

**Construcción un prototipo de sistema computacional inteligente para predicción
meteorológica en la Universidad de Cundinamarca Extensión Facatativá**

AUTOR(ES)

Bryan Rene Rojas Hernández

Nathalia Gutiérrez Alarcón

DIRECTOR

Ing. Jaime Eduardo Andrade Ramírez

UNIVERSIDAD DE CUNDINAMARCA

Facultad de Ingeniería

Programa de Ingeniería de Sistemas

Facatativá, abril de 2025

Construcción un prototipo de sistema computacional inteligente para predicción meteorológica en la Universidad de Cundinamarca Extensión Factativa

AUTOR(ES)

Director

Director: Ing. JAIME EDUARDO ANDRADE RAMIREZ

Especialista en Gerencia de comunicaciones

Magister en sistemas automáticos de producción

GRUPO DE INVESTIGACIÓN DE SISTEMAS Y TECNOLOGÍA DE FACATATIVÁ (GISTFA)

UNIVERSIDAD DE CUNDINAMARCA

Facultad de Ingeniería

Programa de Ingeniería de Sistemas

Facatativá, abril de 2025

DEDICATORIA

Bryan Rojas

Primero que todo dedico este proyecto a mi guía Dios todo poderoso, mi Familia que siempre estuvo apoyándome en todo mi proceso profesional, mi guerrero Félix Stiven, mi compañera de grado y novia, mi director de Grado Jaime Andrade, Co-Autor Álvaro Beltrán, Gladys y amigos como Gabriel que estuvieron acompañándome en este proceso de aprendizaje y lleno de frutos le dedico este proyecto que en lo personal lo apode Máquina Del Tiempo.

Con el corazón lleno de gratitud, dedicamos este proyecto de grado, primero que todo, a Dios, quien con su infinita sabiduría y fortaleza nos acompañó en cada paso de este proceso. Sin Su guía, no habría sido posible llegar hasta aquí.

Nathalia Gutiérrez

Dedico este proyecto primero a Dios todopoderoso, mi guía espiritual que me ha dado fortaleza y sabiduría en cada etapa de este proceso académico.

A mi familia, pilar fundamental en mi vida, por su apoyo incondicional, por cada palabra de aliento y por estar presentes en cada paso de este camino.

A Felix, el fiel compañero felino que nos acompañó durante largas noches de estudio, siendo testigo silencioso de nuestro esfuerzo y dedicación a pesar de su enfermedad.

A Bryan Rojas, mi novio y compañero de grado, por su colaboración y las traspasadas compartidas que nos permitieron culminar este proyecto con éxito.

A nuestro director Jaime Andrade, Co-Autor Álvaro Beltrán, Gladys y Facultad en general por su valiosa orientación académica y profesional.

AGRADECIMIENTOS

Bryan Rojas

La culminación de este proyecto de grado representa no solo el cierre de una etapa académica, sino también el reflejo de los esfuerzos, enseñanzas y apoyo de muchas personas a quienes queremos agradecer profundamente.

Agradezco a Dios por su fortaleza, a mi familia por su paciencia y apoyo, a Felix por su compañía en aquellas noches de desvelo, a Gladys por su colaboración, a Jaime Andrade y Álvaro Beltrán por su guía académica, y a la Universidad por la formación recibida.

Gracias a todos por ser parte de este importante logro.

Nathalia Gutiérrez

A Dios todopoderoso, mi fuente de fortaleza y esperanza, quien me permitió superar cada obstáculo en este proceso académico.

A mi familia, por su paciencia durante mis ausencias, por comprender mis momentos de estrés y por brindarme el soporte necesario para continuar.

A Felix, nuestro guerrero felino, que a pesar de su enfermedad estuvo presente en cada traspasada, haciéndonos compañía en los momentos más difíciles.

A Bryan Rojas, mi compañero de vida y de estudios, por cada noche de desvelo compartida, por tu paciencia, amor y por impulsarme a ser mejor cada día; por su compromiso con el proyecto y las horas de trabajo compartidas que hicieron posible este logro académico.

A nuestro director Jaime Andrade, por compartir su conocimiento y exigirnos la excelencia académica.

Agradezco profundamente a Gladys, del Programa de Ingeniería de Sistemas y Computación, por su constante apoyo y admirable paciencia

A nuestro profesor de otra facultad Álvaro Beltrán, por sus valiosas contribuciones que enriquecieron significativamente nuestro trabajo.

Gracias a todos por acompañarme en esta importante etapa de mi formación académica.

COMPROMISO DE AUTOR

Yo, Bryan Rene Rojas Hernández, con cédula de identidad No. 1000049801 y con cód. 461221169estudiante del programa de Ingeniería de Sistemas de la Universidad de Cundinamarca, declaro que:

El contenido del presente documento es un reflejo de mi trabajo personal y manifiesto que, ante cualquier notificación de plagio, copia o falta a la fuente original, soy responsable directo legal, económico y administrativo sin afectar al director del trabajo, a la Universidad y a cuantas instituciones hayan colaborado en dicho trabajo, asumiendo las consecuencias derivadas de tales prácticas.

Firma:



COMPROMISO DE AUTOR

Yo, Nathalia Gutiérrez Alarcón con cédula de identidad No.1193574756 y con cód. 261220209 estudiante del programa de

Ingeniería de Sistemas de la Universidad de Cundinamarca, declaro que:

El contenido del presente documento es un reflejo de mi trabajo personal y manifiesto que, ante cualquier notificación de plagio, copia o falta a la fuente original, soy responsable directo legal, económico y administrativo sin afectar al director del trabajo, a la Universidad y a cuantas instituciones hayan colaborado en dicho trabajo, asumiendo las consecuencias derivadas de tales prácticas.

Firma:

Handwritten signature of Nathalia G. in black ink.

RESUMEN

La predicción meteorológica en la Sabana de Occidente enfrenta una limitada integración tecnológica, lo que resulta en pronósticos con poca precisión espacial y escasa adaptación a las necesidades específicas de sus diversos sectores. Reconociendo la complejidad geográfica, la marcada variabilidad climática y las restricciones en la infraestructura de monitoreo y la comunicación de la información en esta región, el presente proyecto aborda esta problemática mediante el desarrollo de un sistema computacional inteligente para la predicción del microclima en la Universidad de Cundinamarca, extensión Facatativá. Este innovador sistema integra sensores meteorológicos de alta precisión y calibrados, protegidos mediante carcasas impresas en 3D resistentes a la intemperie, con algoritmos de lógica difusa y software de inteligencia artificial. Esta combinación optimiza la medición y predicción de variables climáticas a nivel local. Se implementó una estación meteorológica de bajo costo, equipada con sensores para temperatura, humedad, radiación solar, precipitación y velocidad del viento, gestionada eficientemente por un microcontrolador ESP32 para la captura, transmisión y análisis de datos. Los resultados obtenidos confirman que esta sinergia entre hardware y software mejora sustancialmente el monitoreo climático local, abriendo oportunidades inmediatas en agricultura de precisión, gestión ambiental y planificación académica. La evaluación del sistema demostró su capacidad para generar mediciones y predicciones fiables con un horizonte de hasta 72 horas, revelando patrones meteorológicos específicos del entorno universitario que no son capturados por los pronósticos generales de la región. En conclusión, este sistema computacional representa un avance significativo en el monitoreo y la predicción de las condiciones meteorológicas locales, constituyéndose como una valiosa contribución a la independencia tecnológica en este campo. Al ofrecer una alternativa de hardware y software de bajo costo y con un notable potencial de replicación en otros contextos educativos y productivos, el proyecto sienta las bases para una gestión climática más informada y adaptada a las realidades locales.

Palabras clave: Meteorología, Inteligencia Artificial, Redes Neuronales LSTM, Lógica Difusa, Estación Meteorológica, ESP32, Sensores Meteorológicos, Pronóstico Meteorológico, sistema Computacional, IoT.

ABSTRACT

Weather forecasting in the Sabana de Occidente faces limited technological integration, resulting in forecasts with low spatial accuracy and poor adaptation to the specific needs of its various sectors. Recognizing the geographical complexity, the marked climatic variability and the restrictions in monitoring infrastructure and information communication in this region, the present project addresses this problem by developing an intelligent computational system for microclimate prediction at the University of Cundinamarca, Facatativá extension. This innovative system integrates high-precision and calibrated meteorological sensors, protected by weather-resistant 3D

printed housings, with fuzzy logic algorithms and artificial intelligence software. This combination optimizes the measurement and prediction of local weather variables. A low-cost weather station was implemented, equipped with sensors for temperature, humidity, solar radiation, precipitation and wind speed, efficiently managed by an ESP32 microcontroller for data capture, transmission and analysis. The results obtained confirm that this synergy between hardware and software substantially improves local climate monitoring, opening up immediate opportunities in precision agriculture, environmental management and academic planning. The evaluation of the system demonstrated its ability to generate reliable measurements and predictions with a horizon of up to 72 hours, revealing weather patterns specific to the university environment that are not captured by general forecasts for the region. In conclusion, this computational system represents a significant advance in the monitoring and prediction of local meteorological conditions, constituting a valuable contribution to technological independence in this field. By offering a low-cost hardware and software alternative with a remarkable potential for replication in other educational and productive contexts, the project lays the foundations for a more informed climate management adapted to local realities.

Keywords: Meteorology, Artificial Intelligence, LSTM Neural Networks, Fuzzy Logic, Weather Station, ESP32, Weather Sensors, Weather Forecasting, Computational system, IoT.

1.7.1.2.4.1.3. Generación de Salidas o Predicciones (Output Layer)	57
1.7.1.2.3. Espectro visible, radiación y fotones.	61
1.7.1.2.1.4. Relación con luxes, watts y julios.	61
1.7.1.2.1.6.¿Por qué es importante esto en un sistema meteorológico?	63
1.7.1.3.3. Redes de Sensores e Internet de las Cosas (IoT).	63
1.7.1.4.2. Entrenamiento y Optimización de modelos	67
1.7.1.5. Climatología y Agroclimatología Aplicada.	71
1.7.6.1 Agricultura de Precisión.	75
1.7.6.1.1 Heladas.....	75
1.7.6.1.3. Estrés Hídrico.....	76
1.7.6.2.1. Balance Hídrico y Control en Cultivos.	77
1.7.1.7.1.2 Prototipado Evolutivo para Hardware.	79
1.7.2 MARCO LEGAL.....	81
II. DOCUMENTACIÓN DEL SOFTWARE	91
2.1.1. Resumen del Desarrollo del Proyecto "Predicción Meteorológica"	91
2.1.2.2. Diseño del Circuito	94
2.1.2.3. Pruebas Individuales	94
2.1.2.4. Validación del Sistema	95
2.1.3. Gestión y Seguimiento del Proyecto.....	95
2.1.3.1. Herramientas Utilizadas:.....	97
2.2. Determinación de Requerimientos.....	100
2.2. 1Resumen.....	100
2.2.2. Descripción General.....	101
2.2.3 Perspectiva del Producto.....	101

2.2.4 Funciones del Producto.....	101
2.2.5. Restricciones	102
2.2.5.3. Restricciones de Sistema Operativo.....	104
2.2.6 Suposiciones y Dependencias	105
2.2.7 Requisitos Específicos	105
2.3. Especificación del Diseño	108
2.3.1. Diagramas de Casos de Uso.....	108
2.3.2. Diagrama de Secuencia.....	111
2.3.3. Diagrama de Actividades.....	123
2.3.4. Diagrama de Despliegue	134
2.4. Diseño de los Casos de Prueba	136
2.5 ESTIMACIÓN DE RECURSOS.....	139
2.5.1. UCP no ajustados.....	140
2.5.2. Factor de Complejidad Técnica (FCT)	140
2.5.3. Factor de Complejidad Ambiental (FCA).....	142
2.5.4. UCP Ajustados.....	142
2.5.5. Esfuerzo Total.....	142
2.5.6. Distribución Real del Trabajo	142
2.5.7. Comparación de la Estimación con lo Real	143
2.5.8. Distribución del Esfuerzo por Fases	143
2.5.9. Distribución por Casos de Uso Principales.....	143
2.6 Resultados.....	147
2.6.1 Calibración de sensores.....	167
2.6.2. Funcionamiento Técnico.....	181
2.6.5. Activación de Alertas con Umbrales	183

2.6.3. Sistema Inteligente para Monitoreo y Predicción Meteorológica.....	185
2.6.3. Desarrollo del Modelo de Inteligencia Artificial	189
2.6.7 Análisis Estadístico de Predicción Meteorológica.....	223
2.7. Conclusiones y recomendaciones	239
2.7.1. Conclusiones	239
2.7.1.1. Conclusión General.....	239
2.7.1.2. Conclusión Personal del Equipo:	241
2.7.1.3.1. Objetivo 1.....	243
2.7.1.3.2. Objetivo 2.....	244
2.7.1.3.3. Objetivo 3.....	247
2.7.1.3.4. Objetivo 4.....	249
2.7.2. Recomendaciones.....	251
2.8. Bibliografía	255

LISTA DE TABLAS

Tabla 1	45
Tabla 2	59
Tabla 3	62
Tabla 4	64
Tabla 5	65
Tabla 6	71
Tabla 7	74
Tabla 8	100
Tabla 9	141
Tabla 10	142
Tabla 11	168
Tabla 12	172
Tabla 13	173
Tabla 14	176
Tabla 15	178
Tabla 16	179
Tabla 17	230
Tabla 18	233
Tabla 19	234

LISTA DE FIGURAS

Figura 1	32
Figura 2	36
Figura 3	38
Figura 4	38
Figura 5	39
Figura 6	39
Figura 7	39
Figura 8	91
Figura 9	96
Figura 10	96
Figura 11	97
Figura 12	98
Figura 13	108
Figura 14	109
Figura 15	110
Figura 16	111
Figura 17	112
Figura 18	114
Figura 19	115
Figura 20	116
Figura 21	117
Figura 22	118
Figura 23	119
Figura 24	120
Figura 25	121
Figura 26	122
Figura 27	123
Figura 28	124
Figura 29	125
Figura 30	126
Figura 31	127
Figura 32	128
Figura 33	129
Figura 34	130
Figura 35	131
Figura 36	132
Figura 37	133
Figura 38	134

Figura 39	136
Figura 40	137
Figura 41	137
Figura 42	138
Figura 43	153
Figura 44	154
Figura 45	155
Figura 46	156
Figura 47	157
Figura 48	157
Figura 49	158
Figura 50	158
Figura 51	159
Figura 52	159
Figura 53	160
Figura 54	161
Figura 55	161
Figura 56	162
Figura 57	163
Figura 58	164
Figura 59	165
Figura 60	165
Figura 61	166
Figura 62	170
Figura 63	171
Figura 64	175
Figura 65	180
Figura 66	181
Figura 67	182
Figura 68	182
Figura 69	183
Figura 70	184
Figura 71	186
Figura 72	187
Figura 73	189
Figura 74	190
Figura 75	191
Figura 76	191
Figura 77	192

Figura 78	193
Figura 79	194
Figura 80	195
Figura 81	196
Figura 82	198
Figura 83	198
Figura 84	199
Figura 85	201
Figura 86	202
Figura 87	203
Figura 88	203
Figura 89	205
Figura 90	206
Figura 91	208
Figura 92	209
Figura 93	209
Figura 94	209
Figura 95	210
Figura 96	210
Figura 97	212
Figura 98	213
Figura 99	214
Figura 100	215
Figura 101	215
Figura 102	216
Figura 103	217
Figura 104	218
Figura 105	218
Figura 106	220
Figura 107	220
Figura 108	221
Figura 109	222
Figura 110	223
Figura 111	224
Figura 112	226
Figura 113	229
Figura 114	232
Figura 115	250

LISTA DE ANEXOS

Anexo 1: Bitácora.....	245
------------------------	-----

I. INTRODUCCIÓN

Las condiciones meteorológicas ejercen una influencia determinante en numerosas actividades humanas, especialmente en sectores como la agricultura, la gestión ambiental y la planificación urbana. La predicción precisa de estas condiciones representa un desafío significativo debido a la complejidad y variabilidad de los sistemas atmosféricos, particularmente a escala local o microclimática. En regiones con topografía variada y características geográficas específicas, como Facatativá en Colombia, los modelos meteorológicos generales frecuentemente no capturan las particularidades climáticas locales, limitando su utilidad para la toma de decisiones en contextos específicos.

