas

A continuación, en la Tabla 3 se presenta el sistema de tareas asignadas dentro del plan de titulación, detallando los objetivos específicos, actividades, resultados esperados y los medios empleados para su desarrollo.

Tabla 3 Sistema de Tareas del Plan de Titulación

Objetivos específicos	Actividades (tareas)	Resultados esperados	Técnicas, Medios e Instrumentos
<p>Identificar valores faltantes en los datos meteorológicos del INAMHI y la NASA para aplicación de técnicas de imputación en las variables necesarias para la predicción.</p>	<ul style="list-style-type: none"> • Recolectar datos meteorológicos por medio de una base de datos proporcionada por el INAMHI de la estación M362. • Obtener datos meteorológicos adicionales de las bases de datos de la NASA. • Revisar todos los datos meteorológicos obtenidos valores atípicos y patrones de datos faltantes. <ul style="list-style-type: none"> - Aplicar técnicas de visualización 	<p>Base de datos integral y confiable sin patrones de datos faltantes, con una serie de datos desde los años 2005 a 2017.</p>	<ul style="list-style-type: none"> • Software de análisis y relleno de datos R Studio. • Librerías Utilizadas: Pmm.match. • Técnicas Aplicadas: Relleno de Datos Análisis y Normalización de Datos.

	<p>para evaluar la distribución de los datos y posibles inconsistencias.</p> <ul style="list-style-type: none"> • Desarrollar un código específico que permitan rellenar de manera eficiente los datos faltantes. 		
<p>Diseñar Escenarios de predicción meteorológica en Python y R Studio a partir de bases de datos previamente tratadas, implementando algoritmos de Machine Learning para la predicción de eventos extremos.</p>	<ul style="list-style-type: none"> • Seleccionar las variables de entrada de la base de datos tratada. • Programar y configurar la red neuronal, incluyendo la codificación de la retroalimentación y ajuste de parámetros para optimizar el aprendizaje. • Realizar varias iteraciones de entrenamiento para ajustar el 	<p>Escenarios matemáticos Red Neuronal y Árbol de Decisión</p>	<ul style="list-style-type: none"> • Machine Learning. • Software Python Árbol de Decisión y R studio para redes neuronales y plataformas de aprendizaje supervisado y automático. • Librerías Utilizadas R Studio: Pacman, tidyverse, Caret, Lubridate, Metrics, ggplot2, dplyr, neuralnet. • Técnicas Aplicadas: Perceptron • Librerías Utilizadas Python:

	<p>Escenario, buscando la configuración más adecuada que maximice la precisión del Escenario.</p>		<p>Pandas, lightgbm (LGBMRegressor), sklearn (scikit-learn), numpy.</p> <ul style="list-style-type: none"> • Técnicas Aplicadas: Light Gradient Boosting Machine
<p>Seleccionar el Escenario con mejor desempeño mediante el uso de métricas estándar y un análisis comparativo, para identificar la opción más adecuada en la predicción de eventos meteorológicos extremos.</p>	<ul style="list-style-type: none"> • Métricas de evaluación: Error cuadrático medio (MSE). Error absoluto medio (MAE). Coeficiente de determinación (R^2). 	<p>Escenario con el mejor rendimiento para su aplicación final en predicciones meteorológicas.</p>	<ul style="list-style-type: none"> • Software R Studio y Python.

3. FUNDAMENTACIÓN TEÓRICA

3.1. Antecedentes

La predicción de precipitaciones ha sido ampliamente estudiada mediante métodos estadísticos y aprendizaje automático. Singh et al. [19] investigaron redes neuronales de retro-propagación para pronosticar lluvias mensuales y estacionales en la India, utilizando datos históricos (1871-2010).

La viabilidad de las Redes Neuronales Artificiales (RNA) como modelo predictivo del Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) mensual en ocho estaciones, utilizando datos históricos de 1915 a 2005 para el entrenamiento y datos simulados del período 2006-2012. Se desarrollaron 30 modelos ANN de tres capas, optimizados mediante los algoritmos de retro-propagación cuasi-Newton de Levenberg–Marquardt y Broyden–Fletcher–Goldfarb–Shanno (BFGS). La mejor arquitectura incluyó 18 neuronas de entrada, 43 ocultas y 1 de salida, con funciones de activación sigmoideas tangentes. El rendimiento del modelo, evaluado con métricas estadísticas, mostró un coeficiente de determinación entre 0.9945 y 0.9990, un RMSE entre 0.0466 y 0.1117, y un MAE entre 0.0013 y 0.0130, destacando su alta precisión para pronosticar eventos mensuales de sequía y sus propiedades asociadas[20].

Kim et al. [21] aplicaron redes LSTM para predicciones horarias en Gangwon-do, Corea, con datos meteorológicos de 2012. Su Escenario superó a las redes neuronales tradicionales (ANN) en precisión, aunque enfrentó problemas de sobreajuste al considerar mediciones de vapor de agua. Chao. Z, comparó cinco enfoques, destacando que las redes LSTM obtenían los mejores resultados en métricas como RMSE y MAE [22].

Las exactitudes predictivas alcanzadas con las redes neuronales tienden a ser considerablemente superiores a las alcanzadas con otros métodos de aprendizaje. Estudios actuales en el entendimiento del funcionamiento de una red neuronal entrenada se han enfocado en la obtención de reglas simbólicas [23].

Kumar evaluó redes RNN y LSTM para predicciones mensuales en India (1871-2016), demostrando la eficiencia del Escenario LSTM con mejores métricas (RMSE, MAE, NSE) [24].

Poornima et al. [25] desarrollaron un Escenario Intensified LSTM para lluvias diarias en Hyderabad, India (1980-2014), superando otros enfoques como ARIMA y Extreme Learning Machine en precisión y tasa de aprendizaje.

Cay [26] desarrolló un Escenario de ARN fundamentado en el algoritmo de retro propagación para un MEP, con la finalidad de estimar el consumo de combustible específico del freno, la potencia efectiva y la temperatura de escape del motor.

Las redes neuronales poseen múltiples usos en la calibración de motores de arranque por chispa. R. F. Turkson et al. [27] han sugerido que estas facilitan el reconocimiento del sistema para el prototipado rápido, la detección virtual, tácticas de control emergentes y aplicaciones de diagnóstico a bordo (OBD).

En general, las investigaciones resaltan la efectividad de las redes neuronales en predicciones de precipitaciones, especialmente por su capacidad para manejar dependencias temporales en series de datos.

4. MARCO REFERENCIAL

4.1.Meteorología

La meteorología es una disciplina que, dentro del campo de la física, analiza la atmósfera y los sucesos que se producen en ella, junto con las normativas que los regulan, con el objetivo de efectuar proyecciones futuras. Elementos como el clima, el tiempo, los vientos, las precipitaciones, los granizos, la nieve, los rayos, las tormentas, la creación de nubes y su progreso son algunos de los elementos fundamentales de este ámbito, ver la Figura 1 del Atlas Meteorológico de 1987.




Figura. 1 Atlas meteorológico de 1987 [28]

4.2. Variables Meteorológicas Fundamentales

Son parámetros responsables de describir el estado del tiempo, son cuantificables y su comportamiento nos permitirá conocer la condición atmosférica en ese momento [28].

4.2.1. Temperatura

Indica el grado de calor del aire y es un factor determinante en la evaporación y condensación del agua en la atmósfera. La temperatura afecta directamente la capacidad del aire para retener vapor de agua, influyendo en la humedad relativa y en la formación de precipitaciones [29].

4.2.2. Presión Atmosférica

Es la fuerza que ejerce el peso de la columna de aire sobre una unidad de superficie en la Tierra. Se mide en milibares (mb) o hectopascales (hPa). Las variaciones en la presión atmosférica influyen en los patrones de viento y en la formación de sistemas meteorológicos que afectan el ciclo hidrológico [29].

4.2.3. Velocidad del viento

Se refiere a la medida de la velocidad de movimiento del aire en el ambiente. Generalmente se manifiesta en kilómetros por hora (km/h) o metros por segundo (m/s). La velocidad del viento influye en la evaporación y en la distribución de la humedad atmosférica, afectando procesos hidrológicos como la formación de nubes y la dispersión de contaminantes [29].

4.2.4. Dirección del viento

Indica la procedencia del viento, es decir, el punto cardinal desde donde sopla. Se expresa en grados a partir del norte geográfico: viento del norte (0°), del este (90°), del sur (180°) y del oeste (270°) [30].

4.2.5. Precipitación

Son todas las formas de agua, líquida o sólida, que caen de la atmósfera y alcanzan la superficie terrestre, incluyendo lluvia, nieve, granizo y neblina. La precipitación es un proceso meteorológico fundamental en hidrología, ya que, junto con la evaporación, constituye la forma en que la atmósfera interactúa con el agua superficial en el ciclo hidrológico [31].

4.2.6. Humedad Relativa

Es el porcentaje que indica la cantidad de vapor de agua presente en el aire en relación con la cantidad máxima que podría contener a una temperatura específica. Una humedad relativa alta puede favorecer la formación de nubes y precipitaciones, mientras que una baja indica condiciones más secas [32].

4.2.7. Humedad Especifica

Es la relación entre la masa de vapor de agua y la masa total de aire húmedo, generalmente expresada en gramos de vapor de agua por kilogramo de aire. Este parámetro es crucial en hidrología para entender la cantidad de vapor de agua presente en la atmósfera y su influencia en procesos como la formación de nubes y precipitaciones [32].

4.2.8. Nubosidad

La nubosidad es la fracción de cielo cubierto con nubes, en un lugar en particular, se refiere a la porción del cielo revestida de nubes, en un sitio específico. Se manifiesta en octas, u octavos del círculo celeste. Se cree que el observador divide el cielo en 8 secciones, las cuales evalúa y señala el porcentaje de cielo que está revestido de nubes [33].

4.2.9. Temperatura Superficial del Mar

La temperatura superficial del mar (TSM) es la temperatura del agua en la capa más externa del océano, generalmente entre 1 mm y 5 metros de profundidad. Esta variable es clave para estudios climáticos, meteorológicos, oceanográficos y ecológicos [34].

4.3. Predicción Meteorológica

La predicción climática fundamentada en la ciencia no emergió hasta la mitad del siglo XIX, bajo la guía de un destacado astrónomo de aquel tiempo: Urbain Le Verrier, francés [35]. En esa época, ya se realizaban observaciones meteorológicas diarias en las ciudades más importantes de Europa, aunque aún no se disponía de la habilidad para realizar pronósticos. Esta situación se transformó rápidamente debido al avance del telégrafo y a un suceso climático acontecido durante un conflicto bélico.

En la segunda mitad del siglo XIX y las primeras décadas del XX, las estaciones telegráficas compartieron instalaciones con los observatorios meteorológicos propios, lo que permitió que los meteorólogos de distintos países iniciaran las primeras predicciones. Sin embargo, tuvieron que pasar varias décadas más hasta que comenzó la predicción numérica del tiempo; fundamentada en los Escenarios que sustentan los pronósticos en el presente.

Los Escenarios actuales no cesan de progresar, incrementando su complejidad con cada día que transcurre. Todo esto ha sido factible gracias a la extraordinaria capacidad de cálculo que los ordenadores han ido desarrollando durante poco más de 60 años [36].

4.3.1. Tipos De Predicciones Meteorológicas

4.3.1.1. Diarias

Las predicciones meteorológicas diarias se basan en datos actuales y Escenarios numéricos para anticipar las condiciones atmosféricas. Son fundamentales para la planificación en sectores como la agricultura, la aviación y la gestión de emergencias, proporcionando información crucial para decisiones importantes [37].

4.3.1.2. Mensual

La predicción mensual examina la predictibilidad en un intervalo de 10 a 30 días, tratando cuestiones de pronóstico de tiempo a largo plazo y estacional. Desde hace diez días, las fluctuaciones oceánicas afectan la atmósfera, por lo que los Escenarios deben tener en cuenta esta interacción [37].

4.3.1.3. Estacional

Facilita la predicción del estado medio atmosférico para los meses venideros, informando acerca de las tendencias climáticas. En contraposición a una simulación climática, se fundamenta en las primeras observaciones del sistema [38]. Conforme se expande el espectro de predicción, las condiciones iniciales se desvanecen y los factores externos adquieren importancia en la progresión del sistema climático.

La Figura 2 ilustra la relevancia relativa de las condiciones iniciales y de contorno en las proyecciones de acuerdo a diversas escalas temporales, demostrando cómo su impacto cambia con el periodo de pronóstico.




Figura. 2 Importancia relativa de las condiciones iniciales y de contorno para las predicciones según las diferentes escalas temporales [39]

de entrenamiento. El panorama generado se examina utilizando datos de prueba, lo que conduce a un porcentaje de precisión en la proyección. Este proceso es iterativo, ya que busca mejorar el Escenario hasta que satisfaga las demandas del problema.

La Figura 4 presenta la estructura del aprendizaje supervisado, resaltando la manera en que el Escenario modifica sus parámetros basándose en ejemplos identificados.

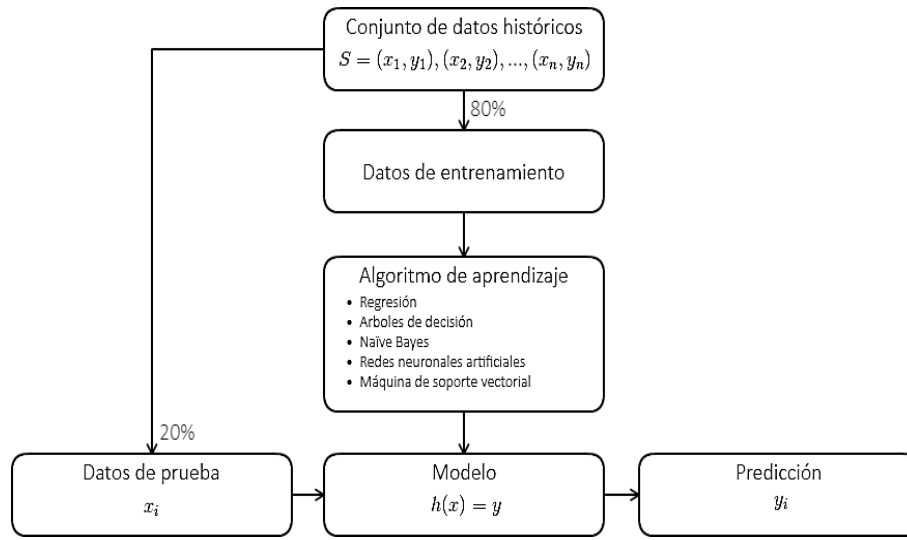


Figura. 4 Aprendizaje supervisado [40]

4.5.1.1. Regresión

El objetivo de la educación de regresión supervisada es prever valores numéricos [40]. En este tipo de actividad, las características son valores constantes, tal como se ilustra en la ecuación (1).

$$y \in \mathbb{R} \quad (1)$$

4.5.1.2. Clasificación

El aprendizaje supervisado de carácter clasificatorio implica prever el nombre o categorización de un elemento o individuo en función de las propiedades que los distinguen, hace referencia a sucesos discretos. La complicada clasificación se divide en binaria y multiclase [40].