La Universidad de Cundinamarca, extensión Facatativá, ubicada en una región con un mesoclima particular influenciado por su altitud, topografía y vegetación circundante, constituye un escenario ideal para el estudio y monitoreo de microclimas. A pesar de contar con una estación meteorológica ubicada en el laboratorio de acuaponía LESTOMA, hasta ahora no se había implementado un sistema integrado que aprovechara estos datos para generar predicciones adaptadas específicamente a las condiciones locales.

Este proyecto surge como respuesta a la necesidad de mejorar la medición y predicción del microclima en el campus universitario, mediante el desarrollo de un prototipo de sistema hardware inteligente que integra sensores meteorológicos calibrados, procesamiento en tiempo real y algoritmos avanzados de inteligencia artificial. El objetivo principal es construir un sistema capaz no solo de medir con precisión variables meteorológicas fundamentales, sino también de generar predicciones fiables a corto y mediano plazo, adaptadas a las características específicas del entorno local.

La convergencia de tecnologías emergentes como el Internet de las Cosas (IoT), la impresión 3D, los sistemas embebidos y la inteligencia artificial ofrece nuevas oportunidades para abordar estos desafíos. Particularmente relevante resulta la aplicación de técnicas como la lógica difusa para el procesamiento en tiempo real de variables meteorológicas interrelacionadas, y las redes neuronales recurrentes (específicamente LSTM) para la identificación de patrones temporales complejos en datos climáticos históricos.

La relevancia de este proyecto se manifiesta en múltiples dimensiones. Desde la perspectiva académica, contribuye al fortalecimiento de la investigación aplicada en la Universidad de Cundinamarca, integrando conocimientos de electrónica, programación, meteorología y aprendizaje automático. En el ámbito tecnológico, propone una solución innovadora que combina hardware y software para resolver un problema concreto, demostrando cómo las tecnologías emergentes pueden aplicarse para crear sistemas que respondan a necesidades locales específicas.

Desde una perspectiva socioeconómica, el sistema desarrollado tiene el potencial de impactar positivamente actividades agrícolas en la región, un sector vital para la economía de Facatativá. Las predicciones microclimáticas precisas permitirían optimizar calendarios de siembra, programas de riego, aplicación de fertilizantes y manejo integrado de plagas, mejorando así la productividad y sostenibilidad de los cultivos. Adicionalmente, el conocimiento detallado del microclima local contribuye a la planificación universitaria, permitiendo programar actividades al aire libre, administrar eficientemente espacios verdes y reducir el consumo energético mediante estrategias adaptadas a las condiciones climáticas previstas.

El marco conceptual del proyecto se sustenta en avances recientes en el campo de la meteorología computacional y la inteligencia artificial aplicada. Investigaciones previas como las de Kuffó Zambrano (2023) han demostrado que las redes neuronales recurrentes (RNN) y Long Short-Term Memory (LSTM) pueden alcanzar precisiones entre 70% y 98% en la predicción de variables meteorológicas, superando significativamente los métodos estadísticos tradicionales. Asimismo, estudios como los de Thomas Alexandre Da Silva (2020) han evidenciado el potencial de estaciones meteorológicas autónomas con tecnología IoT y algoritmos de aprendizaje profundo, logrando predicciones a corto plazo con precisión media superior al 90%.

Una característica distintiva de este proyecto es su enfoque integral que combina hardware diseñado específicamente para el entorno local con algoritmos de inteligencia artificial adaptados a las características del microclima de Facatativá. El sistema implementa dos capas de inteligencia complementarias: una capa de procesamiento inmediato mediante lógica difusa que opera directamente en el microcontrolador, y una capa de análisis profundo y predicción a mediano plazo basada en redes neuronales LSTM ejecutadas en un servidor local. Esta arquitectura híbrida

permite combinar la respuesta inmediata ante condiciones climáticas cambiantes con la capacidad de identificar patrones complejos y tendencias a partir de datos históricos.

La metodología empleada sigue un enfoque sistemático que integra aspectos de ingeniería de hardware, desarrollo de software y validación en sitio. El diseño del hardware se realizó considerando criterios de durabilidad, precisión y eficiencia energética, utilizando técnicas de impresión 3D para fabricar componentes adaptados específicamente a las necesidades del proyecto. La calibración meticulosa de los sensores garantiza la fiabilidad de las mediciones, mientras que la implementación de algoritmos optimizados permite maximizar el rendimiento del sistema con los recursos disponibles.

El presente trabajo documenta el proceso completo de desarrollo del sistema, desde la revisión exhaustiva del estado del arte y el levantamiento de requerimientos, hasta la implementación del hardware, el entrenamiento de los modelos de inteligencia artificial y la evaluación del desempeño del sistema en condiciones reales. Se presta especial atención a la metodología empleada, los desafíos enfrentados y las soluciones implementadas, con el fin de proporcionar una base sólida para futuras investigaciones y desarrollos en este campo.

La estructura del documento sigue el flujo lógico del desarrollo del proyecto. Inicialmente se presenta una revisión del estado del arte y el marco teórico que fundamenta la investigación. Posteriormente se describen en detalle los aspectos metodológicos, incluyendo el diseño e implementación del hardware, el desarrollo de los algoritmos de lógica difusa y aprendizaje profundo, y los protocolos de calibración y validación. A continuación, se presentan y analizan los resultados obtenidos durante el período de evaluación, contrastando las predicciones generadas por el sistema con las condiciones climáticas reales observadas. Finalmente, se discuten las implicaciones de estos hallazgos, las limitaciones identificadas y las oportunidades para futuros desarrollos y aplicaciones.

Los resultados preliminares sugieren que el sistema desarrollado logra capturar con mayor precisión las particularidades del microclima del campus universitario en comparación con los pronósticos meteorológicos generales disponibles para la región. La combinación de mediciones in situ de alta resolución temporal con algoritmos avanzados de análisis y predicción ofrece una herramienta valiosa para comprender y anticipar las condiciones climáticas locales, con

aplicaciones potenciales que trascienden el ámbito académico para extenderse a sectores productivos y de gestión ambiental en la región.

Este proyecto no solo representa una contribución al conocimiento científico y tecnológico en el campo de los sistemas inteligentes para monitoreo y predicción meteorológica, sino que también ofrece una herramienta práctica con potencial para mejorar la toma de decisiones en diversos sectores productivos y académicos de la región, y un modelo replicable que podría adaptarse a otras instituciones y contextos con necesidades similares.

I. INFORME DE INVESTIGACIÓN

1.1 Estado del Arte

Predicción meteorológica urbana basada en datos de estaciones meteorológicas y redes neuronales artificiales

Según el modelo de predicción climática que proponen [1], quienes desarrollaron modelos computacionales para realizar predicciones, principalmente enfocados en variables como temperatura, humedad, precipitación y velocidad del viento. El objetivo es pronosticar las condiciones meteorológicas con mayor precisión. Los métodos más utilizados son: Redes Neuronales Artificiales (RNA), incluyendo: Redes Neuronales Recurrentes (RNN) con algoritmos LSTM (Long Short-Term Memory); Redes Neuronales Feedforward; Redes Neuronales Perceptrón Multicapa; también usaron modelos estadísticos como ARIMA (AutoRegressive Integrated Moving Average). Estos modelos se entrenan con datos históricos de series temporales climáticas. Se utilizan lenguajes de programación como Python y MATLAB, junto con bibliotecas especializadas para aprendizaje automático. Las investigaciones se realizan en diversas instituciones académicas y centros de investigación alrededor del mundo. Los estudios analizados incluyen locaciones en India, Perú, Venezuela, Filipinas y Ecuador, entre otros. La efectividad de los modelos varía según el tipo de red y las variables predichas: Las Redes Neuronales Recurrentes con LSTM alcanzan precisiones del 70% al 98%; Las Redes Neuronales Feedforward y Perceptrón Multicapa logran precisiones entre 72% y 95.5%; Los modelos ARIMA obtienen precisiones del 76% al 80%; La métrica más comúnmente utilizada para evaluar el rendimiento es el Error Cuadrático Medio (MSE). Concluyendo, las variables meteorológicas más frecuentemente

utilizadas son temperatura (máxima, mínima y promedio), humedad relativa, precipitación y velocidad del viento; el tipo de predicción fue a corto y mediano plazo, desde pronósticos diarios hasta mensuales; como inteligencia artificial usaron fueron Las Redes Neuronales Artificiales, especialmente las Recurrentes con LSTM, muestran el mejor desempeño para series temporales climáticas debido a su capacidad para capturar dependencias a largo plazo; los sensores que usaron no fueron mencionados sin embargo, los datos provienen típicamente de estaciones meteorológicas automatizadas que incluyen sensores para medir temperatura, humedad, precipitación y velocidad del viento. Los modelos se implementan utilizando frameworks de aprendizaje automático en Python o MATLAB. El proceso general incluye: Recopilación y preprocesamiento de datos históricos; División de datos en conjuntos de entrenamiento y prueba; Entrenamiento del modelo con técnicas de aprendizaje supervisado; Validación y ajuste del modelo; Realización de predicciones y evaluación del rendimiento.

Según la predicción del microclima urbano basada en datos de estaciones meteorológicas y redes neuronales artificiales [2] se desarrollan modelos de inteligencia artificial, principalmente redes neuronales artificiales (ANN), para predecir las condiciones meteorológicas urbanas y evaluar su impacto en el consumo energético de los edificios. El objetivo es pronosticar con mayor precisión las condiciones meteorológicas locales cerca de los edificios, considerando el efecto de isla de calor urbana. Se recopilan datos de estaciones meteorológicas locales en áreas urbanas y de aeropuertos (considerados como clima no perturbado); se entrenó un modelo de red neuronal artificial (ANN) para establecer la conexión entre los datos del aeropuerto y los datos locales; utilizaron el modelo ANN entrenado para generar datos meteorológicos locales a largo plazo basados en datos históricos del aeropuerto; crearon un Año Meteorológico Típico (TMY) localizado usando los datos generados; realizaron un análisis de sensibilidad para evaluar la importancia de diferentes parámetros meteorológicos; también utilizaron el TMY localizado en simulaciones de consumo energético de edificios usando EnergyPlus. El estudio se realizó en Montreal, Canadá, utilizando datos de cinco estaciones meteorológicas ubicadas en diferentes puntos de la ciudad. El modelo ANN logró predecir con precisión la temperatura del aire ($R^2 = 0.996$, MAE = 0.52°C), velocidad del viento (MAE alrededor de 0.5 m/s) y dirección del viento (MAE alrededor de 30°); el microclima urbano contribuyó a un aumento del 2% al 14% en el consumo de energía para enfriamiento y una reducción del 1% al 10% en el consumo de energía

para calefacción, dependiendo de la ubicación; la temperatura del aire resultó ser el parámetro más significativo en el modelado energético de edificios bajo condiciones de microclima urbano. Concluyendo, las variables meteorológicas más importantes son temperatura del aire, velocidad del viento y dirección del viento; realizaron predicciones a corto y largo plazo, incluyendo la generación de TMY localizados; como inteligencia artificial usaron principalmente una red neuronal artificial de tipo perceptrón multicapa (MLP); los sensores utilizados en las estaciones meteorológicas se equiparon con sensores de temperatura, humedad, velocidad y dirección del viento; implementaron un enfoque de aprendizaje supervisado utilizando Python. El proceso incluye preprocesamiento de datos, entrenamiento del modelo ANN, generación de datos meteorológicos locales a largo plazo y simulación energética de edificios.

Según la estación meteorológica sostenible aplicada con IoT y machine learning [3] se desarrolla una estación meteorológica sustentable, de bajo costo, eléctricamente autónoma e integrada con IoT (Internet of Things). La estación incorpora análisis inteligente de datos locales y algoritmos de deep learning para realizar predicciones meteorológicas a 24 horas. Construyeron el hardware de la estación utilizando sensores como DHT22 (temperatura y humedad), BMP180 (presión), ML8511 (radiación UV), LDR (iluminancia), anemómetro, pluviómetro, etc; programaron un microcontrolador ESP32 para controlar los sensores y enviar datos a un servidor; implementaron la autonomía eléctrica mediante paneles solares y baterías recargables; desarrollaron un sistema web para almacenar y visualizar los datos; entrenaron una red neuronal LSTM (Long Short-Term Memory) bidireccional para realizar predicciones meteorológicas de 24 horas; integraron todo en una interfaz web que muestra datos históricos, predicciones y estadísticas. La estación prototipo se implementó en Taguatinga, Distrito Federal, Brasil. La estación logra autonomía eléctrica de más de 16 horas sin luz solar; obtuvieron predicciones meteorológicas a 24 horas con una precisión media del 90.91%; buena correlación (>90%) entre los datos de la estación prototipo y una estación oficial cercana para temperatura, humedad y presión; menor correlación en datos de viento, posiblemente por obstáculos locales; buena precisión en predicciones de temperatura (MAE 1.5°C), humedad (MAE 6.24%) y presión (MAE 0.68 hPa); menor precisión en predicciones de lluvia acumulada, pero buena clasificación binaria de lluvia/no lluvia (72-77% de precisión). Concluyendo, las principales variables medidas son temperatura, humedad, presión, radiación UV, iluminancia, velocidad y dirección del viento, y precipitación; se utilizaron

predicciones horarias para las próximas 24 horas de temperatura, humedad, presión, punto de rocío, índice de calor, probabilidad de lluvia, etc; como inteligencia artificial se utilizó una red neuronal recurrente LSTM bidireccional; los sensores que implementaron fueron digitales y analógicos especializados para cada variable meteorológica; el sistema utilizó un microcontrolador ESP32 programado en C++ para la adquisición de datos, un backend en Python/Django para el procesamiento y almacenamiento, y un frontend web en HTML/JavaScript para la visualización. La red neuronal se implementa con TensorFlow.

Según la regionalización de la precipitación y temperatura en Santa Catarina con datos de alta resolución temporal y espacial [4] Se realiza una regionalización climática del estado de Santa Catarina (SC), Brasil, utilizando datos de alta resolución temporal y espacial de precipitación y temperatura. El objetivo es entender el comportamiento de estas variables meteorológicas de forma regionalizada. Se aplica la técnica de agrupamiento jerárquico, utilizando el método de Ward, a los datos horarios de las estaciones meteorológicas automáticas (EMAs) de la red del INMET entre 2000 y 2022; estandarizaron los datos para que contribuyan de manera igualitaria al método, independientemente de su escala original; identificaron mesorregiones climáticas distintas en SC basadas en el análisis de agrupamiento; para cada mesorregión, se generan nuevas climatologías de precipitación y temperatura, y se calculan sus variaciones estacionales y ciclos diarios; analizaron los patrones de precipitación y temperatura para cada mesorregión identificada. El estudio se realiza en el estado de Santa Catarina, Brasil, utilizando datos de estaciones meteorológicas automáticas distribuidas por todo el estado. Se identificaron seis mesorregiones climáticas distintas en Santa Catarina: Región Oeste, Medio Oeste, Planalto Norte y Valle del Itajaí, Planalto Serrano, Litoral Sur y Litoral Norte; encontraron patrones distintos de precipitación y temperatura para cada mesorregión; observaron diferencias en los ciclos diarios y estacionales de precipitación y temperatura entre las regiones; identificaron influencias de sistemas meteorológicos específicos en cada región, como los Sistemas Convectivos de Mesoescala (SCM) en la región Oeste. Concluyendo, las principales variables analizadas son precipitación y temperatura, utilizando datos horarios de estaciones meteorológicas automáticas; se realizó un análisis de agrupamiento jerárquico para identificar regiones climáticas homogéneas, seguido de un análisis detallado de los patrones de precipitación y temperatura en cada región; como inteligencia artificial y estadística utilizaron el método de Ward para el agrupamiento jerárquico,

que es una técnica estadística de análisis multivariado; los sensores que utilizaron los datos de las estaciones meteorológicas automáticas (EMAs) de la red del INMET. El estudio se basa en la identificación de patrones similares en los datos de precipitación y temperatura para definir regiones climáticas homogéneas. Luego, se analizan las características específicas de cada región para entender mejor los sistemas meteorológicos que influyen en cada una.

Según la modelación de lluvias anuales utilizando inteligencia artificial en el norte de Bogotá [5] se desarrollan dos modelos de inteligencia artificial (regresiones y redes neuronales artificiales) para calibrar y predecir precipitaciones anuales en la zona norte de Bogotá, Colombia. El objetivo es complementar datos faltantes en registros históricos de precipitación y generar predicciones más precisas. Se recolectan datos de precipitación y otras variables meteorológicas de estaciones del INMET y la Empresa de Acueducto y Alcantarillado de Bogotá; realizaron un pre-procesamiento y análisis de los datos, incluyendo complementación de datos faltantes y análisis de tendencias; desarrollaron dos modelos de inteligencia artificial: a) Un modelo de regresiones basado en árboles de decisión potenciados. b) Una red neuronal artificial utilizando el algoritmo Levenberg-Marquardt; entrenaron los modelos utilizando datos históricos de 1992 a 2013; evaluaron los modelos comparando sus predicciones con datos reales y se generan nuevas bases de datos con valores calibrados. El estudio se realiza en la zona norte de Bogotá, Colombia, centrándose específicamente en la estación meteorológica Apto-Guaymaral ubicada en la localidad de Suba. El modelo de regresiones logró un RMSE de 37.64 y un R de 0.35; el modelo de red neuronal obtuvo un MSE de 658.44 y un R de 0.83; ambos modelos generaron predicciones de precipitación para completar datos faltantes en los registros históricos; los modelos mostraron capacidad para reproducir tendencias generales de precipitación, aunque con algunas discrepancias en años específicos. Concluyendo: Las principales variables analizadas son precipitación, temperatura, humedad relativa, evaporación, brillo solar y número de días con lluvia; se realizaron predicciones mensuales y anuales de precipitación; como inteligencia artificial utilizaron dos modelos de inteligencia artificial: (Regresiones basadas en árboles de decisión potenciados y redes neuronales artificiales con algoritmo Levenberg-Marquardt); Los sensores que utilizaron datos de estaciones meteorológicas automáticas existentes; los modelos se implementan utilizando MATLAB. El proceso incluye preprocesamiento de datos, entrenamiento de modelos, validación y generación de predicciones.

Según la parametrización de estaciones meteorológicas a bajo costo para la caracterización masiva de microclimas urbanos en Bogotá [6] se parametriza el diseño e implementación de estaciones meteorológicas a bajo costo para caracterizar masivamente microclimas urbanos en Bogotá, Colombia. El objetivo es desarrollar una metodología estandarizada que permita implementar estas estaciones de manera eficiente y económica, facilitando el estudio detallado de los microclimas en diferentes zonas de la ciudad. se realiza una revisión exhaustiva de literatura científica sobre el diseño e implementación de estaciones meteorológicas; luego, se construye una propuesta metodológica parametrizada basada en los procedimientos encontrados en la literatura; se diseña e implementa una estación meteorológica prototipo siguiendo la propuesta desarrollada; se utilizaron sensores para medir variables como temperatura, humedad, velocidad y dirección del viento, lluvia y radiación UV; se desarrolla un sistema de adquisición de datos basado en Arduino Mega y NodeMCU ESP8266 para la transmisión inalámbrica; se implementa una API web para el almacenamiento de datos en una base de datos SQL; se crea una aplicación web con arquitectura MVC para la visualización de los datos; se valida la propuesta comparando los datos obtenidos con estaciones meteorológicas robustas y analizando los tiempos de implementación. El estudio se realiza en Bogotá, Colombia. La estación prototipo se implementa en un edificio ubicado en las coordenadas 4.701592256702934, -74.11720556581267. Se logró parametrizar el proceso de diseño e implementación en esquemas metodológicos claros y replicables; se implementa una estación prototipo funcional a un costo aproximado de \$744,000 COP; Los datos obtenidos muestran variaciones respecto a estaciones robustas: temperatura (5.1%), humedad (14.1%), lluvia (6.45%), velocidad del viento (93.96%), dirección del viento (12.3%); Se redujo el tiempo de implementación en un 64.7% respecto a una estación convencional; se desarrolló un sistema funcional de adquisición, transmisión, almacenamiento y visualización de datos meteorológicos. Concluyendo, las principales variables analizadas son temperatura, humedad, velocidad y dirección del viento, lluvia y radiación UV; el estudio no realiza predicciones, se enfoca en la medición y comparación de variables meteorológicas; no se utiliza inteligencia artificial en este proyecto; se utilizaron sensores como DHT22 (temperatura y humedad), GUVVA-S12SD (UV), y el kit meteorológico SEN-15901 (viento y lluvia); se utilizan microcontroladores Arduino Mega y NodeMCU ESP8266 para la adquisición y transmisión de datos; se implementa una API web para el almacenamiento de datos en una base de datos SQL; se desarrolla una aplicación web con

arquitectura MVC para la visualización de los datos.

Según evaluación de los cambios de la cobertura vegetal y su influencia en el microclima en tres zonas urbanas de Villavicencio Meta [7] se evalúa la influencia de los cambios en la cobertura del suelo sobre el microclima en tres zonas urbanas de Villavicencio, Colombia, entre 1994 y 2019. El objetivo es cuantificar los cambios en la cobertura vegetal y zonas urbanas, y correlacionarlos con las variaciones de temperatura para entender el impacto del crecimiento urbano en el clima local. Se recolectan imágenes satelitales Landsat de los años 1991, 1999, 2003, 2014 y 2019; realizaron un preprocesamiento de las imágenes utilizando el software ENVI 4.7; aplicaron una clasificación supervisada de las imágenes para identificar diferentes tipos de cobertura (bosques, pastos, zonas urbanas, etc.); obtuvieron datos de temperatura de estaciones meteorológicas locales; utilizaron sistemas de información geográfica (SIG) como ArcGIS para crear mapas de temperatura y cobertura del suelo; realizaron un análisis estadístico, incluyendo el cálculo del coeficiente de correlación de Pearson, para relacionar los cambios de cobertura con las variaciones de temperatura. El estudio se realiza en tres zonas urbanas de Villavicencio, Colombia, centradas alrededor de las estaciones meteorológicas de La Esmeralda, Cofrem y Catumare. Se observó un aumento significativo de las zonas urbanas, pasando de 35.9% del área en 1991 a 69.9% en 2019; Hubo una disminución correspondiente de la cobertura vegetal (bosques y pastos); la temperatura aumentó aproximadamente 2.67°C entre 1991 y 2019 en el mes de febrero (temporada seca); encontraron una correlación negativa fuerte (-0.91) entre la pérdida de cobertura vegetal y el aumento de temperatura. Concluyendo, las principales variables analizadas son cobertura del suelo (bosques, pastos, zonas urbanas) y temperatura; aunque no se realizan predicciones explícitas, se infiere una tendencia de aumento continuo de temperatura si continúa la pérdida de cobertura vegetal; no se utiliza inteligencia artificial avanzada, pero se emplean técnicas de procesamiento de imágenes y análisis estadístico; los sensores utilizados fueron Imágenes satelitales de Landsat (4-5, 7 y 8) y estaciones meteorológicas terrestres; Uso de SIG (ENVI 4.7 y ArcGIS) para procesar imágenes y crear mapas. Clasificación supervisada de imágenes utilizando el algoritmo de máxima verosimilitud. Análisis estadístico usando el coeficiente de correlación de Pearson.

Según el diseño de prototipo de estación meteorológica portátil como accesorio utilizado por un drone para la obtención de datos meteorológicos en zonas de difícil acceso [8] se desarrolla un prototipo de estación meteorológica portátil que puede ser utilizado por un drone para obtener

datos meteorológicos en zonas de difícil acceso en Colombia. El objetivo es complementar la información de las estaciones meteorológicas fijas y proporcionar datos más precisos en áreas remotas. Se selecciona un dron DJI Mini 2 capaz de transportar el prototipo; se diseña y construye una estación meteorológica portátil utilizando componentes como: (Arduino Nano; Pantalla LCD 16x2; Sensor barométrico BMP180; Sensor de humedad y temperatura DHT22; Otros componentes electrónicos (resistencias, potenciómetro, etc.); se programa el Arduino para recopilar y mostrar los datos de los sensores; se realizan pruebas de campo en la zona rural del municipio de Subachoque, Cundinamarca; se comparan los datos obtenidos con la información suministrada por el IDEAM. El estudio se realiza en Colombia, específicamente en la zona rural del municipio de Subachoque, Cundinamarca. Se logró construir un prototipo funcional de estación meteorológica portátil; obtuvieron datos de temperatura, humedad, presión atmosférica y altitud; encontraron diferencias significativas entre los datos recopilados por el prototipo y los proporcionados por el IDEAM. Concluyendo, el uso de drones con estaciones meteorológicas portátiles puede proporcionar datos más precisos en zonas de difícil acceso; existen diferencias importantes entre los datos locales y los proporcionados por las estaciones meteorológicas fijas; Es necesario considerar la normatividad colombiana para el uso de drones en estas aplicaciones.

Según las estrategias de adaptación de cambio climático basada en ecosistemas para el municipio de Villavicencio [9] se consolida información sobre estrategias de adaptación al cambio climático basadas en ecosistemas para el municipio de Villavicencio, Colombia. Esto incluye: Recopilación de datos meteorológicos históricos (precipitación y temperatura) de los últimos 10 años; identificación de medidas de adaptación al cambio climático a nivel internacional, nacional y local; sistematización y priorización de medidas de adaptación basadas en ecosistemas específicas para Villavicencio. Se analizan datos meteorológicos de estaciones locales del IDEAM para determinar tendencias en precipitación y temperatura; se realiza una revisión exhaustiva de literatura científica, documentos oficiales e instrumentos de planificación sobre adaptación al cambio climático; se revisa el marco normativo y político en materia de cambio climático a nivel nacional y regional; se identifican y priorizan medidas de adaptación basadas en ecosistemas aplicables a Villavicencio; se elaboran fichas detalladas de las medidas priorizadas, incluyendo descripción, objetivos, actividades, barreras, indicadores y costos estimados. El estudio se centra en el municipio de Villavicencio, capital del departamento del Meta, Colombia. Se analizan datos de

estaciones meteorológicas locales y se consideran las características geográficas, ecosistémicas y socioeconómicas específicas del municipio. Se identificaron tendencias en precipitación y temperatura para Villavicencio en los últimos 10 años; se compiló un catálogo de medidas de adaptación implementadas a nivel internacional y nacional; se priorizaron 3 medidas de adaptación basadas en ecosistemas para Villavicencio: (Sistema de abastecimiento de agua en fincas ganaderas; conservación de ecosistemas estratégicos; restauración y enriquecimiento de bosques riparios; se documentaron estrategias ya implementadas en el municipio, como adquisición de predios para conservación, pago por servicios ambientales y reforestación. Concluyendo, el estudio se enfoca en variables meteorológicas (precipitación y temperatura) y medidas de adaptación en los sectores de ganadería, biodiversidad, servicios ecosistémicos y recurso hídrico; no se realizan predicciones, se analizan tendencias históricas y se proponen medidas de adaptación; no se utiliza inteligencia artificial en este estudio; se utilizaron datos de estaciones meteorológicas convencionales del IDEAM; no se menciona el uso de software específico, más allá de herramientas básicas para análisis de datos y elaboración de mapas.

Según la formulación de estrategias de adaptación al cambio climático para los sistemas productivos agroalimentarios del municipio de Facatativá [10] se formula una estrategia de adaptación al cambio climático para los sistemas productivos agroalimentarios del municipio de Facatativá, Cundinamarca, Colombia. Esto incluye: Análisis del comportamiento histórico de variables meteorológicas en Facatativá; Determinación de los impactos del cambio climático en los sistemas productivos agroalimentarios locales; Propuesta de mecanismos de adaptación frente al cambio climático para estos sistemas. Se analizan datos de precipitación, temperatura, humedad relativa, velocidad del viento y brillo solar de estaciones meteorológicas del IDEAM y la CAR para un periodo de 30 años (1989-2018); se realizan mapas de distribución espacial y temporal de temperatura y precipitación usando sistemas de información geográfica; se determinan tendencias meteorológicas y se proyectan escenarios futuros; se aplica una encuesta a 61 agricultores locales para evaluar su percepción sobre el cambio climático y sus impactos; se revisa literatura científica sobre estrategias de adaptación implementadas a nivel mundial; se proponen mecanismos de adaptación ajustados a las características específicas del territorio. El estudio se centra en el municipio de Facatativá, Cundinamarca, Colombia. Se analizan datos de estaciones meteorológicas en un radio de 40 km alrededor del municipio. Se identificaron tendencias de

aumento en temperatura media ($0.02^{\circ}\text{C}/\text{año}$ en promedio) y precipitación ($4.9 \text{ mm}/\text{año}$ en promedio) en el municipio; el 60.7% de los agricultores encuestados reportaron pérdidas en sus cultivos en los últimos años, atribuyéndolas principalmente a factores meteorológicos; se propusieron cuatro estrategias de adaptación: zanjas de infiltración, mulching, cosecha de agua lluvia, y sistemas de policultivo-agroforestería. Concluyendo, las principales variables analizadas son precipitación, temperatura, humedad relativa, velocidad del viento y brillo solar; se realizan proyecciones de temperatura y precipitación para el año 2050 basadas en las tendencias observadas; no se utiliza inteligencia artificial en este estudio; se utilizan datos de estaciones meteorológicas convencionales del IDEAM y la CAR; se utilizan sistemas de información geográfica (ArcGIS) para el análisis espacial y temporal de datos meteorológicos, y software especializado (Cropwat) para cálculos de evapotranspiración.

En conclusión, la predicción de variables meteorológicas representa un impacto en el consumo energético de las ciudades y ha sido abordada desde diversas perspectivas tecnológicas y metodológicas. Los estudios revisados muestran un creciente interés en la aplicación de redes neuronales artificiales (RNA) y otras técnicas de inteligencia artificial (IA) para mejorar la precisión en la predicción de variables meteorológicas locales. Los modelos recurrentes, como LSTM, destacan por su capacidad para capturar dependencias a largo plazo, mientras que modelos como ARIMA o redes Perceptrón Multicapa han mostrado resultados aceptables, aunque limitados en su capacidad para manejar la complejidad no lineal de los fenómenos meteorológicos urbanos. La investigación también resalta la creciente importancia de integrar dispositivos de bajo costo, como estaciones meteorológicas equipadas con IoT, en la recolección de datos. Estos sistemas permiten democratizar el acceso a información meteorológica detallada, esencial para mejorar la toma de decisiones en urbanismo y gestión ambiental. Además, se concluye que el uso de inteligencia artificial en la predicción meteorológica es una tendencia con gran potencial para mitigar los efectos negativos del cambio climático en las ciudades. Sin embargo, aún se requiere mayor investigación para optimizar la integración de tecnologías sostenibles y mejorar la eficiencia de los modelos predictivos, considerando las condiciones específicas de cada entorno urbano. Esta línea de investigación es clave para avanzar hacia la implementación de soluciones innovadoras y sostenibles que beneficien tanto a las ciudades como a sus habitantes.