Binaria: Cuando únicamente existen dos clases disponibles, tal como se señala en la ecuación (2).

$$y \in \{0, 1\} \quad (2)$$

Multiclase: Cuando existen más de dos categorías, como se expresa en la ecuación (3).

$$y \in \{0, 1, 2, 3, \dots, n\} \quad (3)$$

4.5.2. Aprendizaje No Supervisado

El aprendizaje no supervisado utiliza datos compuestos únicamente por el vector de entrada $x = (x_1, x_2, \dots, x_n)$, sin un vector de salida y , lo que significa que no se dispone de un conjunto de datos de entrenamiento, lo que resulta en la ausencia de un porcentaje de predicción. A diferencia del aprendizaje supervisado, este enfoque no requiere datos etiquetados. El algoritmo analiza la información proporcionada y genera un Escenario capaz de detectar estructuras o patrones ocultos. Estos patrones se utilizan posteriormente para clasificar o agrupar nuevos datos de entrada.

La Figura 5 ilustra este proceso, mostrando cómo el aprendizaje no supervisado organiza la información sin intervención humana.

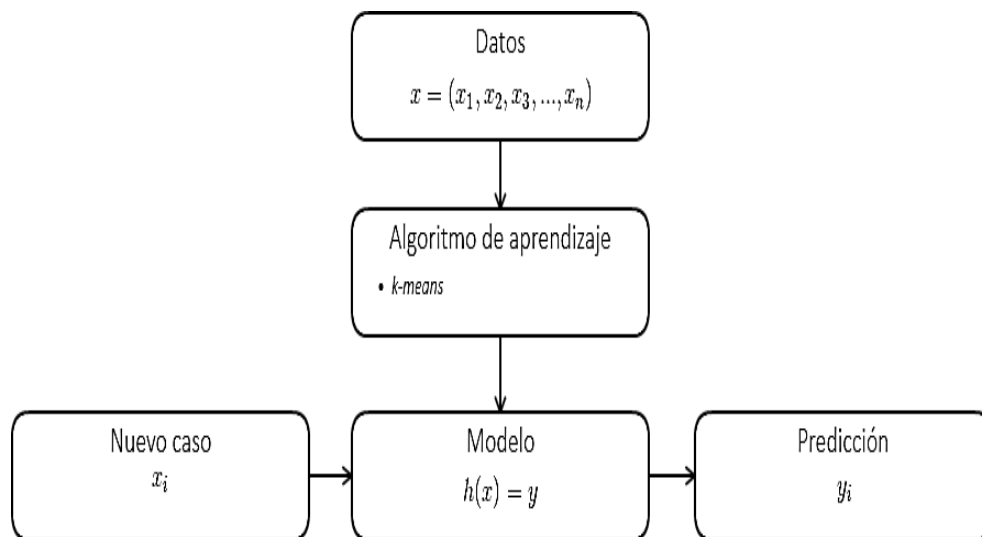


Figura. 5 Aprendizaje no supervisado [40]

El aprendizaje no supervisado es útil para tareas de clustering (agrupamiento)

4.5.2.1. Clustering

Método para identificar conjuntos de objetos de manera que los elementos en un conjunto sean parecidos (o vinculados) entre ellos y que sean distintos (o no vinculados) a los elementos en otros conjuntos. Es un método de enseñanza, en estas situaciones, se entrega a la máquina un conjunto de datos, sin especificar explícitamente cómo utilizarlos ni cuál es el punto de inicio [40].

La Figura 6 muestra un ejemplo de datos sin valores asignados, representando un escenario común en el aprendizaje no supervisado.




Figura. 6 Conjunto de datos sin valores asignados [40].

La Figura 7 presenta grupos de datos segmentados en cuatro grupos, los cuales se distinguen porque sus datos tienen las mismas propiedades entre sí y son distintos a los datos de los demás grupos.




Figura. 7 Conjunto de datos divididos en cuatro grupos [40]

4.5.3. Aprendizaje por Refuerzo

El aprendizaje por refuerzo (RL) es otra de las categorías en las que se clasifican los algoritmos de aprendizaje automático. El método Q-learning empleado en esta técnica ha conseguido superar a jugadores humanos expertos en juegos tradicionales como las damas, el ajedrez, así como en una amplia gama de los juegos de ATARI [41].

Los algoritmos de aprendizaje por refuerzo se basan en el proceso de decisión de Markov, donde un conjunto de estados S , un conjunto de acciones A , una función de recompensa $r(a, A)$, un Escenario de transición $P(s' | s, a)$ y un factor de descuento γ . Por cada decisión tomada por el agente $a \in A$, se recibe una recompensa r y el agente alcanza un nuevo estado s' . Los métodos de

aprendizaje por refuerzo implementan una política $\pi (a | s)$ que mapea cada espacio de estados al espacio de acciones [42].

4.5.4. Underfitting y Overfitting

El objetivo de un Escenario de Machine Learning consiste en aprender de datos que ya se tienen para poder generalizar a futuros nuevos datos de una forma apropiada. Uno de los principales problemas con los que se ha de lidiar es conseguir un equilibrio entre underfitting y overfitting, o lo que es lo mismo, entre sesgo y varianza. Cabe mencionar que una práctica generalizada en Machine Learning consiste en dividir los datos de la muestra en dos conjuntos: el de entrenamiento y el de test [43]. El Escenario se elabora con el conjunto de entrenamiento y los resultados se verifican con el conjunto de test, es decir, se verifica la conducta del Escenario con datos inéditos. Si disponemos de datos etiquetados, es posible evaluar el riesgo empírico utilizando los datos de entrenamiento o los datos de prueba. Es probable que el Escenario se adapte de manera más efectiva a los datos de entrenamiento, dado que son información conocida. No obstante, puede suceder todo lo contrario. O también puede suceder que un Escenario sea extremadamente exacto en el entrenamiento, pero en el examen se registre un error de gran magnitud.

El sesgo estadístico se refiere a la incapacidad de un Escenario de Machine Learning para determinar la relación real entre los datos. La varianza de un Escenario de ML se caracteriza por la variación en la exactitud al estimar diversos grupos de datos [44]

5. Escenarios De Predicción

Un Escenario se compone de un grupo de ecuaciones matemáticas que necesitan cálculos complejos, los cuales son responsabilidad de los ordenadores más potentes que existen hoy en día. Esas ecuaciones consideran los procesos que ocurren en la atmósfera, como el desplazamiento de las masas de aire, la energía involucrada o los procesos termodinámicos involucrados, y se aplican a miles de puntos distribuidos a lo largo y ancho de una malla ficticia que engloba toda la atmósfera [36].

5.1.Lenguajes de Programación

En el campo del análisis de datos y aprendizaje automático, Python y R Studio se han establecido como los lenguajes de programación de mayor uso. Ambos proporcionan instrumentos potentes para el manejo de datos, modelado estadístico y aprendizaje automático, aunque cada uno posee propiedades específicas que los hacen más apropiados para distintas actividades.

5.1.1. Python

Python es un lenguaje de codificación dinámico e interpretativo (codificado en bytes). En el código base, no se encuentran declaraciones de tipos para variables, parámetros, funciones o procesos.

Esto permite mantener el código corto y adaptable, evitando la necesidad de verificar los tipos durante la compilación del código original. Python rastrea todos los tipos de valores durante el tiempo de ejecución y señala el código que carece de sentido al ejecutarse [45].

Es un Escenario de lenguaje de alto nivel; otros Escenarios de lenguajes de alto nivel incluyen C, C++, Perl y Java. Como podemos inferir de la denominación "lenguaje de alto nivel", también hay lenguajes de bajo nivel, a los que también se les denomina lenguajes de máquina o lenguajes de ensamblaje. Por objetivo, los ordenadores solo operan con programas redactados en lenguajes de nivel básico. Es necesario que los programas de alto nivel sean traducidos antes de su ejecución. Esta traducción requiere tiempo, lo que representa un inconveniente mínimo en los lenguajes de alto nivel. Es mucho más sencillo programar en lenguajes de alto nivel; redactar programas en un lenguaje de alto nivel demanda menos tiempo, los programas son más breves y de fácil lectura, y es más probable que estos programas sean precisos. En segundo lugar, los lenguajes de alto nivel son portables, lo que implica que pueden funcionar en distintos tipos de ordenadores sin ninguna alteración o con escasas modificaciones [46]. Los programas diseñados en lenguajes de nivel básico solo pueden funcionar en un tipo de ordenador y necesitan ser reconfigurados para funcionar en otro.

5.1.2. R Studio

R es un lenguaje Orientado a Objetos: bajo este complicado concepto se oculta la sencillez y adaptabilidad de R. La idea de que R es un lenguaje de programación puede desconcertar a muchos usuarios que creen que no poseen conocimientos o "alma de programadores" [47]. Esto no es inherentemente verdad por dos motivos. R, en primer lugar, es un lenguaje interpretado (como Java) y no compilado (como C, C++, Fortran, Pascal), lo que implica que las instrucciones escritas en el teclado se ejecutan directamente sin la necesidad de crear ejecutables. Como segunda evaluación, la sintaxis de R resulta sumamente sencilla e intuitiva [48].

R es una serie unificada de programas destinados a la gestión de datos, cálculo y gráficos [49], entre sus características cuenta con:

- Guardado y gestión eficaz de datos.
- Operadores de cálculo en variables indexadas (Arrays), especialmente en matrices.

- Un conjunto extenso, consistente e integrado de herramientas para el análisis de datos.
- Herramientas visuales para el análisis de información, que operan directamente en la pantalla o impresora.
- Un lenguaje de programación robusto, sencillo y eficaz, que incorpora condicionales, ciclos, funciones de replicación y la opción de entradas y salidas. (Es importante resaltar que gran cantidad de las funciones proporcionadas por el sistema están redactadas en el lenguaje R).

5.2.Árbol de Decisión

Son Escenarios exactos, constantes y de fácil interpretación, principalmente porque establecen unas normas de decisión que pueden ser representadas como un Árbol. Por otro lado, los Escenarios lineales pueden representar conexiones no lineales para resolver problemas. En estos patrones, predominan principalmente los árboles de decisión y los bosques Random. Al ser más exactos y detallados, evidentemente incrementamos nuestra capacidad de predicción, pero perdemos en eficiencia [39].

La Figura 8 muestra el gráfico de un Escenario de árbol, mostrando visualmente cómo se estructuran las decisiones y ramificaciones en este tipo de algoritmos.




Figura. 8 Gráfico de un Escenario de Árbol [39]

5.3.Redes Neuronales

Las redes neuronales artificiales intentan, de alguna manera, emular el funcionamiento del cerebro, donde contamos con millones de neuronas vinculadas en red para transmitir mensajes entre sí. Esta imitación del funcionamiento cerebral humano es uno de los "paradigmas actuales" debido a las capacidades cognitivas de pensamiento que desarrollan. Es complicado reconocer imágenes y vídeos, una red neuronal es óptima para efectuar identificaciones. El problema, al igual que ocurre con el cerebro humano, es que las neuronas son lentas en su formación y necesitan una elevada habilidad computacional. Tal vez sea uno de los patrones que ha obtenido mayores beneficios con la "revolución de los datos" [39].

La Figura 9 muestra un gráfico de una red neuronal, ilustrando la estructura de sus capas y conexiones en el proceso de aprendizaje.




Figura. 9 Gráfico de Redes Neuronales [50]

5.3.1. Tipos de Red Neuronal

Las redes neuronales se clasifican en función de varios factores, como su profundidad, el número de capas ocultas y las capacidades de E/S de cada nodo.

5.3.1.1.Redes Neuronales Convolucionales

Como un escenario de red neuronal muy conocido, las redes neuronales convolucionales utilizan el perceptrón multicapa de Naciones Unidas, que incluye una o varias capas convolucionales. Estas capas pueden estar unidas de manera autónoma. Este escenario de neurona roja emplea fundamentos del álgebra lineal, en particular la multiplicación de matrices Delaware, para identificar y manejar patrones en las imágenes. Las capas convolucionales de este escenario tienen la capacidad de generar mapas de atributos que engloban un área concreta dentro de una entrada visual. Luego, el área se desglosa y examina para obtener resultados útiles [50]. Las Redes

neuronales convolucionales resultan ventajosas para las aplicaciones de identificación de imágenes basadas en Inteligencia Artificial. Este tipo de red neuronal suele emplearse en situaciones de uso sofisticadas como el reconocimiento facial.

5.3.1.2.Redes Neuronales Desconvolucionales

Las Redes neuronales de convolución operan de acuerdo a los mismos fundamentos que las Redes convolucionales, pero en sentido contrario. El propósito de esta aplicación particular de la Inteligencia Artificial es identificar señales y orígenes perdidos que podrían haber sido ignorados previamente por no ser relevantes mientras la red neuronal convolucional realizaba la labor que le habías sido asignada [50]. Las redes neuronales de deconvolución resultan beneficiosas para varias aplicaciones, tales como el análisis y la creación de imágenes.