En investigaciones previas, como la desarrollada por Kuffó Zambrano (2023), se utilizaron redes

neuronales recurrentes (RNN) y Long Short-Term Memory (LSTM) para realizar predicciones de variables como temperatura, humedad y velocidad del viento, obteniendo precisiones que oscilan entre el 70% y el 98%, dependiendo del tipo de variable. Esta aproximación demuestra ser más eficiente que los métodos tradicionales, como los modelos estadísticos ARIMA, que suelen lograr precisiones más limitadas, entre el 76% y el 80%. Programas como Python y MATLAB han sido ampliamente utilizados en estos estudios para el desarrollo y entrenamiento de los modelos predictivos. En el presente proyecto, se prevé utilizar Python debido a su flexibilidad y el amplio soporte de bibliotecas especializadas en aprendizaje automático, como TensorFlow y Keras. Estas herramientas permitirán implementar redes neuronales LSTM para capturar patrones temporales y no lineales en los datos meteorológicos. Además, se aplicarán técnicas de procesamiento y normalización de datos para garantizar la calidad del conjunto de entrenamiento, lo que es fundamental para mejorar la precisión del modelo.

Un estudio realizado por Senwen Yang y colaboradores (2024) aplicó un modelo de IA para predecir el microclima urbano en Montreal, utilizando cinco estaciones meteorológicas distribuidas por la ciudad. Su enfoque incluyó la generación de un Año Meteorológico Típico (TMY) local, lo que les permitió simular el consumo energético de edificios bajo diferentes condiciones meteorológicas. Aunque el enfoque de este estudio está orientado al consumo energético, ofrece una comparación relevante para nuestro proyecto, ya que demuestra cómo las redes neuronales pueden integrar datos de estaciones urbanas y producir predicciones meteorológicas específicas para zonas con microclimas complejos. En el ámbito de las estaciones meteorológicas de bajo costo, proyectos como el de Thomas Alexandre Da Silva (2020) implementaron estaciones autónomas con IoT y algoritmos de aprendizaje profundo, logrando predicciones a corto plazo con una precisión media superior al 90%. Este estudio sugiere que la integración de dispositivos de bajo costo y IA puede democratizar el acceso a predicciones meteorológicas precisas en zonas de difícil acceso o con pocos datos históricos. En nuestro caso, también se proyecta el uso de estaciones meteorológicas accesibles para mejorar la recolección de datos a nivel local y alimentar el modelo predictivo.

El enfoque propuesto en este proyecto se diferencia de estudios previos en el hecho de que está específicamente adaptado a las condiciones de Facatativá, una región con un meso clima particular. Mientras que estudios como los de Barros et al. (2018) y Yang et al. (2024) se centraron en áreas

urbanas densas o en regiones montañosas, nuestro proyecto busca captar las variaciones micro climáticas en una zona semirural, donde las dinámicas meteorológicas pueden ser influenciadas tanto por la geografía como por los cambios en la cobertura vegetal. Estas diferencias topográficas y de uso del suelo pueden presentar desafíos adicionales para el modelo, lo que resalta la importancia de un enfoque personalizado para la recolección y procesamiento de datos. Por lo tanto, se espera que los resultados finales de este estudio no solo superen las predicciones de los modelos estadísticos tradicionales, sino que también ofrezcan una mayor precisión y adaptabilidad a las condiciones locales de Facatativá. Además, la implementación de un modelo de IA basado en RNN y LSTM permitirá realizar predicciones a mediano y largo plazo, proporcionando una herramienta valiosa para sectores clave como la agricultura y la planificación urbana.

1.2. Línea de investigación

El presente proyecto se enmarca en la línea de investigación "Aprendizaje, conocimiento, tecnologías, comunicación y digitalización" del grupo GISTFA, la cual se enfoca en el desarrollo de soluciones tecnológicas innovadoras que integren sistemas inteligentes, gestión del conocimiento y procesos de digitalización para resolver problemáticas específicas de la región.

El desarrollo de una estación meteorológica propia de bajo costo, validada mediante comparación con la estación Davis Vantage Pro2 (Figura 1) instalada en la unidad agroambiental El Vergel, articula el proyecto con cada componente de la línea de investigación:

Figura 1

DAVIS VANTAGE PRO



- **Aprendizaje:** La estación meteorológica desarrollada incorpora algoritmos de inteligencia artificial y técnicas de aprendizaje automático que procesan continuamente los datos recolectados. El sistema aprende patrones meteorológicos locales y mejora sus predicciones mediante redes neuronales artificiales, adaptándose específicamente a las condiciones microclimáticas de Facatativá.
- **Conocimiento:** El diseño y construcción de la estación propia genera nuevo conocimiento técnico sobre desarrollo de instrumentos meteorológicos accesibles. La investigación produce conocimiento científico sobre predicción meteorológica localizada, contribuyendo al entendimiento de las dinámicas climáticas regionales y estableciendo metodologías replicables para otras regiones con características similares.
- **Tecnologías:** El proyecto desarrolla tecnología innovadora al crear una estación meteorológica de bajo costo que integra sensores especializados, microcontroladores, sistemas de comunicación inalámbrica y procesamiento de datos en tiempo real. Esta innovación tecnológica representa una alternativa accesible que democratiza el acceso a instrumentación meteorológica de calidad.
- **Comunicación:** La estación desarrollada incorpora protocolos de comunicación para transmisión automática de datos meteorológicos, visualización de información, y sistema de alerta para el desbordamiento del tanque en LESTOMA, que facilitan la comunicación efectiva de información crítica hacia agricultores, investigadores y gestores ambientales.
- **Digitalización:** El prototipo digitaliza completamente el proceso de monitoreo meteorológico local, automatizando la recolección, almacenamiento, procesamiento y análisis de variables meteorológicas mediante un sistema computacional inteligente.

Como parte fundamental de este proyecto, se diseñó y construyó una estación meteorológica de bajo costo desarrollada con el propósito de ofrecer una alternativa accesible y eficiente para la recolección de datos meteorológicos locales. La confiabilidad del sistema fue validada mediante pruebas de calibración comparativa con la estación Davis Vantage Pro2 instalada en la unidad agroambiental El Vergel, demostrando un nivel de concordancia aceptable

que confirma la precisión de los datos recolectados por el prototipo desarrollado.

1.3 Planteamiento del Problema y Pregunta de Investigación

La predicción meteorológica es fundamental para la planificación en sectores como la agricultura, los recursos naturales y la investigación académica. En Facatativá, un municipio cuya economía depende en gran medida de la producción agropecuaria, el tiempo está influenciado por factores meso climáticos específicos, lo que hace que las condiciones meteorológicas locales varíen de forma significativa en función de la altitud, la topografía y otros aspectos geográficos. Sin embargo, los modelos meteorológicos convencionales no capturan adecuadamente estas variaciones regionales para zonas específicas, lo que genera predicciones poco fiables. Esto afecta directamente los procesos productivos, tanto en la agricultura como en la investigación, ya que decisiones críticas como la siembra, cosecha y manejo de recursos naturales dependen de estimaciones precisas y focalizadas sobre las condiciones meteorológicas. La magnitud del problema se evidencia en las consecuencias que tiene para la productividad agrícola y la gestión ambiental, donde la falta de precisión en las predicciones puede derivar en pérdidas económicas y un uso ineficiente de los recursos. Igualmente, en el ámbito académico y de investigación, los datos meteorológicos no han sido plenamente aprovechados, limitando el desarrollo de estudios que puedan generar conocimiento aplicado para enfrentar estos desafíos.

En este contexto, la Universidad de Cundinamarca, extensión Facatativá, cuenta con una estación meteorológica ubicada en el laboratorio de acuaponía LESTOMA, la cual genera información climatológica relevante. No obstante, esta infraestructura no ha sido utilizada de forma integral para el desarrollo de soluciones tecnológicas enfocadas en la predicción meteorológica localizada. Por ello, este proyecto propone la construcción desde cero de una estación meteorológica de bajo costo, fabricada mediante tecnologías de impresión 3D, que permite recopilar datos confiables de forma continua para ser usados en sistemas inteligentes de predicción meteorológica. Esta solución busca aprovechar las ventajas de la inteligencia artificial con impacto positivo en la toma de decisiones, la planificación agrícola, la gestión ambiental y la investigación científica. Además, esta iniciativa serviría como un modelo replicable, accesible y sostenible para otras instituciones o regiones con características climáticas similares.

¿Cómo construir un prototipo de sistema computacional inteligente que permita predecir las

condiciones meteorológicas locales en la Universidad de Cundinamarca, Extensión Facatativá, con el fin de mejorar la toma de decisiones en actividades académicas, agrícolas o investigativas?

1.4 Objetivo General y Objetivos Específicos

Objetivo General

Construir un prototipo de sistema computacional inteligente para predicción meteorológica en la Universidad de Cundinamarca extensión Facatativá

Objetivos Específicos:

- Realizar una investigación exhaustiva del estado del arte, levantar requerimientos y afinarlos, recopilar y analizar datos meteorológicos de Facatativá.
- Construir las partes físicas e implementar el hardware electrónico de la estación meteorológica, por consiguiente, diseñar y entrenar el sistema inteligente.
- Evaluar la precisión del modelo de Inteligencia Artificial y la estación meteorológica.
- Presentar los resultados en el artículo investigativo cuantitativo con los análisis de los resultados, validación y pruebas.

1.5 Alcance e Impacto del Proyecto

El proyecto de predicción meteorológica utilizando inteligencia artificial tendrá un impacto significativo en diversas áreas relacionadas con los objetivos académicos, de investigación y ambientales, alineándose con la misión institucional de la Universidad de Cundinamarca y las políticas estratégicas en ciencia y tecnología. En particular, contribuirá a la mejora de los procesos de toma de decisiones en la planificación de actividades de la comunidad Udecina y en la región de Facatativá, al proporcionar predicciones meteorológicas esenciales y localizadas. Esto permitirá optimizar la gestión de recursos naturales y la productividad agrícola, contribuyendo así al desarrollo sostenible. Desde la perspectiva del MEDIT (Modelo Educativo Digital y Tecnológico), este proyecto promueve la integración de tecnologías avanzadas como la inteligencia artificial en la educación y la investigación. La creación de un modelo predictivo meteorológico específico para el entorno de la universidad fomenta el desarrollo de competencias tecnológicas y científicas

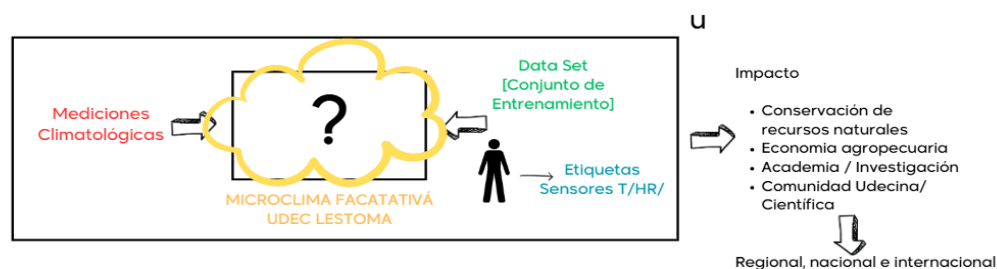
entre estudiantes e investigadores, fortaleciendo el uso de datos en la toma de decisiones y la creación de nuevas soluciones tecnológicas.

Además, este proyecto se alinea con los principios de la Política de Ciencia y Tecnología de la Universidad, que busca impulsar la innovación a través de la investigación aplicada y la transferencia tecnológica. Al desarrollar un sistema de predicción meteorológica con aplicaciones directas en la agricultura y la gestión de recursos, se promueve la generación de conocimiento útil para la comunidad local y regional, impactando favorablemente en la planificación agrícola y la producción sostenible. En cuanto al PEU (Proyecto Educativo Universitario), el proyecto contribuye a la formación integral de los estudiantes al involucrarse en actividades de investigación aplicada que abordan problemas reales del entorno. Además, este enfoque promueve el compromiso con la sostenibilidad ambiental, en consonancia con los Objetivos de Desarrollo Sostenible (ODS), particularmente en áreas como la protección de ecosistemas, el uso eficiente de los recursos hídricos y la mitigación de los efectos del cambio climático.

Finalmente, este proyecto impactará estratégicamente en la región de Facatativá mediante la mejora de procesos tecnológicos y de toma de decisiones basados en datos meteorológicos esenciales y oportunos. Esto permitirá mejorar la producción agrícola, reducir el desperdicio de recursos naturales y fomentar el desarrollo sostenible (Figura 2), lo que contribuirá al cumplimiento de los planes estratégicos municipales y regionales, promoviendo el crecimiento socioeconómico, la productividad y la resiliencia ambiental.

Figura 2

Impacto del proyecto



1.6 Metodología

El presente estudio sigue un enfoque cuantitativo basado en la recopilación de datos meteorológicos, desarrollo de un software local básico para la interpretación y visualización de

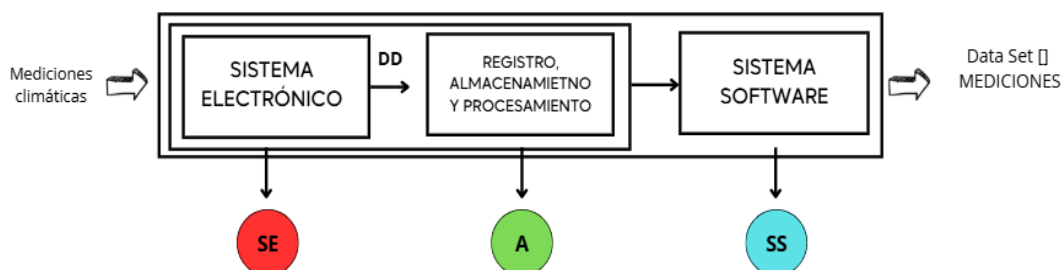
datos junto al diseño y construcción de una estación meteorológica de bajo costo diseñada e instalada en la extensión Facatativá, incluyendo variables como temperatura, humedad relativa, dirección del viento, velocidad del viento, intensidad luminosa entre otras. También se realizará el análisis comparativo, se tendrán cuatro fases de desarrollo para la parte hardware e IA, que inician con la fase de investigación y recolección de datos, en la cual se enfocará el desarrollo para realizar una investigación exhaustiva del estado del arte, levantar requerimientos y afinarlos, recopilar y analizar datos meteorológicos de Facatativá, considerando actividades desde la revisión de literatura y estudios previos sobre predicción meteorológica, sistemas inteligentes; identificación y levantamiento de los requerimientos técnicos y funcionales del proyecto; recolección de datos históricos y actuales de las estaciones meteorológicas de Facatativá; preprocesamiento y análisis de los datos para adaptarlos a los modelos de inteligencia artificial (IA). Seguidamente, se definirá el diseño e implementación del sistema, se enfocará la propuesta en el objetivo dos que responde a diseñar y construir las partes físicas, el hardware electrónico y el sistema inteligente, para la cual se inicia por la construcción y ensamblaje de los componentes físicos de la estación meteorológica; la Implementación y calibración de los sensores (sensor digital de temperatura de humedad, anemómetro, pluviómetro, etc.); desarrollo del modelo computacional para la predicción meteorológica; entrenamiento del modelo de IA con los datos recopilados. En la tercera fase de validación y evaluación, se enfocará en el objetivo tres que es evaluar la precisión del modelo de IA y la estación meteorológica, mediante la ejecución de pruebas de validación del modelo de IA y el análisis de la precisión de las predicciones meteorológicas, junto con la comparación de los resultados obtenidos y registrados por la estación meteorológica en la UDEC con los datos históricos recolectados por el IDEAM y plataformas que ofrezcan variables meteorológicas; se pretende también hacer ajustes y mejora en los parámetros del modelo de IA para aumentar su rendimiento. Finalmente, en la fase cuatro de presentación y análisis, se realizará un estudio detallado de los resultados obtenidos del modelo del sistema inteligente, de la sustentabilidad y operatividad de la estación meteorológica, además se validaron los resultados frente a estudios externos y conjuntos de datos similares, para culminar con la elaboración y presentación de los resultados, hallazgos y análisis.

Sistema Computacional Inteligente

A lo largo de las fases del proyecto, se integrarán soluciones tecnológicas tanto para la adquisición como para el análisis de datos meteorológicos en Facatativá. En la Figura 2 se presentan de manera detallada los elementos de cada componente:

Figura 3

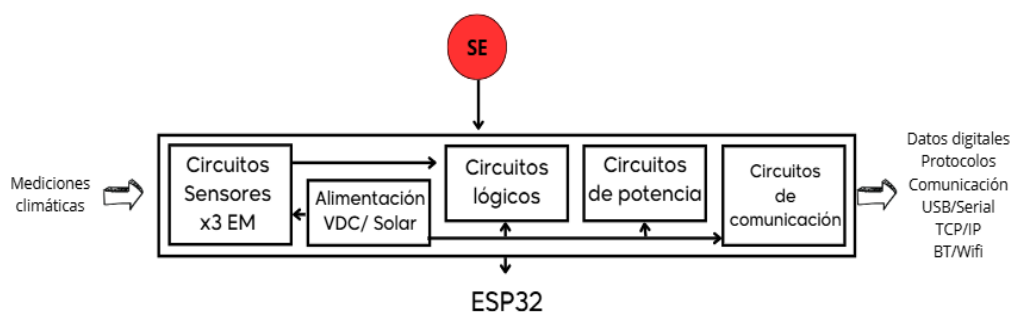
Sistema propuesto



Se parte de considerar que las mediciones meteorológicas serán las esenciales de acuerdo con la población beneficiada y contemplarán velocidad del viento, dirección del viento, temperatura ambiente, humedad relativa, intensidad luminosa entre otras. Dichas mediciones serán captadas por el sistema electrónico (Figura 4), el cual registrará, procesará, almacenará y codificará los datos para ser insumo de predicción del sistema inteligente (Figura 5); también será el encargado de gestionar la energía eléctrica y todos los procesos de comunicación en la estación meteorológica. Los datos procesados también son enviados al software local básico (Figura 6) para ser almacenados como datos históricos, visualizados, analizados y presentados en informes filtrados por día, semana y mes en formato CSV, PDF.

Figura 4

Sistema Hardware



Sistema Computacional Inteligente

Figura 5

Sistema de Almacenamiento

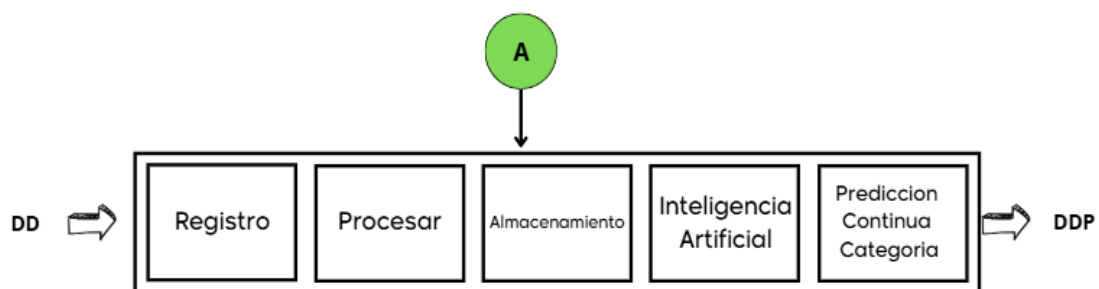


Figura 6

Sistema Software





Figura 7

Ubicación de estación meteorológica



La metodología de análisis de datos se centrará en la estación meteorológica (EM) ubicada en el laboratorio LESTOMA, situado frente al parqueadero y al lado del bloque A, dentro de la Universidad de Cundinamarca, Extensión Facatativá (Figura 7), se llevará a cabo mediante un enfoque estadístico y comparativo. Este proceso permitirá interpretar y validar los datos generados, así como evaluar la precisión del modelo de predicción meteorológica basado en inteligencia artificial. Los siguientes pasos guiarán este análisis, se analizará de forma estadística, comparativa y por último se validará el modelo predictivo. En primer lugar, los datos obtenidos por la estación como temperatura, humedad, velocidad del viento, entre otros, serán sometidos a un análisis comparativo y estadístico para calibración. Se calcularán medidas estadísticas con el fin de identificar patrones generales y comportamientos meteorológicos locales. Aunque el análisis se enfocará en una única estación, se realizará una comparación temporal entre diferentes periodos de observación para evaluar la consistencia de los datos y detectar posibles anomalías o tendencias. Finalmente, con base en estos análisis, se procederá a la validación del modelo de predicción meteorológica, contrastando sus resultados con los datos reales obtenidos por la estación. Esta validación será fundamental para afinar el modelo y garantizar su aplicabilidad en contextos reales dentro del campus universitario.

1.7. MARCOS DE REFERENCIA

1.7.1. Marco Teórico

Este capítulo presenta los fundamentos conceptuales y técnicos esenciales que sustentan el desarrollo del sistema inteligente de predicción meteorológica, propuesto en este proyecto de investigación. Se abordan los principios teóricos asociados a los modelos mixtos (hardware y software), el uso de sensores meteorológicos, las redes IoT, los sistemas de inteligencia artificial, la climatología y sus aplicaciones en diversos sectores estratégicos.

El creciente impacto del cambio climático y la variabilidad atmosférica a nivel local han generado la necesidad de implementar soluciones tecnológicas orientadas a la predicción de condiciones meteorológicas específicas. En este contexto, predecir el comportamiento del tiempo meteorológico adquiere especial relevancia en sectores como la agricultura, la gestión ambiental, las energías renovables y el desarrollo de territorios inteligentes.

El enfoque desarrollado en este proyecto se basa en un modelo mixto que integra infraestructura física (sensores meteorológicos y hardware especializado), conectividad IoT (Internet de las Cosas), procesamiento de datos en tiempo real y algoritmos de inteligencia artificial. Este sistema permite monitorear, analizar y predecir variables meteorológicas claves, contribuyendo a la toma de decisiones oportunas y a la gestión sostenible de los recursos.

1.7.1.1. Contextualización del Proyecto. El presente proyecto de investigación propone el desarrollo de un sistema inteligente de predicción meteorológica, orientado a generar soluciones innovadoras en el ámbito de la agroclimatología, la gestión ambiental y las energías renovables. La creciente necesidad de comprender las dinámicas meteorológicas locales, sumada al avance de las tecnologías emergentes, permite diseñar herramientas que mejoren la adaptación y mitigación frente a fenómenos ambientales adversos.

1.7.1.1.1. Importancia de Predecir el Tiempo Meteorológico. La predicción del tiempo meteorológico resulta fundamental para optimizar procesos agrícolas, planificar actividades productivas, minimizar riesgos y contribuir a la sostenibilidad de los ecosistemas. Un sistema capaz de anticipar las condiciones meteorológicas permite una mejor toma de decisiones, impactando positivamente en diversos sectores estratégicos. En primer lugar, destaca la agricultura de precisión, una técnica moderna que utiliza tecnologías como sensores, GPS, drones e inteligencia artificial para gestionar de manera específica y eficiente los cultivos, optimizando el uso de insumos y aumentando la productividad. Asimismo, la gestión de recursos hídricos se beneficia significativamente, ya que una predicción adecuada facilita la administración sostenible del agua en actividades agrícolas, industriales y urbanas, garantizando su conservación y disponibilidad. Otro sector favorecido es el monitoreo ambiental, proceso que implica observar, medir y analizar parámetros como el aire, el agua, el suelo y el tiempo, con el fin de evaluar su estado, identificar problemas y aplicar acciones correctivas que favorezcan el medio ambiente. Además, la planificación urbana también se ve fortalecida mediante el diseño estratégico de ciudades y comunidades, considerando variables sociales, económicas, ambientales y meteorológicas para mejorar la calidad de vida y promover el desarrollo sostenible. Finalmente, la predicción meteorológica impulsa el uso de

energías limpias, como la solar, eólica, hidráulica y geotérmica, que contribuyen a reducir la huella ambiental y combatir el cambio climático.

1.7.1.1.2. Enfoque del modelo mixto (Hardware + Software + Inteligencia Artificial): El sistema propuesto para la predicción meteorológica se basa en un modelo mixto que integra de manera sinérgica componentes de hardware electrónico, software especializado, inteligencia artificial (IA) y tecnologías de Internet de las Cosas (IoT). Esta arquitectura híbrida permite recopilar, procesar, analizar y visualizar datos meteorológicos en tiempo real, con el fin de generar predicciones meteorológicas de alta precisión adaptadas a condiciones locales.

En contexto de lo anterior, cuando se habla de hardware es el componente físico del sistema está conformado por una estación meteorológica que mide variables clave como temperatura, humedad relativa, velocidad y dirección del viento, radiación solar y precipitación. Estos sensores están conectados a dispositivos de adquisición y procesamiento de datos, como microcontroladores o unidades embebidas en el caso de la estación meteorológica se usa la ESP32, que permiten la recolección local de datos y su preprocesamiento antes del análisis, además de asociar la parte inteligente con lógica difusa (fuzzy logic), esta aporta flexibilidad en la toma de decisiones bajo incertidumbre, al manejar información imprecisa o ambigua, característica inherente de los fenómenos meteorológicos; en la aplicación de escritorio el sistema incorpora software de análisis desarrollado a la medida, capaz de interpretar los datos recogidos por los sensores y ejecutar algoritmos para la identificación de patrones y tendencias meteorológicas. Este software se encarga de la limpieza de datos, su normalización, visualización y el soporte para los modelos predictivos. Está implementado en el lenguaje Python, mientras que en otros casos también usan R, plataformas de análisis en la nube, entre otras; En otro aspecto sobre la inteligencia artificial el corazón predictivo del sistema está constituido por algoritmos de aprendizaje automático (machine learning), diseñados para generar estimaciones meteorológicas basadas en los datos históricos y los tomados en el tiempo actual a intervalos de 5 minutos. El machine learning permite entrenar modelos a partir de grandes volúmenes de datos, identificando correlaciones complejas entre variables meteorológicas. Por otro lado el internet de las cosas (IoT) en cuanto a la conectividad del sistema se logra mediante redes IoT, las cuales permiten el envío

automático de datos hacia servidores remotos o plataformas en la nube, donde estos pueden ser almacenados, procesados y visualizados por los usuarios a través de interfaces gráficas. Esta infraestructura facilita la supervisión remota, la escalabilidad del sistema y su integración con otras aplicaciones o bases de datos.

1.7.1.1.3. Sistemas de Predicción Meteorológica. Los conceptos básicos son: Iniciamos con la meteorología es la ciencia que estudia los fenómenos atmosféricos, sus procesos físicos, químicos y dinámicos, así como las interacciones de estos procesos con la superficie terrestre. Esta disciplina analiza y mide las condiciones del tiempo atmosférico, tales como temperatura, humedad, viento, presión, precipitación y radiación solar, con el fin de entender su comportamiento y predecir su evolución en el corto, mediano y largo plazo.

Luego con *el tiempo meteorológico* se refiere a las condiciones atmosféricas momentáneas que se presentan en un lugar y en un momento determinado. Es un estado variable y dinámico que incluye elementos como temperatura del aire, humedad relativa, precipitación (lluvia, granizo, nieve), velocidad y dirección del viento, radiación solar, presión atmosférica. El tiempo meteorológico puede cambiar de manera rápida, a diferencia del clima, que es más estable y se define a largo plazo.

Es la predicción científica del estado futuro del tiempo en un lugar específico, durante un intervalo determinado (horas, días, semanas). El pronóstico se basa en la observación de datos meteorológicos actuales, modelos matemáticos y físicos, algoritmos de predicción, inteligencia artificial en sistemas avanzados. Tiene diferentes tipos de pronóstico donde está el inmediato que es el de minutos a horas; el de corto plazo que va de 1 a 3 días; el de mediano plazo que es de 3 a 7 días; y por último el de largo plazo debe tener más de una semana.

Otro sería el término *microclima* hace referencia a las condiciones atmosféricas particulares que se presentan en un área geográfica de pequeña escala, diferenciándose significativamente del clima general o *macroclima* que caracteriza a una región más extensa. El microclima está determinado por un conjunto de factores ambientales y geográficos que afectan directamente las condiciones meteorológicas locales, generando características únicas

y específicas dentro de un espacio reducido, que pueden variar desde unos pocos metros hasta varios kilómetros cuadrados.

El microclima puede presentarse en diversos entornos, tales como cultivos agrícolas, parques urbanos, bosques, invernaderos, áreas cercanas a cuerpos de agua, zonas montañosas o incluso en patios y jardines.

Las características principales del microclima sería la variabilidad espacial y temporal donde las condiciones de un microclima pueden cambiar de un sitio a otro dentro de la misma zona, dependiendo de elementos como la altitud, la orientación, la presencia de barreras físicas o la cobertura vegetal. Además, el microclima puede experimentar fluctuaciones diarias o estacionales; otra característica sería la influencia de factores locales debido a que el microclima está directamente condicionado por elementos propios del lugar, como vegetación (cantidad y tipo de plantas), presencia de cuerpos de agua (ríos, lagunas, fuentes), materiales de construcción (concreto, asfalto, ladrillo), sombra o exposición solar, corrientes de viento locales, actividad humana o industrial y topografía del terreno; la última característica sería las condiciones meteorológicas particulares teniendo en cuenta que en un microclima se pueden presentar características específicas y distintas al clima regional, como temperaturas más elevadas o más frescas, mayor o menor humedad, diferente intensidad de radiación solar, cambios en la velocidad o dirección del viento, mayor o menor probabilidad de precipitaciones.

1.7.1.1.4. Aplicaciones de la Predicción Meteorológica. El conocimiento y la predicción de las condiciones meteorológicas tienen aplicación directa en la agricultura inteligente y de precisión que es la integración de tecnologías de monitoreo, automatización y análisis de datos en las labores agrícolas para optimizar la producción, reducir costos y minimizar impactos ambientales; la gestión y monitoreo ambiental que es el conjunto de acciones orientadas a supervisar y regular el uso de los recursos naturales, controlar contaminantes y asegurar el equilibrio ecológico de los ecosistemas; el desarrollo de proyectos sostenibles que son iniciativas o emprendimientos diseñados bajo principios de sostenibilidad, buscando un equilibrio entre desarrollo económico, cuidado ambiental y responsabilidad social; la implementación de ciudades inteligentes conocidas como Smart Cities donde el uso de

tecnología, sensores, redes IoT y análisis de datos se usan para mejorar la calidad de vida urbana, optimizar servicios públicos y reducir el impacto ambiental en las ciudades; sistemas de energías renovables que son infraestructuras tecnológicas que permiten generar energía a partir de recursos naturales renovables e inagotables, como el sol, el viento, el agua o la biomasa.