5.3.1.3.Redes Neuronales Recurrentes

Este avanzado Delaware rojo Escenario neuronal funciona salvaguardando la salida generada por sus nudos procesadores y retornándola al algoritmo. Este método permite que las redes neuronales recurrentes mejoren su capacidad para anticipar. En esta red neuronal, cada nodo desempeña el papel de una célula de memoria. Estas células trabajan arduamente para garantizar que las Naciones Unidas sean capaces de calcular y utilizar de forma inteligente los datos recabados. Sin embargo, lo que hace único a este Escenario es su capacidad para recopilar y utilizar nuevamente todos los datos tratados. Una de las características de una red neuronal recurrente es la presencia de un potente ciclo de retroalimentación por parte de las Naciones Unidas [51]. Estas redes neuronales tienen la capacidad de "auto aprender" de sus fallos. Si se realiza una predicción errónea, el sistema toma nota de la retroalimentación y se empeña en realizar la predicción adecuada mientras los datos son sometidos al algoritmo por segunda vez.

5.3.1.4.Redes Neuronales Prealimentadas

Esta variante básica de red neuronal permite que los datos se desplazan en una única dirección a través de diversos nodos de procesamiento hasta que alcanzan el nodo de salida. Las Redes neuronales de alimentación-atrás están concebidas para manejar grandes cantidades de datos "ruidosos" y generar resultados "puros". Este tipo de perceptrones multicapa de Delaware también se conoce como Escenario Delaware perceptrones (MLP). La estructura de una alimentación neuronal roja comprende la capa de entrada, unas capas ocultas y la capa de salida. A pesar de su nombre alternativo, estos Escenarios utilizan neuronassigmoidales en lugar de perceptrones, lo que les permite abordar problemas no lineales del mundo real [52]. Las redes Alimentación neuronal-

adelante son la base del reconocimiento facial, el procesamiento del lenguaje natural, la visión por ordenador y otros Escenarios de redes neuronales.

5.3.1.5.Redes Neuronales Modulares

Las redes neuronales modulares estables de una serie de redes neuronales autónomas cuyas operaciones están bajo la supervisión intermedia de las Naciones Unidas. Cada rojo independiente es un "módulo" de Naciones Unidas que emplea distintas entradas para completar una porción específica del objetivo general Delaware, la roja más grande. Los módulos no se comunican entre ellos ni perturban los procesos de los demás durante el proceso de cálculo[53]. Esto permite que la implementación de Delaware procesos informáticos amplios y complejos se realice de manera más eficaz y veloz.

5.3.1.6.Redes Neuronales Adversariales

Las redes adversariales generativas son una alternativa de modelado generativo que utiliza las Redes neuronales convolucionales y otras propuestas de aprendizaje profundo de Delaware para automatizar la identificación de patrones en la información. El modelado generativo emplea el aprendizaje no supervisado para llegar a conclusiones factibles a partir de un conjunto de datos únicos. Las Redes generativas adversarias entrenan Escenarios generativos, generando el "problema Delaware de aprendizaje supervisado" de Naciones Unidas, que incluye un Escenario generacional dormido y único Escenario discriminador. El primero está listo para extraer nuevas conclusiones desde el inicio. A la vez, el segundo intenta categorizar las conclusiones obtenidas como "reales" (provenientes del conjunto de datos de Delaware) o "falso como" (producidas por El algoritmo) [54]. Cuando el Escenario discriminador etiqueta erróneamente las conclusiones producidas alrededor de la mitad de Delaware, en ocasiones, el Escenario generador genera conclusiones que son plausibles.

5.4.Algoritmos

5.4.1. Algoritmo de Ensamble

El regresor Light Gradient Boosting Machine (LightGBM) es un innovador enfoque de aprendizaje por conjuntos basado en árboles desarrollado por investigadores de Microsoft y la Universidad de Pekín para superar las dificultades de eficiencia y escalabilidad de XGBoost en contextos de características de entrada de alta dimensión y conjuntos de datos masivos. La técnica LightGBM se compone de dos enfoques principales: la formación de características exclusivas (EFB) y el muestreo unilateral basado en gradientes (GOSS) [55].

5.4.2. Algoritmo de retro-propagación

El algoritmo de propagación de regresión es el más utilizado en redes con conexión orientada hacia el futuro. Es un método de aprendizaje supervisado de gradiente descendente, en el que se pueden distinguir claramente dos fases: en primer lugar, se aplica un patrón de entrada, que se propaga por las distintas capas de la red hasta producir la salida de la misma. Esta respuesta se compara con la respuesta anticipada y se establece el error que cada neurona de respuesta ha cometido. Estos errores se transmiten de regreso, desde la capa de salida hasta todas las neuronas de las capas intermedias [56]. Cada neurona experimenta un error que es equivalente a su aporte en el error total de la red. A partir del error detectado, se corrigen los errores en los pesos.

5.5.Fases de proceso de Aprendizaje de los Algoritmos

5.5.1. Fase de entrenamiento

En esta etapa se cuenta con una gran cantidad de datos, de los cuales se selecciona un segmento para capacitar al algoritmo y proporcionarle toda esta información para que identifique los patrones requeridos y luego pueda realizar proyección [57].

5.5.2. Fase de prueba

Para calcular el error que el Escenario realiza al anticipar nuevas observaciones, se separan los datos en dos conjuntos, uno de entrenamiento y otro de prueba (80%, 20%). La restante información se emplea para medir el aprendizaje del algoritmo. Si las respuestas son correctas en un 80% a 90%, se considera un buen grado de aprendizaje [58]

5.5.3. Fase de Predicción

Proceso mediante el cual, una vez que la red ha sido entrenada, se utiliza para generar respuestas o resultados ante nuevos datos de entrada. Durante esta fase, la red aplica los pesos y sesgos aprendidos durante el entrenamiento para procesar las entradas y producir una salida que representa la predicción o clasificación correspondiente [59].

5.5.4. Evaluación y Exactitud

5.5.4.1.MAE

Es una evaluación de la cantidad media de errores en una proyección. Se determina como el promedio de las medias de las diferencias absolutas entre las proyecciones y los valores obtenidos. Un MAE reducido señala que el Escenario está generando proyecciones exactas [56]

5.5.4.2.RMSE

Es un indicador de la cantidad media de errores al cuadrado en una proyección. Se determina mediante la raíz cuadrada de la raíz cuadrada promedio entre los valores estimados y observados. [60]. Un RMSE bajo también indica que el Escenario produce predicciones precisas, pero penaliza errores más grandes que MAE.

5.5.4.3.R²

El coeficiente de determinación (R al cuadrado) señala la proporción de la variación en la variable de respuesta, la cual se justifica por la variable independiente X en un Escenario lineal de regresión. Conforme aumenta el R cuadrado, la variabilidad que el Escenario de regresión lineal explica se incrementará [61].

5.5.5. Ventajas y limitaciones de los Escenarios

Los árboles de decisión son herramientas transparentes, eficientes y flexibles para la toma de decisiones. Aunque útiles, pueden volverse complejos, inestables y riesgosos si no se manejan con cuidado [62]. Requieren poco tiempo y recursos, pero es crucial analizar adecuadamente los posibles resultados para maximizar su efectividad.

Las redes neuronales tienen una alta capacidad de aprendizaje y flexibilidad para trabajar con diversos tipos de datos, pero también se limita por la necesidad de gran cantidad de datos, dificultad para interpretar Escenarios y tendencia al sobre entrenamiento [63]. Requieren ajuste de hiperparámetros y son sensibles a la escala de los datos, lo que puede afectar su desempeño.

6. MÉTODOS Y PROCEDIMIENTOS

6.1.Área de Estudio

La presente investigación se llevará a cabo en la provincia de Cotopaxi, específicamente en el cantón Sigchos, dentro de la parroquia San Francisco de las Pampas. En esta localidad se encuentra ubicada la estación meteorológica “Las Pampas” con el código M0362.

La Figura 10 muestra el mapa de ubicación de la zona de estudio, permitiendo visualizar la localización exacta del área donde se realizará la investigación.




Figura. 10 Mapa de Ubicación Zona de Estudio

La estación meteorológica “Las Pampas”, con el código M0362, está ubicada en una zona estratégica para el estudio.

La Tabla 4 muestra las coordenadas geográficas, proporcionando información precisa sobre su ubicación.

Tabla 4 Coordenadas estación meteorológica

LATITUD	LONGITUD	ELEVACIÓN
0° 25' 31,4" S	78° 57' 54" W	1583 m

6.2. Esquema Metodológico

6.2.1. Fase 1




Figura. 11 Esquema Metodológico Fase 1

La Fase 1, representada en la Figura 11, detalla el procedimiento de recolección y estudio de datos climáticos del periodo 2005-2017, constituyendo el fundamento para la evolución del estudio.

La Tabla 5 muestra los datos climáticos suministrados por el INAMHI, documentados de forma diaria durante el periodo comprendido entre 2005 y 2017.

Tabla. 5 Datos Meteorológicos INAMHI

	DATOS METEOROLÓGICOS (Diarios)	PERIODO
INAMHI	Precipitación	2005-2017
	Temperatura	
	Nubosidad Media diaria	
	Humedad Relativa	

La Tabla 6 muestra los datos climáticos suministrados por la NASA, documentados en periodos diarios y mensuales durante el periodo comprendido entre 2005 y 2017. Esta información fue recogida por el satélite Sentinel-3 [64], que forma parte del Proyecto Copérnico [65], un proyecto de la Unión Europea destinado a la observación terrestre y la vigilancia del medio ambiente. Los datos fueron suministrados por NOAA, que trabaja en el proyecto Merra-2 que es un proyecto retrospectivo para mejoras en asimilación meteorológica. Los datos meteorológicos se obtienen mediante el satélite Copernicus Sentinel-3, mientras que los demás datos climáticos fueron documentados por los satélites Aqua [66] y Aura [67].

Tabla. 6 Datos Meteorológicos NASA

	DATOS METEOROLGICOS (Diarios y Mensuales)	PERIODO
NASA	Precipitación	2005-2017
	Temperatura	
	Humedad Relativa	
	Velocidad Viento	
	Presión Atmosférica	
	Humedad Especifica	
	Dirección del Viento	

6.2.2. Fase 2



Figura. 12 Esquema Metodológico Fase 2

La fase 2, representada en la Figura 12, consistirá en el preprocesamiento de datos, que implicará la atribución de valores ausentes en R studio para la predicción de precipitaciones.

6.2.2.1. Preprocesamiento de Datos

Para asegurar la calidad de la información meteorológica recolectada, se implementaron métodos de atribución de valores ausentes mediante el uso de `Pmm.match` y `Missforest` en R.

5.2.2.2. Imputaciones con `Pmm.match` (Multiple Imputation by Chained Equations)

Para reemplazar los valores faltantes, se aplicó la función `pmm.match`. Este proceso utilizó el método Predictive Mean Matching (PMM), que selecciona valores observados similares para reemplazar los faltantes, manteniendo la coherencia estadística.

6.2.3. Fase 3




Figura. 13 Esquema Metodológico Fase 3

La fase 3 que se muestra en la Figura 13 se desarrollarán Escenarios matemáticos para el análisis de datos meteorológicos utilizando R Studio para Red Neuronal y Python para Árbol de Decisiones.

6.2.3.1.R Studio - Red Neuronal

Después de obtener un conjunto de datos sin valores faltantes, se procedió al desarrollo de un Escenario de Red Neuronal Artificial (RNA) en R Studio para predecir variables meteorológicas clave.

La estructura del Escenario matemático quedó definida como se muestra en la ecuación (4).

$$Y_{salida} = f(W_2 * f(W_1 * X + b_1) + b_2) \quad (4)$$

donde:

X:es el conjunto de datos de entrada.

W_1, W_2 : son los pesos de las conexiones entre capas.

b_1, b_2 : son los sesgos.

f : representa la función de activación utilizada en cada capa.

6.2.3.2.Python - Árbol de Decisiones

Un Escenario de boosting consiste en una combinación de múltiples árboles de decisión, donde cada nuevo árbol corrige los errores del anterior. Se representa matemáticamente como se presenta en la ecuación (5).

$$F(x) = \sum_{m=1}^M \gamma_m h_m(x) \quad (5)$$

Donde

$h_m(x)$ es cada uno de los Escenarios débiles (árboles de decisión)

γ_m es un peso ajustado a cada Escenario en la combinación final

M es el número total de Escenarios usados en el proceso de boosting

6.2.4. Fase 4




Figura. 14 Esquema Metodológico Fase 4

La fase 4, como se muestra en la Figura 14, realizará la predicción de datos meteorológicos utilizando R Studio para Red Neuronal y Python para Árbol de Decisiones.

6.2.4.1. R Studio para Red Neuronal

1. Ajuste de Predicciones según la Temporada

Se aplicaron reglas de corrección basadas en la precipitación media histórica utilizando la ecuación (6) [68].

$$P_{ajustado} = \begin{cases} 0, & \text{si } Mes \in [5,11] \text{ y } P_{predicho} < \mu_{seca} \\ 0, & \text{si } Mes \notin [5,11] \text{ y } P_{predicho} < 1 \\ P_{predicho}, & \text{en caso contrario} \end{cases} \quad (6)$$

2. Análisis Estacional de Precipitaciones

Para identificar patrones climáticos, se calculó la precipitación media en la temporada seca con la ecuación (7). Este valor servirá posteriormente para ajustar predicciones según la estacionalidad [69].

$$\mu_{seca} = \frac{1}{n} \sum_{i=1}^n P_i \quad (7)$$

donde P_i representa los valores de precipitación durante los meses secos.

3. Normalización de Datos

Con el objetivo de optimizar el rendimiento del Escenario, se implementó una normalización de rango en las variables predictivas [70]. Con el propósito de garantizar que todas las variables predictoras tengan la misma escala y contribuyan adecuadamente al aprendizaje, el Escenario se realiza para mejorar la actuación. La función preProcess con el método “rango” se utiliza para aumentar los datos al rango [0,1] según se define en la ecuación (8) como sigue:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (8)$$

donde:

- X: es el valor original,
- X_{min} y X_{max} : son los valores mínimo y máximo de la variable.