1.7.1.1.5. Factores que afectan el tiempo meteorológico. Los principales factores meteorológicos que intervienen en la conformación de variables meteorológicos son la temperatura ambiente que es la medida del grado de calor o frío presente en un área específica. Afecta el desarrollo de plantas, el confort térmico y los procesos industriales o agrícolas. Humedad relativa del aire: Es el porcentaje que indica la cantidad de vapor de agua presente en el aire con respecto a la cantidad máxima que podría contener a una temperatura determinada; la velocidad y dirección del viento que son las características del flujo de aire en un área determinada. Influyen en la ventilación natural, dispersión de contaminantes y polinización; la radiación solar que es la energía que proviene del sol y llega a la superficie terrestre. Es esencial para procesos naturales como la fotosíntesis y generación de energía solar; la precipitación (lluvia, granizo, nieve) que es la caída de agua desde la atmósfera en diferentes formas. Es vital para los ecosistemas, agricultura y recarga de fuentes hídricas; y la presión atmosférica que es la fuerza que ejerce el aire sobre la superficie terrestre. Su variación es indicativa de cambios climáticos y fenómenos meteorológicos.

1.7.1.1.6. Glosario de Términos

Tabla 1.

Glosario

Término	Definición
Tiempo Meteorológico	Se refiere a las condiciones atmosféricas momentáneas que se presentan en un lugar y en un momento determinado

IoT (Internet of Things)	Internet de las cosas. Tecnología que permite la conexión e interacción de dispositivos físicos a través de Internet para compartir datos en tiempo real.
Sensores Meteorológicos	Dispositivos encargados de medir variables ambientales como temperatura, humedad, presión, velocidad del viento, entre otros.
Inteligencia Artificial (IA)	Rama de la informática que diseña sistemas capaces de simular procesos de inteligencia humana como aprender, razonar o predecir.
Hardware	Conjunto de elementos físicos o materiales de un sistema informático, como sensores, microcontroladores, placas electrónicas, etc.
Software	Conjunto de programas, aplicaciones y sistemas que permiten operar o controlar un hardware.
Sistema Computacional	Integración de hardware y software dentro de un mismo sistema para cumplir funciones específicas de recolección, análisis y predicción de datos.
Fuzzy Logic (Lógica Difusa)	Técnica de inteligencia artificial que permite trabajar con información imprecisa o incierta, imitando el razonamiento humano.

Ruido Gaussiano	Variación aleatoria que afecta las señales de sensores o datos, representada matemáticamente mediante una distribución normal o gaussiana.
SINA	Sistema Nacional Ambiental de Colombia, encargado de coordinar las acciones de protección ambiental en el país.
IDEAM	Instituto de Hidrología, Meteorología y Estudios Ambientales de Colombia. Es la entidad responsable de monitorear y gestionar los datos climatológicos y ambientales en el país.
Agrometeorología	Ciencia que estudia las relaciones entre el clima y la agricultura, aplicando datos meteorológicos a los procesos de producción agrícola.
Energías Renovables	Fuentes de energía que se obtienen de recursos naturales inagotables o de rápida regeneración, como el sol, el viento, o el agua.
Machine Learning	Subcampo de la inteligencia artificial que permite a las máquinas aprender automáticamente a partir de datos sin ser programadas explícitamente.
Predicción Meteorológicas	Proceso de estimar las condiciones meteorológicas futuras a partir de modelos matemáticos, datos históricos y tecnología de análisis.

Big Data	Análisis y gestión de grandes volúmenes de datos complejos provenientes de múltiples fuentes.
Telemetría	Técnica que permite medir y transmitir datos a distancia mediante sistemas electrónicos o de comunicación inalámbrica.
Red de Sensores	Conjunto de sensores interconectados que permiten la recopilación, transmisión y análisis de datos en tiempo real.
Climatología	Ciencia que estudia el clima, sus variaciones y su comportamiento a lo largo del tiempo.
Monitoreo Ambiental	Observación y registro sistemático de las condiciones del medio ambiente con el objetivo de evaluar su estado y evolución.
GISTFA	Grupo de Investigación de sistemas y tecnología de Facatativá, asociado a este proyecto
LESTOMA	Laboratorio experimental de sistemas tecnológicos orientados a modelos acuapónicos
MEDIT	Modelo Educativo Digital y Tecnológico
ODS	Objetivos de Desarrollo Sostenible

Estación Meteorológica	Dispositivo que recopila datos meteorológicos, como temperatura, humedad y presión atmosférica.
Sistema Inteligente	Es una tecnología que usa inteligencia artificial para aprender y tomar decisiones.
Microclima	Clima característico de un área pequeña o de un entorno geográfico específico.
Mesoclima	Clima que cubre un área más amplia que el microclima, pero más pequeña que el clima regional.
Facatativá	Municipio en Colombia, cuya economía depende principalmente de la agricultura.
Tiempo real	El concepto de tiempo real se refiere a un sistema o proceso informático que opera de manera inmediata, es decir, en tiempo real. Los datos para este sistema se obtendrán en intervalos de 5 minutos, 12 conjuntos por hora, es decir, $12 * 24$ datos por día.

1.7.1.2. Sistema Computacional (Hardware + Software + Inteligencia Artificial): En este capítulo se aborda el diseño conceptual y funcional del modelo mixto propuesto en el presente proyecto. Este modelo integra tecnologías de hardware, software e inteligencia artificial (IA), orientadas a la predicción meteorológica en entornos específicos. La fusión de estos elementos permite desarrollar un sistema inteligente, capaz de captar, procesar, analizar y predecir las condiciones meteorológicas locales en tiempo real.

1.7.1.2.1 Definición de Modelo Mixto: Un modelo mixto se refiere a la integración de distintas metodologías, tecnologías y enfoques (cuantitativos y cualitativos) en un mismo sistema con el fin de optimizar procesos y resultados.

En el contexto de sistemas de predicción meteorológica, un modelo mixto combina tecnología de hardware (sensores y dispositivos físicos) que hace referencia al conjunto de dispositivos físicos y electrónicos encargados de capturar, medir y transmitir información del entorno físico hacia sistemas computacionales. En un sistema de predicción meteorológica, estos elementos permiten la recolección de datos ambientales esenciales en tiempo real, necesarios para el análisis y toma de decisiones; la tecnología de software (algoritmos de análisis y gestión de datos) donde incluye el diseño y programación de algoritmos capaces de procesar los datos capturados por el hardware. El software se encarga de filtrar, almacenar, analizar y transformar los datos en información útil para el usuario o el sistema inteligente. Su estructura se basa en modelos computacionales y matemáticos que permiten visualizar, predecir o interpretar los fenómenos ambientales; y la inteligencia Artificial (procesos de aprendizaje y predicción automatizada) que permite dotar a los sistemas de predicción con capacidades de aprendizaje automático, análisis inteligente de patrones y toma de decisiones autónomas. Su función principal en estos entornos es optimizar la precisión de los pronósticos mediante el autoajuste de los modelos en función de los datos históricos y en tiempo real.

1.7.1.2.2 Integración de Hardware y Software. El modelo mixto propuesto se basa en la interacción constante entre hardware y software. A continuación, se detallan los componentes principales del sistema computacional como el hardware donde se usan microcontroladores, sensores, entre otros, que son dispositivos electrónicos diseñados para captar y medir parámetros meteorológicos esenciales como el de temperatura que son sensores térmicos (LM35, DHT22, etc.); humedad relativa que se miden con un sensor digital de temperatura y humedad; velocidad y dirección del viento que por lo general se usan anemómetros, aunque para la veleta en estaciones meteorológicas de bajo costo se usan potenciómetro infinito o reed switch; el de radiación solar donde se usan piranómetros, pero para estaciones meteorológicas de bajo costo también se puede usar el S12SD o TSL2561; la precipitación se mide con pluviómetros automáticos.

En este contexto "para continuar se usan módulos de adquisición y transmisión de datos que son sistemas que permiten recolectar la información generada por los sensores y transmitirla, generalmente mediante redes inalámbricas (WiFi, LoRa, ZigBee, NB-IoT), hacia centros de procesamiento o almacenamiento en la nube; también se usan microcontroladores y dispositivos IoT donde los microcontroladores (MCU) son el núcleo de procesamiento local en los sistemas IoT (Internet of Things). Son pequeños computadores programables que controlan la lectura de sensores, procesan datos básicos y permiten la comunicación con otros sistemas.

1.7.1.2.2.1. Software Especializado. En relación con los algoritmos de control y procesamiento son rutinas lógicas programadas que permiten controlar el flujo de datos, gestionar la operación de sensores, realizar cálculos matemáticos, aplicar filtros a los datos y tomar decisiones básicas en función de las condiciones ambientales captadas; Los modelos matemáticos y estadísticos son herramientas que permiten interpretar y predecir el comportamiento de las variables meteorológicas. Se basan en técnicas como series temporales, regresiones lineales y no lineales, modelos ARIMA, análisis de correlación y tendencia); en cuanto a la implementación de lógica difusa (Fuzzy Logic) para el manejo de incertidumbre en los datos esta permite trabajar con incertidumbre y con información imprecisa, propia de los entornos naturales. En sistemas meteorológicos, ayuda a tomar decisiones cuando los datos

no son completamente definidos o presentan ruido. Por ejemplo: “Si la humedad es ALTA y la temperatura es BAJA, entonces la posibilidad de lluvia es MEDIA”. Finalmente, las plataformas de visualización y monitoreo son sistemas de software o aplicaciones que permiten al usuario observar el estado de las variables meteorológicas en tiempo real, realizar análisis históricos, configurar alertas y visualizar predicciones.

1.7.1.2.3 Inteligencia Artificial Aplicada a Sistemas de Predicción. La Inteligencia Artificial (IA) cumple un rol fundamental en el diseño de sistemas predictivos modernos, especialmente en el ámbito meteorológico, agrícola y ambiental, entre otros, al permitir analizar grandes volúmenes de datos y encontrar patrones complejos.

1.7.2.3.1 Definición de Inteligencia Artificial. La Inteligencia Artificial es un área de la informática que se centra en desarrollar sistemas capaces de realizar tareas que tradicionalmente requieren inteligencia humana, como el aprendizaje, el razonamiento, la adaptación y la predicción.

La historia de la Inteligencia Artificial (IA) se remonta a mediados del siglo XX, cuando los primeros científicos comenzaron a explorar la idea de crear máquinas capaces de simular procesos de razonamiento y aprendizaje similares a los de los seres humanos.

En la década de 1950 fue el nacimiento del concepto de “Inteligencia artificial”, el término fue acuñado por John McCarthy en 1956 durante la Conferencia de Dartmouth, considerada el punto de partida formal de esta disciplina. En ese momento, la IA se centraba principalmente en desarrollar programas capaces de resolver problemas lógicos, jugar ajedrez o realizar tareas básicas de razonamiento. Las primeras investigaciones buscaban imitar el pensamiento humano a través de algoritmos simples y reglas definidas.

En (1980 - 2000) la evolución y aparición del machine learning, durante las décadas de 1980 y 1990, la inteligencia artificial experimentó importantes avances, especialmente con el desarrollo de nuevas técnicas de aprendizaje automático (*Machine Learning*). Esta evolución permitió que las máquinas no solo siguieran reglas predefinidas, sino que fueran capaces de aprender de los datos, adaptarse a situaciones cambiantes y mejorar su rendimiento con la

experiencia. En este periodo se desarrollaron sistemas expertos, redes neuronales artificiales básicas y técnicas de minería de datos, sentando las bases para el crecimiento posterior de la IA.

En la actualidad, la Inteligencia Artificial se ha aplicado en múltiples industrias, ha alcanzado un desarrollo significativo, siendo aplicada en una gran variedad de campos e industrias. Los avances en procesamiento de datos, capacidad de cómputo, algoritmos de *Machine Learning* y *Deep Learning* (aprendizaje profundo), han permitido a la IA participar activamente en áreas como la salud (diagnóstico médico automatizado); la agricultura (predicción de plagas y optimización de cultivos); las finanzas (análisis predictivo y gestión de riesgos); el transporte (vehículos autónomos); el medio ambiente (monitoreo climático y predicciones meteorológicas); y la industria (automatización de procesos y mantenimiento predictivo).

A todo esto, el crecimiento del Internet de las Cosas (IoT), el Big Data y la computación en la nube han permitido una integración más eficiente de la IA con sistemas de sensores y dispositivos inteligentes, logrando soluciones innovadoras para problemas complejos del mundo real.

En cuanto a los conceptos básicos

- **Machine Learning (Aprendizaje Automático):** Es un subconjunto de la IA que permite a los sistemas aprender de los datos sin ser explícitamente programados. Los algoritmos de Machine Learning identifican patrones en los datos y mejoran sus predicciones a medida que reciben nueva información.
- **Deep Learning (Aprendizaje Profundo):** Es una extensión del Machine Learning que utiliza redes neuronales profundas (muchas capas de procesamiento) para resolver problemas complejos. Es altamente eficiente en la detección de patrones no lineales o relaciones ocultas en grandes volúmenes de datos.
- **Lógica Difusa (Fuzzy Logic):** Es una técnica de IA que maneja conceptos de verdad parcial, permitiendo que las variables no se definan únicamente como VERDADERO o

FALSO, sino que se expresan en grados de pertenencia (entre 0 y 1), ideal para fenómenos naturales donde las fronteras son difusas.

- **Redes Neuronales Artificiales:** Sistemas computacionales inspirados en las redes neuronales biológicas. Permiten el aprendizaje, adaptación y predicción de comportamientos complejos mediante el entrenamiento con grandes conjuntos de datos.

1.7.2.3.2 Modelos Predictivos Basados en IA. Los modelos predictivos utilizan algoritmos de IA para analizar datos históricos y proyectar escenarios futuros. Se utilizan en sistemas de climatología para estimar variables atmosféricas y comportamientos meteorológicos.

1.7.2.3.2.1. Tipos de Modelos:

- **Modelos Estadísticos:** Se basan en métodos matemáticos tradicionales para encontrar relaciones y tendencias.
- **Modelos Basados en Lógica Difusa:** Utilizan reglas difusas para procesar información incierta o imprecisa.
- **Modelos de Machine Learning:** Aprenden de los datos y mejoran sus predicciones de manera autónoma.
- **Modelos Híbridos (combinan varios enfoques):** Combinan múltiples técnicas (estadística, lógica difusa, machine learning) para obtener mejores resultados en ambientes complejos.
- **Modelo de Deep Learning:** Utiliza redes neuronales con múltiples capas ocultas para capturar relaciones altamente complejas y no lineales en datos meteorológicos. Su arquitectura profunda permite aprender representaciones jerárquicas de los datos, identificando patrones sutiles que otros modelos no pueden detectar. Es especialmente efectivo para predicciones meteorológicas al manejar la naturaleza caótica y multivariable del clima.

1.7.2.3.3 Deep learning (ADAM). El aprendizaje profundo (Deep Learning) con optimizador ADAM representa una evolución avanzada de las redes neuronales artificiales. Este enfoque

utiliza arquitecturas neuronales con múltiples capas ocultas especializadas para capturar patrones temporales complejos en datos meteorológicos.

El funcionamiento de los modelos de Deep Learning implementados en este proyecto se basa en arquitecturas de redes neuronales profundas optimizadas específicamente para series temporales meteorológicas. La implementación utiliza el algoritmo de optimización ADAM (Adaptive Moment Estimation), que combina las ventajas de los algoritmos AdaGrad y RMSProp.

A nivel general, el funcionamiento del modelo se puede dividir en tres componentes principales:

1.7.2.3.3. Arquitectura Neuronal Especializada

El modelo implementa una arquitectura BiLSTM (LSTM Bidireccional) que analiza secuencias meteorológicas en ambas direcciones temporales. Esta estructura incluye:

- Capas convolucionales 1D para la extracción inicial de patrones locales en las series temporales
- Capas LSTM bidireccionales que capturan dependencias temporales en ambas direcciones
- Mecanismo de atención que identifica los segmentos más relevantes de las secuencias de entrada
- Normalización por lotes (Batch Normalization) que estabiliza y acelera el entrenamiento
- Funciones de activación no lineales como ReLU y Softmax que modelan relaciones complejas

1.7.2.3.3.2. Optimizador ADAM: El algoritmo ADAM ajusta la tasa de aprendizaje para cada parámetro del modelo de forma adaptativa:

- Mantiene tasas de aprendizaje individuales que se adaptan según los gradientes históricos
- Utiliza estimaciones del primer momento (media) y segundo momento (varianza) de los gradientes
- Incorpora corrección de sesgo para los momentos estimados
- Proporciona convergencia más rápida y estable que los optimizadores tradicionales
- Opera con hiperparámetros configurables: `learning_rate`, `beta_1`, `beta_2` y `epsilon`

1.7.2.3.3.3. Regularización y Prevención de Sobreajuste. El modelo implementa varias técnicas para mejorar la generalización:

- Dropout espacial y recurrente que reduce la dependencia entre neuronas
- Regularización L2 que penaliza pesos grandes en las capas densas y recurrentes
- Ruido gaussiano que incrementa la robustez frente a variaciones en los datos de entrada
- Early stopping que detiene el entrenamiento cuando no se observan mejoras en el conjunto de validación
- Técnicas de aumento de datos que generan variaciones sintéticas de condiciones meteorológicas infrecuentes

1.7.2.4. Redes Neuronales Artificiales (RNA). Las Redes Neuronales Artificiales son estructuras computacionales inspiradas en el funcionamiento del cerebro humano. Están compuestas por nodos (neuronas artificiales) interconectados que procesan información.

1.7.1.2.4.1. Funcionamiento Básico de las Redes Neuronales Artificiales (RNA). El funcionamiento de una Red Neuronal Artificial (RNA) se basa en la imitación del

comportamiento del cerebro humano, particularmente en la forma como las neuronas procesan y transmiten información. Las RNA están conformadas por un conjunto de nodos o "neuronas artificiales" distribuidos en diferentes capas que permiten transformar datos de entrada en resultados o predicciones útiles.

A nivel general, el funcionamiento básico de una red neuronal se puede dividir en tres etapas principales:

1.7.1.2.4.1.1 Entrada de Datos (*Input Layer*). En esta primera fase, la red neuronal recibe los datos de entrada que pueden provenir de sensores, bases de datos, sistemas de monitoreo, o cualquier otra fuente de información. Estos datos pueden ser valores numéricos, imágenes, señales climáticas, entre otros. Cada dato de entrada es asignado a una neurona dentro de la capa de entrada.

1.7.1.2.4.1.2. Procesamiento mediante Capas de Nodos (*Hidden Layers*). Luego de recibir la información, los datos pasan a través de una o varias capas ocultas (*hidden layers*), donde ocurre el procesamiento de la información. En estas capas:

- Cada nodo (neurona artificial) recibe una combinación ponderada de las entradas.
- Se aplican funciones matemáticas de activación que permiten determinar la salida de cada nodo.
- Las conexiones entre nodos tienen "pesos" ajustables, los cuales se modifican durante el entrenamiento de la red para mejorar la precisión de las predicciones.

Estas capas ocultas permiten a la red neuronal identificar patrones complejos, relaciones no lineales y características relevantes dentro de los datos, algo fundamental en tareas de predicción y clasificación.

1.7.1.2.4.1.3. Generación de Salidas o Predicciones (*Output Layer*). Finalmente, la información procesada llega a la capa de salida, donde la red proporciona un resultado o predicción; la calidad y precisión de las salidas dependen directamente del proceso de

entrenamiento previo de la red neuronal, donde se ajustan los pesos de las conexiones internas para reducir los errores de predicción. Dependiendo del tipo de problema, esta salida puede representar:

- Un valor numérico (como la temperatura estimada).
- Una categoría (por ejemplo, lluvia o no lluvia).
- Una probabilidad asociada a un evento.
- Una acción específica dentro de un sistema automatizado.

1.7.1.2.4.1.4. Aplicaciones en Predicción de Datos:

- Pronóstico de variables meteorológicas: temperatura, humedad, velocidad del viento, radiación solar.
- Identificación de patrones climáticos recurrentes.
- Detección de eventos extremos: lluvias torrenciales, heladas, sequías.

1.7.1.2.4.1.5. Aplicaciones de IA en Climatología y Agricultura. La IA ha transformado la manera en que se monitorean y gestionan los recursos naturales y los entornos agrícolas.

Los casos de uso reales:

- Sistemas de monitoreo ambiental inteligente.
- Predicción de plagas y enfermedades agrícolas.
- Optimización de riego y fertilización.
- Gestión de recursos hídricos.
- Sistemas de alerta temprana frente a eventos meteorológicos extremos.

1.7.1.2.1. Conceptos Técnicos Fundamentales. Este capítulo tiene como objetivo describir y explicar los principales conceptos técnicos que sustentan el diseño, desarrollo e implementación del sistema de predicción meteorológica. Se abordan las tecnologías de sensores, magnitudes físicas, redes de sensores, el Internet de las Cosas (IoT) y las bases de datos en la nube.

1.7.1.2.2. Sensores meteorológicos y Magnitudes Físicas

1.7.1.3.1.1. Tipos de Sensores. Los sensores meteorológicos permiten medir variables ambientales fundamentales que intervienen en los procesos de predicción meteorológica. Entre los sensores más utilizados en sistemas de monitoreo ambiental y agroclimático. Cada sensor meteorológico se encarga de medir una magnitud física específica del ambiente. Las principales magnitudes físicas asociadas son:

Tabla 2.

Magnitud física de los sensores

Sensor	Magnitud Física Medida	Unidad de Medición	Citado
Anemómetro (sensor de efecto Hall)	Velocidad de viento	m/s, km/h	Diseño y construcción de un Sistema de Medidas de Efecto Hall DC y AC, 2011
Veleta (Reed Switch	Dirección del viento	Grados (°)	Qbprofe (s.f)
Pluviómetro (Reed Switch)	Precipitación	mm	Qbprofe (s.f)
Sensor digital de temperatura y humedad (DHT22)	Temperatura/Humedad relativa	°C / %	Naylamp Mechatronics (s.f.) Max Electrónica (s.f.)
Sensor de Luminosidad (TSL2561)	Radiación solar directa (duración)	Horas de sol (Lux)	Dualtrónica (s.f.); CD Tecnología (s.f.); Max Electrónica (s.f.)

En el diseño del sistema de predicción meteorológica, se seleccionaron sensores que cumplen con criterios técnicos y prácticos esenciales, tales como bajo costo, precisión adecuada, disponibilidad en el mercado, facilidad de integración con plataformas embebidas y amplia documentación técnica. La elección de estos sensores responde a la necesidad de implementar un sistema funcional, confiable y replicable, adaptado a las condiciones climáticas locales y a los requerimientos del proyecto.

El anemómetro basado en sensor de efecto Hall fue escogido por su capacidad para medir la velocidad del viento mediante la detección de impulsos generados por un imán giratorio. Esta tecnología ofrece una respuesta confiable ante condiciones ambientales adversas y es ampliamente utilizada en estaciones meteorológicas de bajo costo, destacándose por su robustez y eficiencia en la medición de velocidades en m/s y km/h (Diseño y Construcción de un Sistema de Medidas de Efecto Hall DC y AC, 2011).

En cuanto a la dirección del viento, se empleó una veleta con Reed Switches y resistencias SMD, la cual detecta la orientación mediante la activación de un circuito magnético dependiente de la variación de la resistencia. Esta solución, de bajo consumo energético y sencilla implementación, permite obtener valores en grados con una adecuada precisión para el análisis climatológico (Qbrofe, s.f.).

Para la medición de precipitación, se optó por un pluviómetro que también incorpora un Reed Switch. Este dispositivo utiliza un mecanismo de balancín que cuenta las veces que el recipiente bascula por la acumulación de agua, lo que permite medir la cantidad de precipitación en milímetros. Este método es simple, confiable y de uso común en sistemas meteorológicos automatizados (Qbrofe, s.f.).

En el caso de la temperatura y la humedad relativa, se seleccionó el sensor digital DHT22, el cual entrega lecturas con precisión de ± 0.5 °C en temperatura y $\pm 2-5$ % en humedad. Además de su bajo costo, este sensor ofrece comunicación digital simple a través de un solo cable, lo cual facilita su integración en sistemas embebidos sin necesidad de calibraciones complejas (Naylamp Mechatronics, s.f.; Max Electrónica, s.f.).

Finalmente, para la medición de la radiación solar directa expresada en horas de sol (Lux), se utilizó el sensor TSL2561. Este dispositivo permite una medición precisa de la luz visible, gracias a su sensibilidad espectral diseñada para simular la respuesta del ojo humano. Su inclusión en el sistema permite estimar la duración de la insolación diaria, lo cual es clave en el análisis agroclimático (Dualtrónica, s.f.; CD Tecnología, s.f.; Max Electrónica, s.f.).

Otros sensores históricos

- Pluviógrafo: Mide y registra gráficamente la lluvia.
- Heliógrafo: Registra la duración de la radiación solar directa.
- Termómetro de Mercurio: Medición manual de temperatura.

1.7.1.2.3. Espectro visible, radiación y fotones. La radiación solar es uno de los factores más importantes en meteorología y agroclimatología, ya que es la fuente principal de energía que impulsa muchos procesos físicos en la atmósfera y en la superficie terrestre, como la temperatura, la evaporación, el crecimiento de plantas, entre otros.

- El espectro visible es sólo una pequeña parte del espectro electromagnético total (que incluye rayos X, ultravioleta, infrarrojo, microondas, etc.).
- Es la franja de luz que el ojo humano puede ver, y va desde los *380 nanómetros (nm)* hasta los *750 nanómetros (nm)* de longitud de onda.
- Este rango abarca los colores que percibimos: violeta, azul, verde, amarillo, naranja y rojo.

Dato clave: Las longitudes de onda más cortas (violeta y azul) tienen más energía. Las más largas (rojo) tienen menos energía.

1.7.1.2.1.4. Relación con luxes, watts y julios. Cuando hablamos de radiación o luz, es importante conocer estas 3 unidades que se usan para medir aspectos diferentes pero complementarios:

Tabla 3.

Relación con luxes, watts y julios

Unidad	¿Qué mide?	¿Dónde se usa?
Lux (lx)	Iluminancia. Es decir, cuánta luz visible incide sobre una superficie (luz útil).	Meteorología, agricultura, diseño de iluminación.
Watt (W)	Potencia de energía. Mide cuánta energía llega o sale en forma de radiación por segundo.	Paneles solares, radiación solar directa.
Julio (J)	Energía total acumulada o transferida ($1 \text{ W} = 1 \text{ J/seg}$).	Análisis de radiación diaria, calefacción natural.

Ejemplo:

- El Sol emite radiación → esta radiación llega a la Tierra con cierta potencia (Watts).
- Esa energía se acumula con el tiempo (Julios).
- Pero solo una parte de esa radiación es visible y útil para las plantas o los humanos (Luxes).

1.7.1.2.1.5. Comportamiento de los Fotones. Los fotones son las partículas que componen la luz (incluida la luz solar). Cada fotón transporta una cantidad de energía que depende de su frecuencia o longitud de onda. Cuanto más corta es la longitud de onda más energía lleva el fotón.

Los fotones del espectro visible (luz que vemos) interactúan con el medio ambiente generando:

- Calor (aumentan la temperatura del suelo o el aire).
- Fotosíntesis (activan procesos en las plantas).
- Cambios climáticos (a través de la evaporación o radiación térmica).

1.7.1.2.1.6. ¿Por qué es importante esto en un sistema meteorológico? Porque los sensores meteorológicos, especialmente aquellos relacionados con radiación (como piranómetros o heliógrafos), captan esta información para medir cuánta energía solar recibe un lugar; predecir temperatura, humedad y evaporación; analizar el microclima agrícola; y optimizar riego o cultivos basados en la luz solar disponible.

1.7.1.3.3. Redes de Sensores e Internet de las Cosas (IoT). El Internet de las Cosas (IoT, por sus siglas en inglés) hace referencia a la interconexión de dispositivos físicos a través de internet, permitiendo el intercambio de datos en tiempo real. En el contexto del sistema de predicción meteorológica, el IoT permite la comunicación de sensores meteorológicos, módulos de control y plataformas de visualización.

Los principales protocolos de comunicación utilizados en redes de sensores e IoT que permiten el envío seguro y eficiente de los datos capturados por los sensores hacia plataformas de análisis o almacenamiento en la nube son Wifi, Bluetooth, ZigBee, LoRa (Long Range), MQTT (Message Queuing Telemetry Transport) y HTTP/HTTPS.

En un sistema basado en IoT (Internet de las Cosas), como el de monitoreo y predicción meteorológica, la gestión y transmisión de datos es una de las etapas más importantes, ya que permite transformar los datos capturados por los sensores en información útil y disponible desde cualquier lugar.

Un flujo básico de gestión de datos en un sistema IoT se compone de varias fases:

17.1.3.3.1 Captura de Datos

- Los sensores meteorológicos (anemómetro, veleta, pluviómetro, termohigrómetro, etc.) están conectados a un microcontrolador o hardware.
- Realizan lecturas de variables físicas en intervalos regulares (por ejemplo, cada minuto, cada 5 minutos, cada hora).
- Estas lecturas son datos brutos (sin procesar).

1.7.1.3.3.2. Transmisión de Datos. *Los datos capturados por los sensores se transmiten mediante protocolos de comunicación IoT hacia un servidor local o hacia la nube.*

Algunos métodos de transmisión comunes son:

- Wi-Fi (802.11)
- Bluetooth Low Energy (BLE)
- LoRa (larga distancia)
- ZigBee
- MQTT (protocolo muy usado en IoT)
- HTTP / HTTPS

1.7.3.3.3. Procesamiento de Datos- *El procesamiento de los datos puede hacerse de dos formas:*

Tabla 4.

Procesamiento de datos

Tipo	¿Dónde ocurre?	Ventaja
Procesamiento Local (Edge Computing)	En el mismo microcontrolador o cerca de los sensores.	Reduce la latencia y consumo de internet.
Procesamiento en la Nube (Cloud Computing)	En servidores externos (Google, AWS, Azure).	Mayor capacidad de almacenamiento y análisis avanzado.

1.7.1.3.3.4. Almacenamiento de Datos (Bases de datos en la nube. El almacenamiento en la nube permite guardar, organizar y gestionar grandes volúmenes de datos históricos capturados por los sensores.

Algunas plataformas muy utilizadas son:

Tabla 5.

Plataformas utilizadas

Plataforma	Características
Firestore (Google)	Base de datos NoSQL, ideal para datos en tiempo real.
Google Cloud Platform (GCP)	Soluciones completas de almacenamiento y Big Data.
AWS IoT (Amazon)	Integración con servicios de inteligencia artificial y machine learning.
Azure IoT Hub (Microsoft)	Gestión segura de dispositivos IoT y almacenamiento.
MySQL en la Nube	Base de datos relacional tradicional adaptable a IoT.

Como los datos viajan por redes públicas o privadas, es fundamental protegerlos contra posibles ataques o pérdidas de información.

Las Principales Estrategias de Seguridad:

- **Cifrado de Datos:** Uso de SSL/TLS para encriptar la información durante la transmisión.
- **Autenticación de Dispositivos:** Identificar correctamente cada sensor o nodo para evitar accesos no autorizados.
- **Seguridad de Red:** Implementación de claves seguras, VPN, Firewalls y redes privadas.
- **Protocolos Seguros:** Utilizar:
 - HTTPS (HTTP seguro)
 - MQTT con TLS (cifrado para IoT)
 - SSH (para conexiones remotas seguras)
- **Actualizaciones Remotas Seguras (OTA):** Actualizar el firmware de los sensores a distancia, pero de forma protegida.