6.2.5. Fase 5

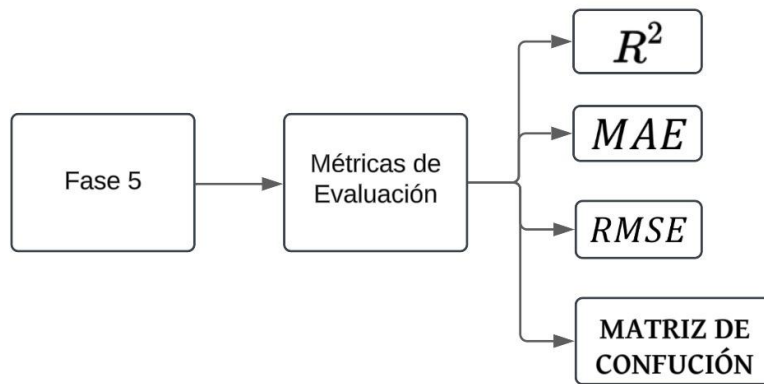


Figura. 15 Esquema Metodológico Fase 5

La fase 5, tal como puede observarse en la Figura 15, implicará el análisis del desempeño del Escenario a partir de métricas muy concretas que permitirán valorar la exactitud del mismo, la tasa de error y la fiabilidad del pronóstico, lo que permitirá detectar espacios de mejora y realizar modificaciones a nivel iterativo para la mejora del Escenario. Igualmente, este método permitirá adaptarse a diferentes contextos y objetivos, promoviendo la organización y la toma de decisiones de una forma eficiente en campos que sean susceptibles del clima. El método pretenderá incorporar un enfoque global a las tecnologías de vanguardia, a fuentes fiables y a un escenario de machine learning para dar predicciones del clima exactas y útiles. Este procedimiento será clave para incrementar la comprensión del comportamiento del clima y ofrecer aplicaciones valiosas en los diferentes campos.

6.2.5.1. Métricas de Evaluación

Se calcularon métricas de desempeño para evaluar la precisión de los Escenarios:

La ecuación (9) muestra la expresión matemática Error Absoluto Medio (MAE) [71].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

Rango: $MAE \geq 0$ (siempre positivo).

Valores Aceptables:

- Mientras más próximo a 0, mejor. El MAE bajo señala que el Escenario realiza predicciones acertadas.

La ecuación (10) muestra la expresión matemática Error Cuadrático Medio (RMSE) [71].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

Rango: $RMSE \geq 0$.

Valores Aceptables:

- **Debe ser lo más bajo posible.**
- Si el RMSE es similar al MAE, significa que no hay errores extremadamente grandes.
- Un RMSE pequeño en comparación con la media de los valores reales indica buen desempeño.

La ecuación (11) muestra la expresión matemática Coeficiente de Determinación (R^2) [72].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (11)$$

Rango: $R^2 \in [0,1]$

Valores Aceptables:

- R^2 aproximadamente 1 es óptimo (sugiere que el Escenario memoriza los datos).
- $R^2 > 0.8 \rightarrow$ Buen Escenario.
- $0.6 < R^2 < 0.8 \rightarrow$ Escenario aceptable, pero con margen de mejora.
- $R^2 < 0.6 \rightarrow$ El Escenario no explica bien la variabilidad de los datos.

7. ANÁLISIS DE RESULTADOS

7.1. Identificación de Datos Faltantes

7.1.1. Datos INAMHI

La Figura 16 muestra la precipitación mensual, se observan picos notables de precipitación en 2006, 2009, 2011 y 2016, alcanzando hasta 20 mm en algunos meses. También hay períodos prolongados de baja precipitación, como entre 2007 y 2008, y nuevamente entre 2013 y 2014. Se evidencian vacíos en la serie temporal, como la falta de registros entre 2010 y 2011, y puntos aislados en 2017, lo que refleja la ausencia de datos continuos.

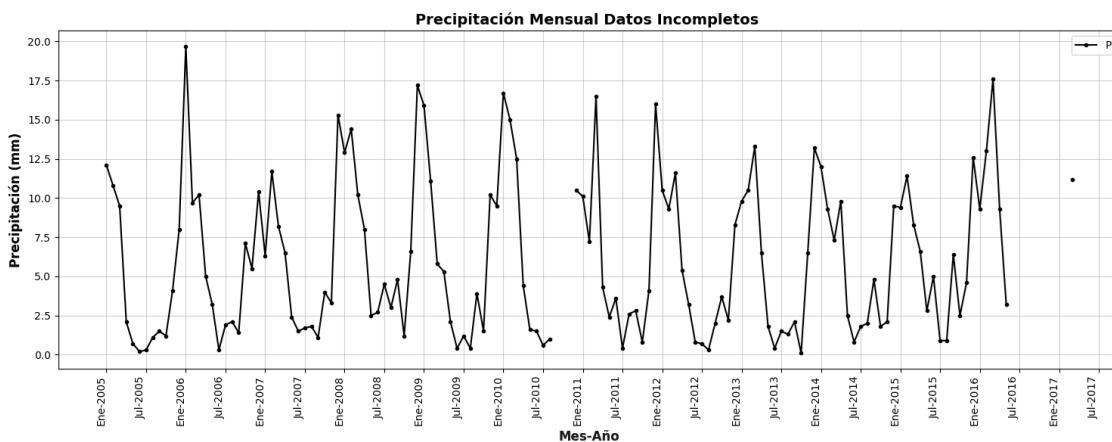


Figura. 16 Precipitación Mensual con Datos Incompletos

La Figura 17 muestra la precipitación mensual, se evidencia una mayor continuidad en la serie de datos, reflejando que el método MICE permitió la imputación de valores faltantes. Se observan picos significativos de precipitación en 2006, 2009, 2011 y 2016, alcanzando hasta 18 mm en algunos meses. Los períodos prolongados de baja precipitación, como entre 2007-2008 y 2013-2014, ahora presentan valores imputados, vitando la presencia de vacíos.

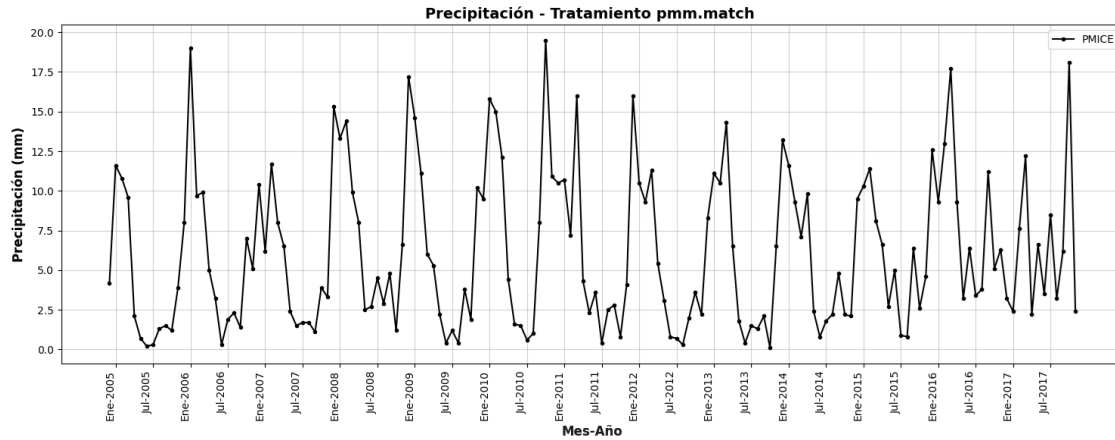


Figura. 17 Precipitación Mensual con Imputación de Datos utilizando Pmm.match

La Figura 18 muestra la precipitación mensual, representa el período temporal de análisis, desde enero de 2005 hasta octubre de 2017, segmentado por intervalos semestrales. Muestra la cantidad de precipitación mensual, con un rango de valores entre 0 y 20 mm, muestra una mayor continuidad en la serie de datos, reflejando que el método *MissForest* permitió la imputación de valores faltantes. Se observan picos significativos de precipitación en 2006, 2009, 2011 y 2016, alcanzando hasta 18 mm en algunos meses. En el período final, particularmente entre 2016 y 2017, los valores imputados presentan menor variabilidad, lo que sugiere que el método suavizó las fluctuaciones en la precipitación.

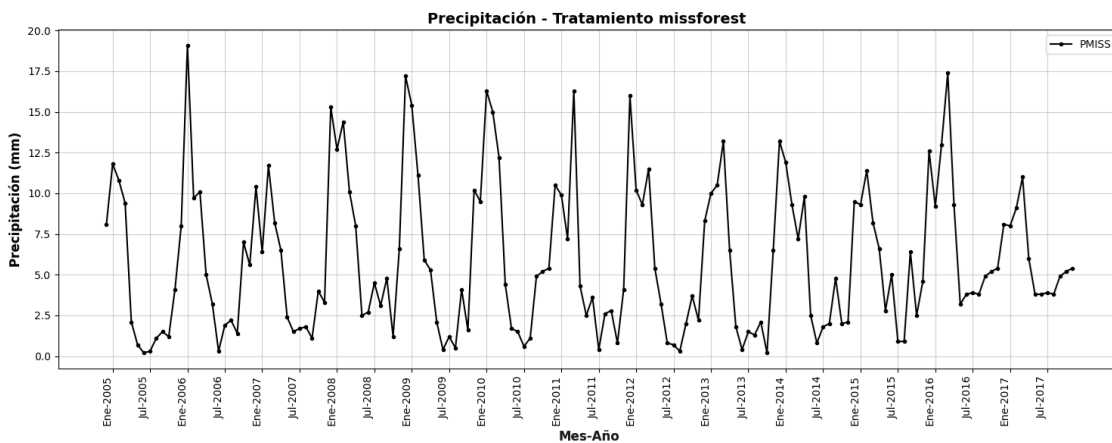


Figura. 18 Precipitación Mensual con Imputación de Datos utilizando Missforest

La Figura 19 muestra la temperatura mensual, Muestra la temperatura mensual promedio, con un rango de valores entre 17.2 °C y 18.8 °C, se observan picos significativos de temperatura en 2005, 2010 y 2016, alcanzando hasta 18.8 °C. Los períodos prolongados de menor temperatura, como

entre 2008-2009 y 2011-2012, también reflejan la presencia de registros incompletos. Al final de la serie, particularmente en 2017, se observa un valor aislado, indicando un dato incompleto o atípico.

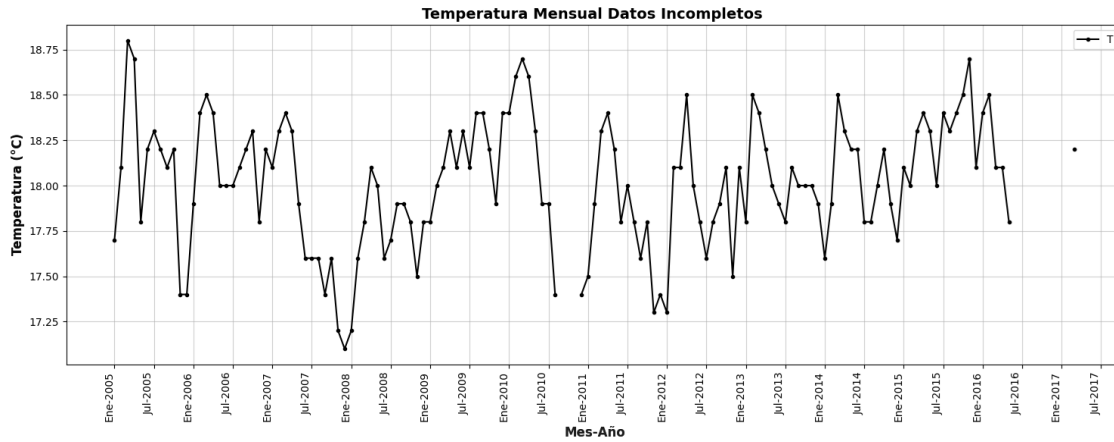


Figura. 19 Temperatura Mensual con Datos Incompletos

La Figura 20 muestra la temperatura mensual, Muestra la temperatura mensual promedio, con un rango de valores entre 17.0 °C y 18.7 °C. Se observan picos significativos de temperatura en 2005, 2010 y 2016, alcanzando hasta 18.7 °C, mientras que los períodos prolongados de menor temperatura, como entre 2008-2009, ahora presentan valores imputados, evitando vacíos.




Figura. 20 Temperatura Mensual con Imputación de Datos utilizando Pmm.match

La Figura 21 muestra la temperatura mensual, Muestra la temperatura mensual promedio, con un rango de valores entre 17.2 °C y 18.6 °C. Se observan picos significativos de temperatura en 2005, 2010 y 2016, alcanzando hasta 18.6 °C. Los períodos prolongados de menor temperatura, como entre 2008-2009 y 2011-2012, ahora presentan valores imputados, eliminando los vacíos y

permitiendo un análisis más completo de la variabilidad climática. Hacia el final de la serie, especialmente entre 2016 y 2017, la variabilidad disminuye, lo que sugiere una suavización de los datos imputados.




Figura. 21 Temperatura Mensual con Imputación de Datos utilizando Missforest

La Figura 22 representa la humedad relativa mensual media, indicando un intervalo de valores de 86% a 98%. Se notan incrementos relativos de humedad que superan el 96% en 2005, 2008, 2011 y 2012, mientras que en 2006 y 2009 se observan reducciones notables, llegando a valores cercanos al 87%. La serie presenta una irregularidad significativa, con intervalos extensos de alta humedad y caídas bruscas, lo que indica la ausencia de registros consistentes.

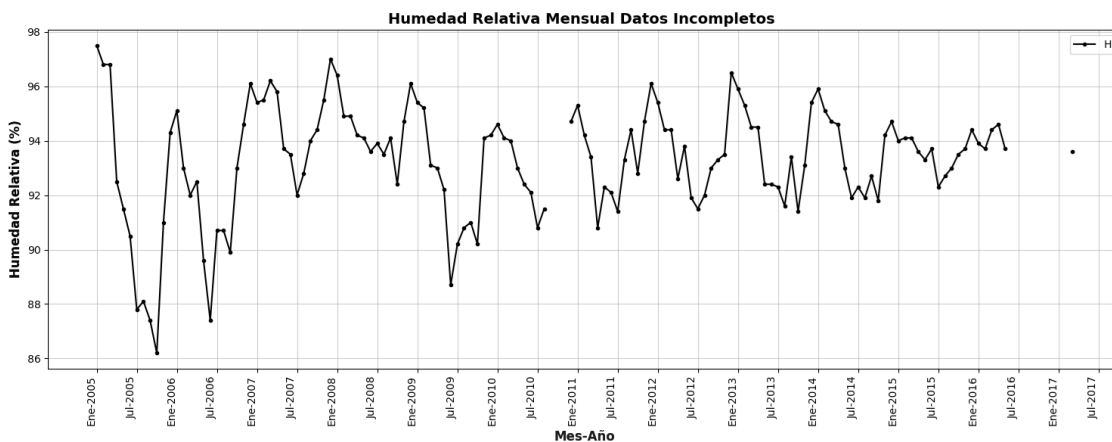


Figura. 22 Humedad Relativa Mensual con Datos Incompletos

La Figura 23 presenta la humedad relativa mensual media, indicando un intervalo de valores de 86% a 98%. Se nota un incremento en la continuidad de la serie de datos, cubriendo las lagunas

existentes en los datos iniciales. Los picos de humedad relativa que superan el 96% persisten en 2005, 2008 y 2011, mientras que las notables reducciones en 2006, 2009 y 2017 también son perceptibles, aunque con valores interpolados. El cálculo ha moderado las variaciones, ofreciendo una representación más consistente de la variabilidad climática.




Figura. 23 Humedad Relativa Mensual con Imputación de Datos utilizando Pmm.match

La Figura 24 muestra la humedad relativa mensual media, presentando un intervalo de valores de 86% a 98%. Se nota un incremento en la continuidad de la serie de datos, suprimiendo las lagunas que existen en la información inicial. Las elevaciones relativas de humedad que superan el 96% son notables en 2005 y 2008, mientras que las significativas reducciones en 2006 y 2009 han sido mitigadas por la imputación.

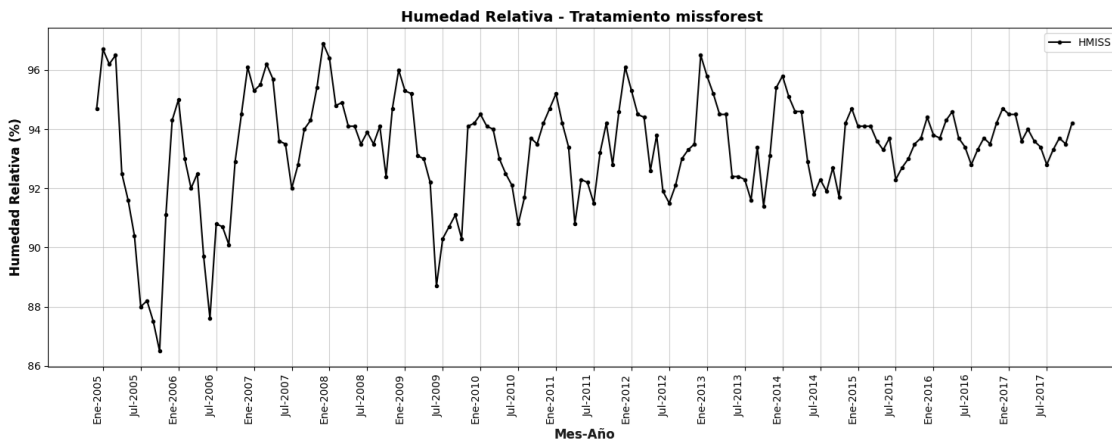


Figura. 24 Humedad Relativa Mensual con Imputación de Datos utilizando Missforest

La Figura 25 muestra la nubosidad mensual, Muestra la nubosidad mensual promedio, medida en octas, con un rango de valores entre 4.5 y 7.5 octas. Se observan picos significativos de nubosidad, cercanos a 7.5 octas, en 2006, 2009, 2010 y 2012, mientras que los valores más bajos, cercanos a 4.8 octas, se presentan en 2005 y 2014.

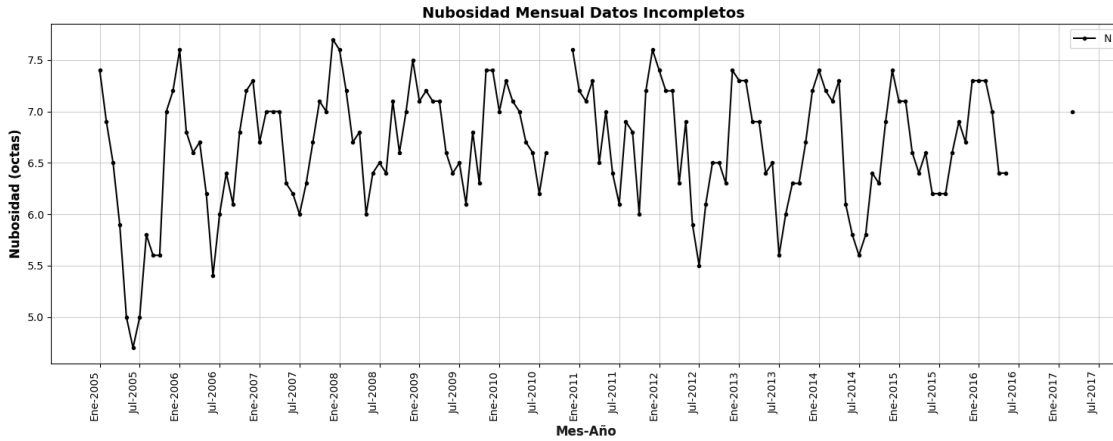


Figura. 25 Nubosidad Mensual con Datos Incompletos

La Figura 26 muestra la nubosidad mensual, Muestra la nubosidad mensual promedio, medida en octas, con un rango de valores entre 4.5 y 7.5 octas. Se observan picos significativos de nubosidad, alcanzando hasta 7.5 octas, en 2006, 2009, 2011 y 2013. Los períodos de menor nubosidad, como entre 2005 y 2006 y en 2014, ahora presentan valores completados, reflejando una serie temporal más coherente.




Figura. 26 Nubosidad Mensual con Imputación de Datos utilizando Pmm.match

La Figura 27 muestra la nubosidad mensual, Muestra la nubosidad mensual promedio, medida en octas, con un rango de valores entre 4.5 y 7.5 octas. Se observan picos significativos de nubosidad, alcanzando hasta 7.5 octas, en 2006, 2009, 2011 y 2013.




Figura. 27 Nubosidad Mensual con Imputación de Datos utilizando Missforest

El método Pmm.match ha permitido reconstruir la serie temporal, completando los registros ausentes y generando una tendencia más continua y coherente en el tiempo. MissForest permitió reconstruir la serie temporal, completando los registros ausentes y generando una tendencia más continua y coherente en el tiempo. Aunque la imputación fue efectiva para llenar los vacíos, la suavización de los valores extremos podría afectar la precisión de las predicciones en eventos climáticos extremos.

7.1.2. Datos NASA

La Figura 28 muestra la dirección del viento mensual, presenta variaciones bruscas en la dirección del viento, alternando entre valores cercanos a 0° y picos cercanos a 360° , lo que indica cambios frecuentes y marcados en la procedencia del viento durante el período analizado. Se observan fluctuaciones regulares en ciclos anuales, lo que sugiere una estacionalidad en la dirección predominante del viento. Existen períodos con caídas abruptas a valores cercanos a 0° , como en 2005, 2010 y 2015, lo que puede indicar momentos de calma o cambios repentinos en la dirección del viento.




Figura. 28 Dirección del Viento Mensual según Datos de la NASA

La Figura 29 muestra la humedad específica mensual, Muestra la cantidad de vapor de agua en la atmósfera, expresada en gramos de vapor de agua por kilogramo de aire seco. Los valores fluctúan entre 9.5 y 12 g/kg. Se observan picos significativos en 2010 y 2016, donde la humedad específica alcanzó valores cercanos a 12 g/kg. Los períodos de baja humedad, como en 2007 y 2013, muestran valores cercanos a 9.5 g/kg.




Figura. 29 Humedad Específica Mensual según Datos de la NASA

La Figura 30 muestra la humedad relativa mensual, Muestra la humedad relativa mensual expresada en porcentaje, con un rango de valores entre 72% y 88%. Se observan picos significativos en 2006, 2010 y 2016, con valores cercanos al 88%. Los períodos de menor humedad relativa, como en 2009 y 2013, muestran valores alrededor del 72%. La humedad relativa refleja la cantidad de vapor de agua en el aire en relación con su capacidad máxima de retención a una

temperatura específica. Los picos indican condiciones de alta saturación, mientras que las caídas sugieren un ambiente más seco.




Figura. 30 Humedad Relativa Mensual según Datos de la NASA

La Figura 31 muestra la presión atmosférica mensual, Indica la presión atmosférica mensual, con un rango de valores entre 75.8 y 76.0 hPa. El gráfico muestra fluctuaciones moderadas en la presión atmosférica durante el período analizado. Se observan picos en 2010 y 2016, alcanzando valores máximos cercanos a 76.0 hPa. Los valores mínimos se registran en 2007 y 2010, descendiendo hasta 75.8 hPa. Un aumento suele asociarse con condiciones estables y soleadas, mientras que una disminución puede indicar la llegada de precipitaciones y tormentas.




Figura. 31 Presión Atmosférica Mensual según Datos de la NASA

La Figura 32 muestra la precipitación mensual, Indica la cantidad de precipitación mensual, con un rango de valores entre 0 y 10 mm. Se observan picos significativos en 2006, 2009, 2011 y 2017,

alcanzando valores cercanos a 9-10 mm. Los períodos de baja precipitación son evidentes entre 2007-2008 y 2012-2014, con valores inferiores a 2 mm. La irregularidad en las precipitaciones destaca la presencia de ciclos de sequía y lluvia intensa. Esta variabilidad puede afectar la planificación agrícola y la gestión de recursos hídricos, aumentando la vulnerabilidad ante eventos extremos.




Figura. 32 Precipitación Mensual según Datos de la NASA

La Figura 33 muestra la temperatura mensual, Muestra la temperatura mensual promedio, con un rango de valores entre 13.0 °C y 15.5 °C. Se observan picos significativos de temperatura en 2010 y 2016, alcanzando valores cercanos a 15.5 °C. Los períodos de menor temperatura se registran entre 2008 y 2011, con valores por debajo de 13.5 °C.

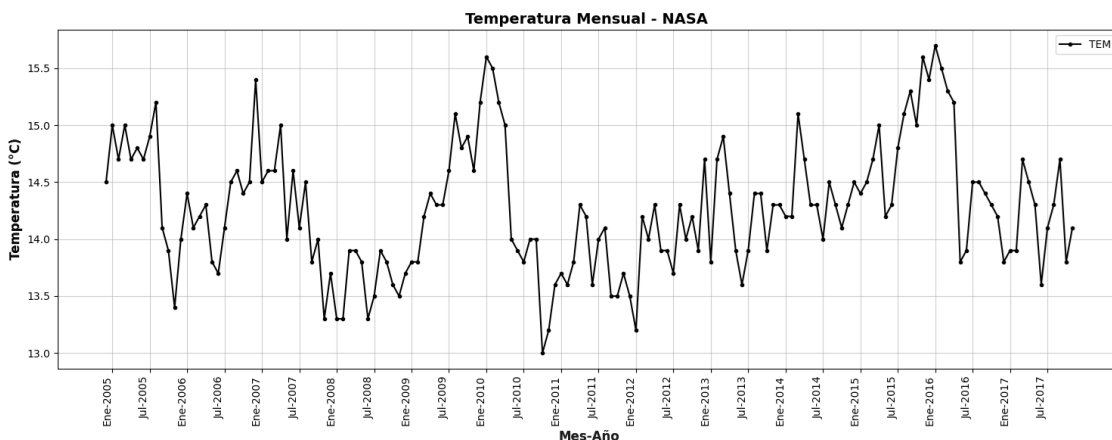


Figura. 33 Temperatura Mensual según Datos de la NASA

La Figura 34 muestra la temperatura superficial del mar mensual, Muestra la temperatura superficial del mar (TSM) mensual, con valores que oscilan entre 19.5 °C y 28.5 °C. Los picos de

temperatura máxima alcanzan alrededor de 28 °C durante los años 2015 y 2016. Los períodos con temperaturas más bajas, cercanas a 19.5 °C, se observan en 2007, 2012 y 2017. Se evidencia una tendencia de aumento de la temperatura en años recientes, lo que podría estar relacionado con fenómenos como El Niño y el calentamiento global.




Figura. 34 Temperatura Superficie del Mar Mensual según Datos de la NASA

La Figura 35 muestra la velocidad del viento mensual, Muestra la velocidad promedio mensual del viento, con valores que oscilan entre 0.9 y 1.9 m/s. Se observan picos significativos en 2005, 2010 y 2014, con valores cercanos a 1.9 m/s. Los períodos de menor velocidad, alrededor de 0.9 m/s, se presentan principalmente en 2011, 2013 y 2015. La fluctuación constante sugiere una influencia directa de condiciones atmosféricas cambiantes y fenómenos climáticos regionales.




Figura. 35 Velocidad del Viento Mensual según Datos de la NASA

7.1.3. Escenario 1 de Predicción con Redes Neuronales Basados en Datos del INAMHI con Imputación de Datos Faltantes con pmm. match

En la Figura 36 se muestra la estructura de la Red Neuronal con 3 Variables de Entrada basada en la ecuación (12).

$$Precipitaciones = Humedad_{Relativa} + Nubosidad_{Media Diaria} + Temperatura \quad (12)$$




Figura. 36 Estructura de la Red Neuronal con 3 Variables de Entrada (Pmm.match)

La Tabla 7 muestra diferentes Configuraciones de una red neuronal con tres variables de entrada (Temperatura, Nubosidad Media Diaria y Humedad Relativa), evaluadas mediante prueba y error.

Tabla 7 Configuraciones de una Red Neuronal 3 Inputs

Inputs	Hidden	Error	Steps
Temperatura Nubosidad Media diaria Humedad Relativa	(2,5,3)	1.597	1242
	(5,9,2)	1.647	730
	(3,6,4)	1.633	526
	(4,8,3)	1.628	520
	(10,7,5,2)	1.611	518

El desempeño del Escenario no fue óptimo, ya que, a pesar de probar diferentes Configuraciones, ninguna alcanzó un ajuste ideal. Aunque la arquitectura (10,7,5,2) presentó el menor error (0.254),

el número de iteraciones (7,339 pasos) sigue siendo considerable, lo que indica que el Escenario aún requiere un tiempo significativo para converger.

7.1.4. Escenario 2 de Predicción con Redes Neuronales Basados en datos del INAMHI con imputación de datos faltantes con Missforest

En la Figura 37 se muestra la estructura de la Red Neuronal con 3 variables de entrada basada en la ecuación (13).

$$Precipitaciones = Humedad_{Relativa} + Nubosidad_{Media Diaria} + Temperatura \quad (13)$$




Figura. 37 Estructura de la Red Neuronal con 3 Variables de Entrada (Missforest)

En la Tabla 8, muestran diferentes Configuraciones de la red neuronal con 3 Inputs, evaluadas mediante un enfoque de prueba y error.

Tabla 8 Configuraciones de una Red Neuronal 3 Inputs

Inputs	Hidden	Error	Steps
Temperatura Nubosidad Media diaria Humedad Relativa	(2,5,3)	0.813	2392
	(5,9,2)	0.376	16580
	(3,6,4)	0.647	3475
	(4,8,3)	0.754	1860
	(10,7,5,2)	0.254	7339

La arquitectura (10,7,5,2) obtuvo el mejor desempeño, con un error mínimo de 0.254693 y una convergencia en 7,339 iteraciones, lo que indica un ajuste ideal y una eficiencia óptima en el entrenamiento. Si bien este resultado refleja una alta capacidad predictiva, la incorporación de más variables de entrada podría mejorar aún más la precisión del Escenario y optimizar su convergencia sin comprometer su rendimiento.

7.1.5. Escenario 3 de Predicción con Redes Neuronales basada en datos de la NASA

En la Figura 38 se muestra la estructura de la red neuronal con 6 variables de entrada basada en la ecuación (14).

$$\begin{aligned}
 \text{Precipitaciones} = & \text{Humedad}_{\text{Relativa}} + \text{Temperatura} + \\
 & + \text{Velocidad}_{\text{Viento}} + \text{Presion}_{\text{Atmosferica}} + \text{Humedad}_{\text{Especifica}} + \text{Direccion}_{\text{Viento}} \\
 & + \text{Temperatura}_{\text{Superficie del mar}}
 \end{aligned}
 \tag{14}$$




Figura. 38 Estructura de la Red Neuronal con 6 Variables de Entrada

En la Tabla 9, se presentan las distintas de una Red Neuronal 6 Inputs, evaluadas mediante un enfoque de prueba y error.

Tabla 9 Configuraciones de una Red Neuronal 6 Inputs

Inputs	Hidden	Error	Steps
Dirección del Viento	(2,5,3)	0.458	432
Humedad Especifica	(5,9,2)	0.293	1228
	(3,6,4)	0.358	827

Humedad Relativa	(4,8,3)	0.335	1029
Presión Atmosférica			
Temperatura	(10,7,5,2)	0.306	410
Temperatura Superficial del Mar			
Velocidad del Viento			

Se destaca que la que la configuración (10,7,5,2) registró el rendimiento más óptimo, logrando un error mínimo de 0.30685, lo que señala que el Escenario ha conseguido un ajuste exacto a los datos de entrenamiento y una elevada capacidad predictiva. Además, mostró la menor cantidad de iteraciones frente a otras Configuraciones, lo que evidencia una convergencia más eficaz y un proceso de aprendizaje mejorado.

Su reducido número de iteraciones lo hace la mejor alternativa para la predicción de precipitaciones, dado que consigue un rendimiento superior en un periodo de tiempo reducido, previniendo el sobreajuste y potenciando su habilidad para generalizar. Los ensayos realizados para determinar la configuración más apropiada, así como los análisis comparativos de diferentes arquitecturas, se describen en los Anexos 2 a 4.

7.2. Análisis de Rendimiento y Evaluación de Escenarios

7.2.1. Comparación de Predicciones y Valores Reales

7.2.1.1. Escenario 1 - INAMHI (Pmm.match)

La Tabla 10 muestra un contraste entre los estimados de precipitación basados en la base de datos del INAMHI (Pmm.match) y los valores reales registrados en 2017, empleando R Studio como instrumento de procesamiento y predicción.

Tabla 10 Valores de Precipitación INAMHI (Pmm.match)

Mes	Año	Precipitación Base de Datos INAMHI	Precipitación Real
Enero	2017	1.11	3.2
Febrero	2017	7.71	2.42
Marzo	2017	10.31	7.57
Abril	2017	10.29	12.22
Mayo	2017	2.92	2.21
Junio	2017	5.39	6.62

Julio	2017	8.71	3.51
Agosto	2017	4.86	8.54
Septiembre	2017	9.09	3.22
Octubre	2017	1.77	6.23
Noviembre	2017	3.09	18.05
Diciembre	2017	5.12	2.42

La discrepancia observada entre los valores reportados por la base de datos del INAMHI y las precipitaciones reales indica que el Escenario podría estar siendo entrenado con datos que no representan fielmente la variabilidad climática. Los resultados demuestran que los datos suministrados por la base de datos no siempre representan con exactitud los valores verdaderos de las precipitaciones, particularmente en meses con sucesos extremos. Estas discrepancias importantes podrían impactar en la habilidad predictiva del Escenario, poniendo en riesgo su exactitud y restringiendo su eficacia para la predicción de sucesos hidrológicos críticos.




Figura. 39 Comparación de Predicciones INAMHI (Pmm.match)

La Figura 39 presenta un mal comportamiento, dado que los valores reales de la lluvia durante unos meses no son pronosticados correctamente. La tendencia general se sostiene en cierto modo, pero hay unas variaciones grandes, donde la predicción menosprecia los máximos de precipitación observados.

El Escenario ofrece unas variaciones muy atormentadas lo que pone de manifiesto que la variabilidad de la información fidedigna no está bien recogida. Esta dificultad pone en evidencia errores potenciales en la configuración de la red neuronal, en la elección de las variables o en la calidad del conjunto de datos que se ha implementado para la actividad. Se puede dar la situación que los datos de formación sean deficientes o la carencia de variables climáticas necesarias hace que el Escenario se quede corto cuando intenta sacar patrones complejos de su interior.

7.2.1.2. Escenario 2 - INAMHI (Missforest)

La Tabla 11 presenta un contraste entre los estimados de lluvia derivados de la base de datos del INAMHI (Missforest) y los valores reales registrados en 2017, empleando R Studio como instrumento de procesamiento y proyección.

Tabla 11 Comparación entre Valores de Precipitación INAMHI (Missforest)

Mes	Año	Precipitación Base de Datos INAMHI	Precipitación Real
Enero	2017	14.97	8.06
Febrero	2017	11.14	8.0
Marzo	2017	9.92	9.06
Abril	2017	5.15	11.04
Mayo	2017	8.92	6.01
Junio	2017	3.31	3.8
Julio	2017	3.42	3.83
Agosto	2017	2.96	3.91
Septiembre	2017	3.67	3.82
Octubre	2017	5.07	4.94
Noviembre	2017	3.78	5.21
Diciembre	2017	6.72	5.54

La discrepancia observada entre los valores estimados por la base de datos del INAMHI y las precipitaciones reales sugiere que el Escenario podría estar siendo entrenado con datos que sobrestiman los valores observados, afectando su capacidad para representar con precisión la variabilidad climática. Los resultados demuestran que, aunque en ciertos meses los valores proyectados se aproximan más a los verdaderos, en épocas de gran variabilidad climática la diferencia continúa siendo significativa. Estas irregularidades podrían poner en riesgo la exactitud

del Escenario predictivo, creando prejuicios que restrinjan su eficacia en la predicción de sucesos hidrológicos extremos.

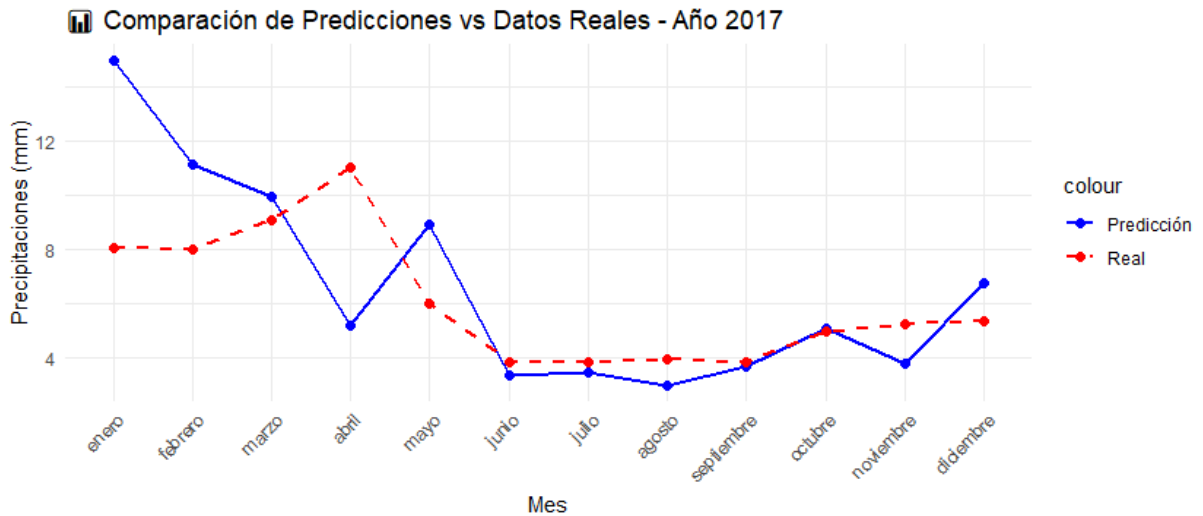


Figura. 40 Comparación de Predicciones INAMHI (Missforest)

La figura 40 refleja la comparativa entre las Predicciones del INAMHI, observándose un desempeño poco sobresaliente, donde se llega a captar parcialmente la tendencia general de las precipitaciones, evidenciándose la existencia de problemas en el caso de los eventos extremos. La mayor limitación que tiene radica en la excesiva suavización de los valores previstos, lo cual merma su capacidad para captar picos, o bien, caídas abruptas. Esto podría deberse a una escasez de datos de entrenamiento, o bien, a la carencia de aspectos meteorológicos necesarios. A pesar de que el Escenario está suficientemente fundamentado, todavía sigue siendo un tipo de clima que precisa de numerosas mejoras considerables que aumenten su veracidad y su fiabilidad.

7.2.1.3. Escenario 3 - NASA

La Tabla 12 presenta un contraste entre los estimados de lluvia derivados de la base de datos de la NASA y los valores reales registrados en 2017, empleando R Studio como instrumento de procesamiento y predicción.

Tabla 12 Comparación entre Valores de Precipitación NASA

Mes	Año	Precipitación Base de Datos NASA	Precipitación Real
Enero	2017	6.434209	8.06
Febrero	2017	7.116065	8.00

Marzo	2017	9.359806	9.06
Abril	2017	6.011285	11.04
Mayo	2017	6.792973	6.01
Junio	2017	3.758809	3.80
Julio	2017	1.807193	3.83
Agosto	2017	2.027522	3.91
Septiembre	2017	2.365907	3.82
Octubre	2017	4.577342	4.94
Noviembre	2017	2.991483	5.21
Diciembre	2017	4.807058	5.36

En esta tabla, es posible comprobar un rendimiento alto y confiable en cuanto a la estimación de los valores reales de lluvia en gran parte de los meses. Y a diferencia de los Escenarios ya descritos, este escenario posee menos discrepancias, indicativo de que los datos que se utilizaron permiten una representación más precisa de los patrones climáticos que tiene lugar en esta región.

A pesar de las fluctuaciones que tienen lugar en eventos extremos, la tendencia global es la misma y estable, lo que indica que el Escenario puede regular y adecuadamente la variabilidad de las precipitaciones. Por lo que se recomienda que se incorporen variables climáticas y cambios en la configuración del Escenario, para conseguir un rendimiento aún más elevado, aumentando así la capacidad predictiva sobre situaciones con variabilidad más acentuada.




Figura. 41 Comparación de Predicciones NASA

La Figura 41 muestra un rendimiento robusto, consiguiendo identificar tendencias generales y adaptándose con exactitud durante varios meses. A diferencia de los anteriores Escenarios con menor cantidad de variables, este enfoque incorpora un mayor número de factores meteorológicos, lo que permite obtener resultados más coherentes y representativos de la realidad climática. Si bien aún existen discrepancias en eventos extremos y ciertas subestimaciones, la base estable y predecible del Escenario lo hace una herramienta confiable para la estimación de precipitaciones y sugiere un mejor desempeño en futuras predicciones.

5.3.1.4. Escenario 4 - Python

La Tabla 13 muestra la comparación entre los valores de precipitación reales y los valores predichos por el Escenario basado en datos de la NASA y los valores reales registrados en el año 2017, utilizando Python como herramienta de procesamiento y predicción.

Tabla 13 Valores de Precipitación NASA

Año	Mes	Precipitación Reales	Predichos
2016	Enero	5.38	6.01
2016	Febrero	3.25	4.82
2016	Marzo	6.48	4.94
2016	Abril	7.57	6.17
2016	Mayo	4.43	2.99
2016	Junio	2.57	2.19
2016	Julio	1.31	1.32
2016	Agosto	0.63	0.47
2016	Septiembre	2.18	1.19
2016	Octubre	2.42	1.85
2016	Noviembre	3.08	1.96
2016	Diciembre	3.19	3.08

Se muestra un desempeño aceptable, logrando capturar la tendencia de la precipitación en la mayoría de los meses. Sin embargo, la subestimación en meses con precipitaciones más altas y la sobreestimación en otros períodos sugieren que aún hay margen de mejora.

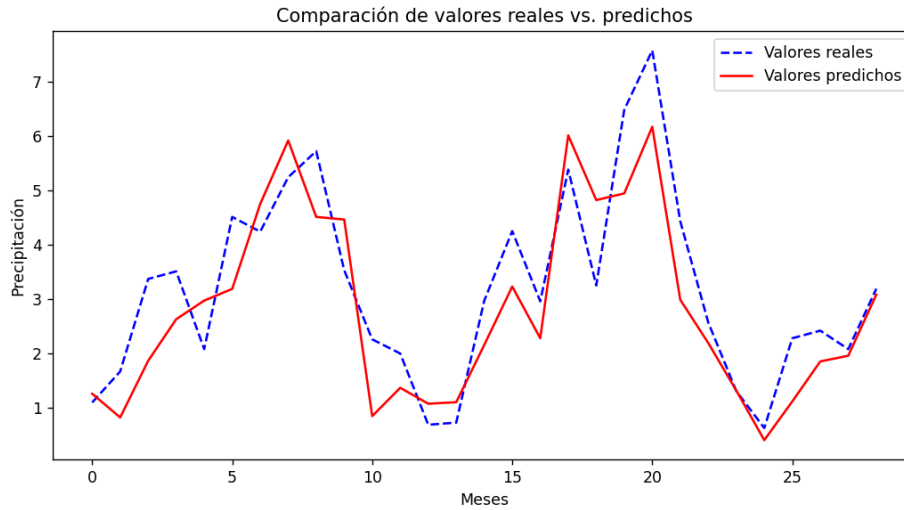


Figura. 42 Comparación de Predicciones NASA

La Figura 42 presenta la comparación entre los valores reales de las precipitaciones y los valores de esta misma característica predichos en diferentes meses, en este caso a partir de los datos de la NASA, y puede observarse que existe una alta correlación entre ambas series, lo que sugiere que el Escenario tiene una estructura bastante sólida y bien entrenada capaz de representar la tendencia de las precipitaciones en el tiempo. Por otro lado, también encontramos entre las limitaciones del Escenario que no es posible construir predicciones para años que no aparezcan en la serie que estamos modelizando, ya que las predicciones del Escenario en el caso de la precipitación solo están basadas en las cifras del año anterior, lo cual limita la aplicación del mismo a la predicción de precipitaciones.

7.2.2. Métricas de Evaluación en R Studio

La Tabla 14 presenta los resultados de la evaluación de los 3 distintos Escenarios de redes neuronales midiendo su desempeño a través de tres métricas.

Tabla 14 Métricas de Evaluación en R Studio

Escenarios	Hidden	MAE	RMSE	R2	Análisis
Escenario 1	(10, 7, 5, 2)	1.63	2	0.81	Buen equilibrio entre error bajo y buen ajuste.
Escenario 2		2.92	4.15	0.199	Alto error y bajo R ² , lo que indica un mal ajuste.
Escenario 3		0.79	1.01	0.70	Mejor MAE y RMSE, con un R ² adecuado.

El Escenario 3 evidencia nada menos que el de evaluación más eficaz. Un MAE (0.79) y RMSE (1.01) por debajo del resto, lo que significa un poder predictivo sobresaliente y un error bajo. Es importante asumir que los valores pronosticados no son iguales a sus homólogos o valores reales de precipitación. A pesar de que el Escenario 3 es el que mejor se ajusta ($R^2 = 0.76$; gran capacidad explicativa), la predicción de las precipitaciones estará siempre rodeada de un margen de variabilidad intrínseco, los resultados deben asumirse con una perspectiva probabilística y se hace evidente que se permite completar la predicción con otros tipos de análisis que incrementen la fiabilidad en la toma de decisiones ante la presencia de contingencias de tipo ambiental o climático.

7.2.3. Métricas de Evaluación en Python

La Tabla 15 presenta indicadores de evaluación en Python, evaluando su rendimiento mediante tres indicadores.

Tabla 15 Métricas de Evaluación en Python

Parámetro	Valores Posibles	Valores	Métrica
n_estimators	50, 100, 200	100	$R^2 = 0,708$
max_depth	3, 5, 7, -1	3	
learning_rate	0.01, 0.1, 0.2	0.1	MAE= 0,806
num_leaves	20, 31, 40	20	
Subsample	0.6, 0.8, 1.0	1.0	RMSE=0,935
colsample_bytree	0.6, 0.8, 1.0	1.0	

El Escenario 4 en rendimiento global, el coeficiente de determinación $R^2=0.708$ sugiere que el Escenario explica el 70.8% de la variabilidad en los datos, lo que indica un ajuste adecuado. No obstante, el RMSE de 0.935 revela que el Escenario penaliza más los errores grandes, lo que sugiere que aún hay margen de mejora en la precisión de las predicciones, especialmente en valores extremos.

7.2.4. Matriz De Correlación

La Figura 43 presenta la matriz de correlación del Escenario 3, dado que los resultados obtenidos confirman que es el más destacado entre todos los Escenarios evaluados.




Figura. 43 Matriz de Correlación entre Variables Climáticas y Precipitación

La Tabla 16 de interpretación de la matriz de correlación en relación con la precipitación, proporciona información sobre los factores que tienen mayor influencia en la predicción de la precipitación.

Tabla 16 Interpretación de la Matriz de Correlación en Relación con la Precipitación

Variable	Correlación con Precipitaciones (real)	Interpretación	Importancia para la predicción
Humedad Relativa (Humedad_Relativa)	0.84	Fuerte relación positiva, mayor humedad implica más probabilidades de lluvia.	Variable clave. Alta influencia en la predicción y en las lluvias.
Humedad Específica (HE)	0.72	Correlación positiva moderada, mayor	Importante para la predicción. Refleja la

		contenido de vapor de agua favorece la precipitación.	disponibilidad de humedad.
Dirección del Viento (DV)	0.51	Correlación positiva moderada, ciertas direcciones de viento pueden transportar más humedad.	Moderada importancia. Algunas direcciones favorecen las lluvias.
Temperatura Superficial del Mar (TM)	0.58	Correlación positiva moderada, aguas más cálidas generan mayor evaporación y humedad.	Importancia moderada. Contribuye al aumento de la humedad atmosférica.
Presión Atmosférica (Presion_Atmosferica)	-0.19	Relación negativa débil, presiones más bajas suelen favorecer la lluvia.	Influencia baja. No es un predictor dominante.
Temperatura del Aire (Temperatura)	-0.11	Relación negativa débil, la temperatura no está directamente relacionada con la lluvia.	Baja importancia para la predicción.
Velocidad del Viento (Velocidad_Viento)	-0.05	Relación negativa débil, vientos fuertes pueden dispersar la humedad y reducir las lluvias.	Importancia baja, su influencia es mínima.

En la predicción de las precipitaciones, los factores de mayor impacto comprenden la humedad relativa, la humedad específica y la temperatura superficial del mar, mientras que la orientación del viento tiene un efecto menos significativo. La priorización de estas variables en la elaboración de Escenarios predictivos mejora la exactitud en la predicción de las precipitaciones.

8. CONCLUSIONES

- El análisis de la base de datos meteorológicas del INAMHI y la NASA presentó valores faltantes en los registros. Lo que demandó la aplicación de métodos de imputación, entre los que se emplearon los métodos pmm. match y Missforest. El análisis comparativo

determinó que MissForest fue el método más eficiente para imputación de datos faltantes, ya que permitió completar las series temporales con datos más coherentes en las condiciones climáticas reales. La base de datos de la NASA no requirió de imputación de datos ya que contenía registros completos y constantes durante periodos mensuales.

- Se desarrollaron cuatro escenarios para valorar el rendimiento predictivo a través de métricas, utilizando estas bases de datos. Los escenarios 1 y 2 se basaron en datos del INAMHI, lo que mostró limitaciones en la predicción de eventos extremos debido a la dependencia de la calidad de la información. El Escenario 3 con datos de la NASA y una arquitectura ideal de red neuronal (10,7,5,2), presentó mejor aprendizaje y sin sobreajuste, con un MAE de 0.79, un RMSE de 1.01 y un R2 de 0.70, sobresaliendo por su habilidad para capturar el 70% de la variabilidad de las precipitaciones.
- Los modelos 1,2,4 se encuentran dentro de los rangos de las métricas de evaluación lo que quiere decir que son aptos para su uso, sin embargo, desde un enfoque hidrológico no muestran coherencia en las series temporales y requieren de mayor precisión en las imputaciones de las bases de datos.

9. RECOMENDACIONES

- Se recomienda la recopilación de base de datos completos, para garantizar predicciones con mayor confiabilidad, disminuyendo la necesidad de técnicas de imputación lo que reducirá la presencia de valores atípicos en los estudios.
- Se recomienda utilizar arquitecturas diferentes y bases de datos horarios o diarios completas para mejorar el entrenamiento en redes neuronales y lograr predicciones más confiables.
- Se recomienda realizar la validación del modelo del Escenario 3 incorporando nuevas bases de datos, teniendo en cuenta diversas fuentes. Esta metodología permitirá la evaluación integral de la robustez y confiabilidad del modelo, no solo mediante un análisis métrico, sino también en términos de su eficacia y precisión en situaciones hidrológicas.

10. BIBLIOGRAFIA

- [1] Sistema Nacional de Información Ambiental, “EVENTOS EXTREMOS Y DESASTRES OCURRENCIA EVENTOS EXTREMOS Y DESASTRES FRECUENCIA ACUMULADA,” vol. 17, 1906.
- [2] Comisión Nacional del Agua, “Manual para el control de inundaciones,” vol. 2416, 2011, Accessed: Jan. 23, 2025. [Online]. Available: www.conagua.gob.mx
- [3] Jorge Julián Vélez Upegui, “(PDF) DESARROLLO DE UN MODELO DISTRIBUIDO DE PREDICCIÓN EN TIEMPO REAL PARA EVENTOS DE CRECIDAS.” Accessed: Jan. 21, 2025. [Online]. Available: https://www.researchgate.net/publication/271203785_DESARROLLO_DE_UN_MODEL_O_DISTRIBUIDO_DE_PREDICCION_EN_TIEMPO_REAL_PARA_EVENTOS_DE_CRECIDAS
- [4] Organización de las Naciones Unidas, “ONU-Habitat - Sequías, tormentas e inundaciones: el agua y el cambio climático dominan la lista de desastres.” Accessed: Jan. 23, 2025. [Online]. Available: <https://onu-habitat.org/index.php/sequias-tormentas-e-inundaciones-el-agua-y-el-cambio-climatico-dominan-la-lista-de-desastres>
- [5] Organización de las Naciones Unidas, “Sequías, tormentas e inundaciones: el agua y el cambio climático dominan la lista de desastres | Noticias ONU.” Accessed: Jan. 23, 2025. [Online]. Available: <https://news.un.org/es/story/2021/07/1494632>
- [6] Red de Estudios Sociales en Prevención de Desastres en América Latina, “Especial : La Sequía en el Nordeste del Brasil,” vol. 5, Jun. 1995.
- [7] M. y E. A. Instituto de Hidrología, “Sede electrónica del Ideam en construcción | Instituto de Hidrología, Meteorología y Estudios Ambientales.” Accessed: Jan. 23, 2025. [Online]. Available: <https://www.ideam.gov.co/web/agua/modelacion-hidrologica>
- [8] Dr. Juan Julio Ordoñez Gálvez, “‘Contribuyendo al desarrollo de una Cultura del Agua y la Gestión Integral del Recurso Hídrico’ ¿QUÉ ES CUENCA HIDRÓLOGICA? ¿QUÉ ES CUENCA HIDRÓLOGICA?,” 2011.
- [9] Andrea L. Varela y Santiago R. Ron, “Geografía y clima,” Pontificia Universidad Católica del Ecuador. Accessed: Jan. 23, 2025. [Online]. Available: <https://bioweb.bio/fungiweb/GeografiaClima/>
- [10] Intergovernmental Panel on Climate Change (IPCC), “Future Global Climate: Scenario-based Projections and Near-term Information,” *Climate Change 2021 – The Physical Science Basis*, pp. 553–672, Jun. 2023, doi: 10.1017/9781009157896.006.
- [11] J. C. Robert Hofstede and y Marcos Cerra, “LOS PÁRAMOS ANDINOS ¿Qué Sabemos?,” *UICN*, p. 79, 2014, Accessed: Jan. 23, 2025. [Online]. Available: www.uicn.org/sur
- [12] GAD Municipal de Sigchos, “Las Pampas,” Gobierno Autónomo Descentralizado de la Parroquia Las Pampas. Accessed: Jan. 23, 2025. [Online]. Available: https://www.gadmsigchos.gob.ec/new/index.php?option=com_content&view=article&id=382&Itemid=703

- [13] B. S. Carlos Amat y León and en el marco de la A. A. Andina. María Teresa Cigarán y David Vásquez, “El Cambio Climático no tiene fronteras,” *Comunidad Andina*, p. 40, May 2008, Accessed: Jan. 23, 2025. [Online]. Available: www.comunidadandina.org
- [14] Manuel Antonio Martínez Guzmán, “TECNOLOGÍAS PARA EL USO SOSTENIBLE DEL AGUA Una contribución a la seguridad alimentaria y la adaptación al cambio climático,” *Tegucigalpa, M.D.C.*, Oct. 2013, Accessed: Jan. 23, 2025. [Online]. Available: www.gwpcentroamerica.org.
- [15] A. Urquiza and M. Billi, “Seguridad hídrica y energética en América Latina y el Caribe Definición y aproximación territorial para el análisis de brechas y riesgos de la población,” *Naciones Unidas*, p. 138, 2020, Accessed: Jan. 23, 2025. [Online]. Available: www.cepal.org/apps
- [16] M. E. A. Andrea Carrión, “Investigación aplicada sobre cambio climático: aportes para ciudades de América Latina,” *FLACSO*, p. 238, Mar. 2020, Accessed: Jan. 23, 2025. [Online]. Available: www.flacsoandes.edu.ec
- [17] D. Neira-Rodado, J. C. Paz-Roa, J. W. Escobar, and M. Á. Ortiz-Barrios, “A novel machine learning approach for spatiotemporal prediction of EMS events: A case study from Barranquilla, Colombia,” *Heliyon*, vol. 11, no. 2, p. e41904, Jan. 2025, doi: 10.1016/J.HELIYON.2025.E41904.
- [18] Unidad de Cambio Climático, de la División de Desarrollo Sostenible y Asentamientos Humanos de la Comisión Económica para América Latina y el Caribe, “Medidas de adaptación y mitigación frente al cambio climático en América Latina y el Caribe .” Accessed: Jan. 23, 2025. [Online]. Available: <https://repositorio.cepal.org/server/api/core/bitstreams/889969d0-e5a0-48cf-a01d-54432324a595/content>
- [19] M. Saha, A. Santara, P. Mitra, A. Chakraborty, and R. S. Nanjundiah, “Prediction of the Indian summer monsoon using a stacked autoencoder and ensemble regression model,” *Int J Forecast*, vol. 37, no. 1, pp. 58–71, Jan. 2021, doi: 10.1016/J.IJFORECAST.2020.03.001.
- [20] J. Schmitt, F. Offermann, M. Söder, C. Frühauf, and R. Finger, “Extreme weather events cause significant crop yield losses at the farm level in German agriculture,” *Food Policy*, vol. 112, Oct. 2022, doi: 10.1016/j.foodpol.2022.102359.
- [21] X. Ren *et al.*, “Deep Learning-Based Weather Prediction: A Survey,” *Big Data Research*, vol. 23, Feb. 2021, doi: 10.1016/J.BDR.2020.100178.
- [22] S. D. Latif *et al.*, “Assessing rainfall prediction models: Exploring the advantages of machine learning and remote sensing approaches,” *Alexandria Engineering Journal*, vol. 82, pp. 16–25, Nov. 2023, doi: 10.1016/J.AEJ.2023.09.060.
- [23] P. Negro and C. Pons, “Extracción de reglas de redes neuronales feedforward entrenadas con lógica de primer orden,” *Electronic Journal of SADIO*, vol. 23, no. 2, Apr. 2024, Accessed: Feb. 16, 2025. [Online]. Available: <http://sedici.unlp.edu.ar/handle/10915/167050>

- [24] A. N. Aizansi, K. O. Ogunjobi, and F. K. Ogou, "Monthly rainfall prediction using artificial neural network (case study: Republic of Benin)," *Environmental Data Science*, vol. 3, p. e11, 2024, doi: 10.1017/EDS.2024.10.
- [25] A. Y. Barrera-Animas, L. O. Oyedele, M. Bilal, T. D. Akinosho, J. M. D. Delgado, and L. A. Akanbi, "Rainfall prediction: A comparative analysis of modern machine learning algorithms for time-series forecasting," *Machine Learning with Applications*, vol. 7, p. 100204, Mar. 2022, doi: 10.1016/J.MLWA.2021.100204.
- [26] W. Contreras Urgilés, J. Maldonado Ortega, R. León Japa, W. Contreras Urgilés, J. Maldonado Ortega, and R. León Japa, "APLICACIÓN DE UNA RED NEURONAL FEED-FORWARD BACKPROPAGATION PARA EL DIAGNÓSTICO DE FALLAS MECÁNICAS EN MOTORES DE ENCENDIDO PROVOCADO," *Ingenius. Revista de Ciencia y Tecnología*, vol. 2019, no. 21, pp. 32–40, 2019, doi: 10.17163/ING.S.N21.2019.03.
- [27] R. F. Turkson, F. Yan, M. K. A. Ali, and J. Hu, "Artificial neural network applications in the calibration of spark-ignition engines: An overview," *Engineering Science and Technology, an International Journal*, vol. 19, no. 3, pp. 1346–1359, Sep. 2016, doi: 10.1016/J.JESTCH.2016.03.003.
- [28] E. Académico, P. De Ambiental, Y. Yacira, and E. Tiza, "FACULTAD DE INGENIERÍA," 2020.
- [29] J. Manuel Peralta Jaramillo, A. Lopez Agüera, A. Barriga, and I. Sosa-Tinoco, "Análisis estadístico de la información meteorológica para la explotación de energías renovables en el," 2013, Accessed: Jan. 25, 2025. [Online]. Available: <https://www.researchgate.net/publication/262420217>
- [30] P. INEC, "CONCEPTOS Y DEFINICIONES," p. 8, 2023.
- [31] Msc Ing. Abel A. Muñiz Paucarmayta, "Capitulo II Precipitacion | PDF | Precipitación | Nube." Accessed: Jan. 21, 2025. [Online]. Available: <https://es.scribd.com/document/279044843/Capitulo-II-Precipitacion>
- [32] E. Varas, "ICH 3202-HIDROLOGÍA," 2001.
- [33] S. Soto, M. Desamparados, and P. Vegetal, "Nubosidad, niebla y meteoros eléctricos Apellidos, nombre," 2020.
- [34] H. Grassl, "Chapter 1.1 Climate and oceans," *International Geophysics*, vol. 77, no. C, pp. 3–9, 2001, doi: 10.1016/S0074-6142(01)80108-X.
- [35] F. De Ciencias, "ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO," 2014.
- [36] J. Miguel and V. Rubio, "E.M. n° 45 Septiembre-Diciembre 2013 ORIGEN Y DESARROLLOS ACTUALES DE LA PREDICCIÓN METEOROLÓGICA," *Encuentros Multidisciplinarios*, vol. 45, Sep. 2013.
- [37] A. Pastor Saavedra, "Predicciones mensual, estacional y anual," vol. 28, 2009, doi: 10.31978/014-18-009-X.28.

- [38] Monarch, “What is a Short Range Weather Forecast .” Accessed: Jan. 26, 2025. [Online]. Available: <https://www.monarchweather.com/weather-glossary/what-is-a-short-range-weather-forecast>
- [39] L. Judith Sandoval, “ALGORITMOS DE APRENDIZAJE AUTOMÁTICO PARA ANÁLISIS Y PREDICCIÓN DE DATOS,” vol. 11, p. 5, Jul. 2018.
- [40] Pablo Antonio Stack Sánchez, “Métodos de Aprendizaje Supervisado y no Supervisado para la Estimación de Microestructura Cerebral en Datos de DWMR,” Guanajuato, 2021. Accessed: Feb. 15, 2025. [Online]. Available: <https://cimat.repositorioinstitucional.mx/jspui/bitstream/1008/1129/1/TE%20835.pdf#page=41&zoom=100,120,453>
- [41] A. Shakarami, M. Ghobaei-Arani, and A. Shahidinejad, “A survey on the computation offloading approaches in mobile edge computing: A machine learning-based perspective,” *Computer Networks*, vol. 182, Dec. 2020, doi: 10.1016/j.comnet.2020.107496.
- [42] W. Ejaz, M. Basharat, S. Saadat, A. M. Khattak, M. Naeem, and A. Anpalagan, “Learning paradigms for communication and computing technologies in IoT systems,” *Comput Commun*, vol. 153, pp. 11–25, Mar. 2020, doi: 10.1016/j.comcom.2020.01.043.
- [43] R. C. Cubas, D. Por, B. Melián, B. J. Marcos, and M. Vega, “Machine Learning aplicado a un problema de Regresión Machine Learning in a Regression Problem”.
- [44] R. C. Cubas, D. Por, B. Melián, B. J. Marcos, and M. Vega, “Machine Learning aplicado a un problema de Regresión Machine Learning in a Regression Problem,” May 2024.
- [45] V. Alvarez Gálvez and A. Soto Suárez, “Introducción a la programación en Python,” pp. 1–88, 2020.
- [46] A. Downey *et al.*, “Aprenda a Pensar Como un Programador con Python”, Accessed: Feb. 17, 2025. [Online]. Available: www.gnu.org
- [47] E. Paradis and J. A. Ahumada, “R para Principiantes”.
- [48] José Ulises Jimenez, “Introducción a R y RStudio,” *Centro de Investigaciones Hidraulicas e Hidrotecnicas*, pp. 1–21, Dec. 2019, Accessed: Jan. 26, 2025. [Online]. Available: <https://ridda2.utp.ac.pa/bitstream/handle/123456789/9428/manual-introduccion-R.pdf>
- [49] W. Venables, R. Gentleman & R. Ihaka, and M. Machler, *Introducción a R*. 1999.
- [50] M. Ortiz Domínguez, “Redes neuronales artificiales,” *Ingenio y Conciencia Boletín Científico de la Escuela Superior Ciudad Sahagún*, vol. 12, no. 23, pp. 38–44, Jan. 2025, doi: 10.29057/ESCS.V12I23.14132.
- [51] I. Bonet Cruz, S. Salazar Martinez, A. R. Abed, G. Abalo, and M. M. G. Lorenzo, “Redes neuronales recurrentes para el analisis de secuencias Recurrent neural network for sequences analysis”.
- [52] Leonardo César Corbalán, “Una nota sobre Evolución de redes neuronales para comandar criaturas que alcanzan objetivos sorteando obstáculos en un entorno virtual 2D del estilo,” Argentina, 2002.

- [53] J. M. D, “Capítulo 2 Redes neuronales para el modelado de sistemas dinámicos: los módulos neuronales,” Apr. 2001.
- [54] J. de la Torre, “REDES GENERATIVAS ADVERSARIAS (GAN) FUNDAMENTOS TEÓRICOS Y APLICACIONES SURVEY,” 2023.
- [55] A. Gupta, R. S. Kaler, and H. Singh, “Investigation of OBS assembly technique based on various scheduling techniques for maximizing throughput,” *Optik (Stuttg)*, vol. 124, no. 9, pp. 840–844, May 2013, doi: 10.1016/j.ijleo.2012.01.044.
- [56] Andrea Bentancor1 and Pablo Pincheira, “Predicción de errores de proyección de inflación en Chile,” *Scielo*, vol. 77, Mar. 2010, Accessed: Feb. 20, 2025. [Online]. Available: https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2448-718X2010000100129
- [57] C. A. de Souza, C. B. Westphall, R. B. Machado, L. Loffi, C. M. Westphall, and G. A. Geronimo, “Intrusion detection and prevention in fog based IoT environments: A systematic literature review,” *Computer Networks*, vol. 214, Sep. 2022, doi: 10.1016/j.comnet.2022.109154.
- [58] M. Rakcheep, M. Laosakun, S. Khaengkarn, and J. Srisertpol, “Enhancing testing cell set efficiency: A machine learning approach on hard disk drive data,” *Manuf Rev (Les Ulis)*, vol. 11, p. 11, 2024, doi: 10.1051/MFREVIEW/2024008.
- [59] M. Á. Pérez Chavarría, H. H. Hidalgo Silva, and F. J. Ocampo Torres, “Predicción de series de tiempo aplicando redes neuronales artificiales,” *Ciencias marinas, ISSN 0185-3880, ISSN-e 2395-9053, Vol. 28, N.º. 1 (MAR), 2002, págs. 67-77*, vol. 28, no. 1, pp. 67–77, 2002, Accessed: Feb. 15, 2025. [Online]. Available: <https://dialnet.unirioja.es/servlet/articulo?codigo=4706007&info=resumen&idioma=ENG>
- [60] Julieth Cerón, “RPubs - MAE y RMSE.” Accessed: Jan. 26, 2025. [Online]. Available: https://rpubs.com/stefens07/MAE_RMSE
- [61] MathWorks, “Coeficiente de determinación (R-cuadrado).” Accessed: Jan. 26, 2025. [Online]. Available: <https://www.mathworks.com/help/stats/coefficient-of-determination-r-squared.html>
- [62] R. R. Ripoll, J. B. Maline, G. A. G. Montoya, F. N. M. Castillo, and L. B. T. Pesantez, *Decision Trees. A Practical Tool for Happy Manager Decision Making*, vol. 53, no. 9. Editorial de la Universidad Nacional Experimental Rafael María Baralt, 2018. Accessed: Jan. 26, 2025. [Online]. Available: <https://pure.ups.edu.ec/es/publications/decision-trees-a-practical-tool-for-happy-manager-decision-making>
- [63] C. Alberto Ruiz Marta Susana Basualdo Autor and D. Jorge Matich, “Cátedra: Informática Aplicada a la Ingeniería de Procesos-Orientación I Redes Neuronales: Conceptos Básicos y Aplicaciones,” pp. 1–55, Mar. 2001.
- [64] NOAA, “‘Sentinel-3,’ Ocean Watch,” Sentinel-3. Ocean Watch. Accessed: Feb. 20, 2025. [Online]. Available: <https://oceanwatch.noaa.gov/cwn/platforms/sentinel-3.html>
- [65] Agencia Espacial Europea, “Copernicus.” Accessed: Feb. 20, 2025. [Online]. Available: <https://sentiwiki.copernicus.eu/web/slstr-applications>

- [66] S. Peng *et al.*, “Ocean’s largest chlorophyll-rich tongue is extending westward (2002–2022),” *Nature Communications*, vol. 16, no. 1, Dec. 2025, doi: 10.1038/S41467-024-55650-8.
- [67] J. J. Bryan Duncan, “Aura - Sistema de observación de la Tierra de la NASA.” Accessed: Feb. 22, 2025. [Online]. Available: <https://eosps.nasa.gov/missions/aura>
- [68] F. Chollet and J. J. Allaire, “Deep Learning with R,” 2018.
- [69] M. Lezaun, “Predicciones del Tiempo y Matemáticas,” *Bol. Soc. Esp. Mat. Apl. n o*, vol. 22, pp. 61–100, 2002.
- [70] Joaquín Amat Rodrigo, “Redes neuronales con R,” Jul. 2021. Accessed: Feb. 15, 2025. [Online]. Available: <https://cienciadedatos.net/documentos/68-redes-neuronales-r>
- [71] T. O. Hodson, “Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not,” *Geosci Model Dev*, vol. 15, no. 14, pp. 5481–5487, Jul. 2022, doi: 10.5194/GMD-15-5481-2022.
- [72] A. Novales, “Análisis de Regresión,” Sep. 2010, Accessed: Feb. 15, 2025. [Online]. Available: <https://www.ucm.es/data/cont/docs/518-2013-11-13-Analisis%20de%20Regresion.pdf>