Las ventajas de una buena Gestión de Datos IoT:

- Mayor precisión en las predicciones meteorológicas.
- Visualización de datos en tiempo real desde cualquier lugar.
- Análisis histórico para tomar mejores decisiones.
- Automatización de alertas o respuestas inteligentes del sistema.
- Seguridad e integridad de la información.

1.7.1.4. Modelos de Inteligencia Artificial Utilizados en Predicción Meteorológicos. En los últimos años, la inteligencia artificial (IA) ha transformado significativamente los métodos de predicción meteorológica, permitiendo una mayor precisión en la estimación de variables meteorológicas a corto, mediano y largo plazo.

Dentro del presente proyecto, los principales modelos de IA aplicados fueron:

- **LSTM Bidireccional (BiLSTM):** El modelo LSTM (Long Short-Term Memory) es un tipo de red neuronal recurrente especializada en procesar series temporales y datos secuenciales, lo cual es ideal para datos meteorológicos. La versión Bidireccional permite que el modelo analice tanto las entradas pasadas como las futuras, mejorando la calidad de las predicciones. La ventaja es la capacidad de aprender dependencias a largo plazo y patrones complejos en los datos meteorológicos.
- **Mecanismo de Atención (Attention Mechanism):** Este método permite que el modelo se enfoque en las variables más relevantes dentro de un conjunto de datos. En predicción meteorológica, permite que el sistema identifique periodos críticos o variables que afectan directamente el tiempo meteorológico (humedad, radiación, temperatura, viento, entre otras).
- **Ensemble de Modelos (Modelos Híbridos):** Consiste en la combinación de varios modelos de IA (como LSTM, GRU, Redes Neuronales Artificiales) para generar un

resultado conjunto y más robusto. Se basa en la idea de que un conjunto de modelos diversificados puede superar el rendimiento de un único modelo. La ventaja es que aumenta la estabilidad, precisión y confiabilidad de las predicciones meteorológicas.

- **Optimización y Entrenamiento de Modelos:** El desarrollo de modelos de IA en aplicaciones meteorológicas requiere procesos metodológicos específicos que garanticen resultados precisos, consistentes y coherentes con las leyes físicas del ambiente. Este proceso sistemático abarca desde la preparación inicial de los datos hasta la evaluación final del rendimiento.

1.7.1.4.1. Preprocesamiento de Datos. El preprocesamiento de datos constituye una fase crítica que determina en gran medida la calidad del modelo resultante:

- Limpieza de datos: Identificación y manejo de valores atípicos mediante técnicas como Z-score ($\pm 3\sigma$) o IQR; filtrado de datos inconsistentes (ej. humedad >100%, temperaturas extremas irreales); detección de discontinuidades en series temporales.
- Normalización y estandarización: Escalado Min-Max para variables con límites definidos (0-1 para humedad relativa); estandarización Z-score para variables como temperatura y presión atmosférica; transformaciones logarítmicas para variables con distribución sesgada (ej. precipitación).
- Tratamiento de datos faltantes: Imputación basada en interpolación temporal para series de alta frecuencia; métodos de imputación espacial utilizando datos de estaciones cercanas; técnicas avanzadas como KNN o regresión para preservar relaciones entre variables.
- Ingeniería de características: Cálculo de índices meteorológicos relevantes (índice de calor, sensación térmica); extracción de características de temporalidad (hora del día, estacionalidad); integración de variables derivadas (gradientes de presión, delta de temperatura).

1.7.1.4.2. Entrenamiento y Optimización de modelos

El proceso de entrenamiento debe considerar las particularidades de los datos meteorológicos:

- Partición estratificada de datos: División cronológica respetando secuencias temporales (70-15-15% para entrenamiento, validación y prueba); estratificación por temporadas o condiciones meteorológicas para garantizar representatividad; validación cruzada adaptada a series temporales (Time Series Cross-Validation).
- Selección y configuración de algoritmos; Redes neuronales recurrentes (LSTM, GRU) para capturar dependencias temporales; modelos de ensemble (Random Forest, Gradient Boosting) para variables con relaciones no lineales; redes convolucionales para procesamiento de datos espaciales (mapas meteorológicos).
- Ajuste de hiperparámetros: Optimización bayesiana para exploración eficiente del espacio de hiperparámetros; grid search o random search con métricas específicas para fenómenos meteorológicos; ajuste de tasas de aprendizaje con programación adaptativa (learning rate scheduling).
- Técnicas de regularización: Dropout (20-50%) para prevenir sobreajuste en redes neuronales profundas; regularización L1/L2 para modelos de regresión y redes neuronales; early stopping basado en conjunto de validación con criterios meteorológicos.

1.7.1.4.3. Post-procesamiento con Restricciones Físicas. La integración de conocimiento físico en modelos de IA mejora significativamente su robustez:

- Restricciones físicas fundamentales: Límites termodinámicos (temperatura del punto de rocío \leq temperatura ambiente); conservación de energía y masa en sistemas meteorológicos cerrados; respeto de ecuaciones atmosféricas fundamentales (ecuación hidrostática, balance geostrofico).
- Métodos de implementación de restricciones: Funciones de pérdida personalizadas que penalizan violaciones de leyes físicas; capas de corrección física post-predicción (physics-informed neural networks); técnicas de ensemble con ponderación basada en coherencia física.

- Calibración de predicciones probabilísticas: Métodos de calibración isotónica para ajustar distribuciones de probabilidad; técnicas de post-procesamiento estadístico (Model Output Statistics); corrección de sesgos sistemáticos observados en validación histórica.

1.7.1.4.4. Métricas de Evaluación y Validación. La evaluación debe considerar múltiples dimensiones de rendimiento relevantes para aplicaciones meteorológicas:

● **Métricas de Precisión Generales:**

- RMSE (Root Mean Square Error): Sensible a errores grandes, crítico para eventos extremos.
- MAE (Mean Absolute Error): Evaluación de error promedio sin penalización cuadrática.
- MAPE (Mean Absolute Percentage Error): Útil para variables con rangos amplios.
- R^2 (Coeficiente de Determinación): Evaluación de capacidad explicativa general.

● **Métricas Específicas para Meteorología:**

- NSE (Nash-Sutcliffe Efficiency): Estándar en hidrología y predicción de caudales.
- Skill Score: Comparación con modelos de referencia (climatología o persistencia).
- Brier Score: Evaluación de predicciones probabilísticas de eventos binarios.
- CRPS (Continuous Ranked Probability Score): Para predicciones probabilísticas continuas.

● **Evaluación Especializada:**

- Matrices de contingencia para predicción de eventos extremos (precisión, recall, F1-score).
- Análisis espectral para evaluar representación de ciclos y patrones temporales.
- Evaluación de incertidumbre mediante análisis de ensemble spread-skill.

1.7.1.4.4.5 Consideraciones Operacionales. La implementación de modelos en entornos operativos meteorológicos requiere:

- Eficiencia computacional: Optimización para inferencia en tiempo real (cuantización, poda de modelos); paralelización para procesamiento de datos masivos espaciotemporales; equilibrio entre complejidad y tiempo de respuesta para alertas tempranas.
- Actualización y mantenimiento: Reentrenamiento periódico con datos recientes (estrategias de transfer learning); monitoreo de drift conceptual debido a cambio climático o variabilidad; Integración en flujos de trabajo operativos meteorológicos existentes.

La combinación de técnicas avanzadas de aprendizaje automático con el conocimiento físico de sistemas meteorológicos permite desarrollar modelos híbridos que aprovechan lo mejor de ambos enfoques, resultando en predicciones más robustas, físicamente consistentes y confiables para aplicaciones críticas.

1.7.1.4.5. Comparación con Modelos Tradicionales de Predicción Meteorológica

Históricamente, la predicción meteorológica se ha basado en modelos estadísticos y físicos clásicos, los cuales presentan ventajas, pero también limitaciones frente a los modelos basados en IA.

Tabla 6.*Comparación de modelos tradicionales*

Modelo Tradicional	Descripción	Limitaciones
ARIMA	Modelo estadístico para series temporales.	No capta relaciones no lineales complejas.
Penman-Monteith	Modelo físico para estimar evapotranspiración.	Depende de muchos parámetros medidos.
Regresiones Lineales	Relaciones simples entre variables.	Poca capacidad de generalización.

Las Ventajas de los Modelos de IA Frente a los Modelos Tradicionales:

- Capturan relaciones no lineales.
- Mejoran la predicción multivariable.
- Se adaptan a grandes volúmenes de datos.
- Capacidad de autoaprendizaje.
- Menor dependencia de ecuaciones específicas.

1.7.1.5. Climatología y Agroclimatología Aplicada. La climatología y agroclimatología aplicada son disciplinas fundamentales para el estudio, análisis y predicción de fenómenos atmosféricos, especialmente en contextos agrícolas, ambientales y de gestión del recurso hídrico. Su integración en sistemas de predicción meteorológica con inteligencia artificial permite una mejor toma de decisiones en actividades agrícolas, manejo del agua y adaptación al cambio climático.

1.7.1.5.2 Variables Meteorológicas Clave.

- **Evapotranspiración: (ET):** Es la pérdida de agua desde el suelo y la vegetación hacia la atmósfera, combinando evaporación directa y transpiración vegetal. La importancia que posee es el indicador esencial en la gestión de riego, predicción de sequías y balance hídrico de los cultivos. Para calcularlo estimarlo se realiza por métodos empíricos o modelos avanzados como FAO Penman-Monteith.

Humedad

- **Humedad Relativa (HR):** Porcentaje de vapor de agua presente en el aire respecto a su capacidad máxima.
- **Humedad Absoluta:** Cantidad real de vapor de agua presente en un volumen de aire.
- **Punto de Rocío:** Temperatura a la cual el aire se satura y comienza a condensar el vapor de agua.

Balance Hídrico y Déficit Hídrico

- **Balance Hídrico:** Relación entre el agua que entra (precipitación) y sale (evapotranspiración) de un sistema agrícola o ecosistema.
- **Déficit Hídrico:** Condición donde la demanda de agua supera la disponibilidad, afectando cultivos y ecosistemas.

Radiación Solar

- La radiación solar varía según la latitud, época del año y condiciones atmosféricas. Es un factor determinante en los procesos de fotosíntesis, temperatura y evapotranspiración.
- Tablas según latitud:FAO y otros organismos disponen de tablas para estimar radiación solar diaria media por latitud.

Estomas, Fotosíntesis y Transpiración

- *Estomas:* Pequeñas aberturas en las hojas de las plantas por donde se regula el intercambio gaseoso.
- *Fotosíntesis:* Proceso vital de las plantas donde convierten CO₂ y luz solar en energía (glucosa).
- *Transpiración:* Liberación de vapor de agua desde los estomas hacia la atmósfera.

1.7.1.5.3 Herramientas y Ecuaciones

1.7.1.5.3.1. Modelo FAO Penman-Monteith. Método estándar internacional recomendado por la FAO para estimar la evapotranspiración de referencia (ET_o), combinando:

- Radiación solar
- Temperatura del aire
- Humedad relativa
- Velocidad del viento

La Ecuación FAO Penman-Monteith es considerada actualmente por la FAO (Organización de las Naciones Unidas para la Alimentación y la Agricultura) como el método más confiable y estandarizado a nivel mundial para calcular la *Evapotranspiración de referencia* (ET_o), que es la cantidad de agua que pierde un cultivo por evaporación y transpiración. La ecuación general:

$$ET_o = \frac{0.408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} u^2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 u_2)}$$

¿Qué significa cada término?

Tabla 7.

Términos de la FAO

Símbolo	Descripción	Unidades
ET _o	Evapotranspiración de referencia.	mm/día
R _n	Radiación neta en superficie del cultivo.	MJ/m ² /día
G	Flujo de calor en el suelo.	MJ/m ² /día
T	Temperatura media diaria del aire a 2 m.	°C
u ₂	Velocidad del viento a 2 m de altura.	m/s
e _s	Presión de vapor de saturación.	kPa
e _a	Presión de vapor actual.	kPa
(e _s - e _a)	Déficit de presión de vapor.	kPa
Δ	Pendiente de la curva de presión de vapor vs temperatura.	kPa/°C
γ	Constante psicrométrica.	kPa/°C

¿Cómo funciona?

La ecuación FAO Penman-Monteith (Allen et al., 1998) combina tres factores esenciales: energía disponible, déficit de presión de vapor y movimiento del aire.

- 1. Energía disponible (R_n - G):** Cuánta energía solar hay disponible para evaporar agua.
- 2. Déficit de presión de vapor (e_s - e_a):** Qué tan seco está el ambiente (mayor déficit = más evapotranspiración).
- 3. Movimiento del aire (u₂):** Mayor viento = mayor pérdida de agua.

Las ventajas de FAO Penman-Monteith son:

- Es un modelo físico basado en principios reales.
- Integra variables meteorológicas clave.
- Se adapta a cualquier región o clima.
- Es recomendado por FAO desde 1998.
- Compatible con estaciones meteorológicas automáticas y sensores IoT.

Otros Autores y Métodos Antiguos:

- Método Hargreaves-Samani: Basado en temperatura y radiación.
- Método Blaney-Criddle: Relacionado con temperatura y fotoperiodo.
- Método Thornthwaite: Basado en temperatura mensual.

Sensores Sónicos y Modernos

Los sensores sónicos permiten medir velocidad del viento, evapotranspiración y otros parámetros de forma precisa, utilizando ondas sonoras.

Fórmulas Tradicionales y Empíricas

- **Tanque Evaporímetro Clase A:** Mide la evaporación directa de agua.
- **Fórmulas Empíricas:** Relacionan variables meteorológicas simples para estimar E_{To} en ausencia de datos completos.

1.7.1.6. Aplicaciones del Sistema Propuesto. El sistema inteligente de predicción meteorológica basado en hardware, sensores y modelos de inteligencia artificial permite una amplia gama de aplicaciones en sectores estratégicos como la agricultura de precisión y la gestión ambiental. Estas aplicaciones permiten a los usuarios tomar decisiones informadas, mejorar la productividad, optimizar recursos y minimizar riesgos ambientales y productivos.

1.7.6.1 Agricultura de Precisión. La agricultura de precisión se basa en el uso de tecnologías avanzadas (sensores, sistemas de información geográfica, inteligencia artificial) para optimizar el uso de insumos agrícolas, mejorar la productividad y minimizar impactos ambientales.

1.7.6.1.1 Heladas. La importancia de las heladas puede causar la pérdida total o parcial de cultivos sensibles (ej. papa, frutales, café), para poder predecir se debe utilizar sensores de temperatura y humedad en tiempo real junto con modelos LSTM o de lógica difusa para anticipar descensos críticos de temperatura, se esperaría una activación automática de medidas

preventivas como riego nocturno, cobertura de cultivos o encendido de generadores térmicos. Por ejemplo, en zonas rurales de Cundinamarca, se puede alertar a productores de papa con 4 a 6 horas de anticipación para tomar acciones.

1.7.6.1.2. Evapotranspiración. Es la combinación de la evaporación del agua desde el suelo y la transpiración de las plantas. El sistema emplea datos de radiación solar, temperatura, humedad relativa y velocidad del viento para calcular ET_0 con la fórmula FAO Penman-Monteith, esta permite establecer calendarios de riego óptimos, evitando tanto el exceso como el déficit de agua en el cultivo, tendría bastantes beneficios como ahorro de agua, ya que, mayor eficiencia del riego por goteo o aspersión.

1.7.6.1.3. Estrés Hídrico. El estado en que la planta no puede absorber suficiente agua para compensar la pérdida por transpiración, a través de sensores de humedad del suelo, temperatura foliar (IR) y variables ambientales, se esperaría una activación de alarmas para aplicar riego suplementario antes de que el cultivo se vea afectado. Por ejemplo, el control de estrés en cultivos de tomate o lechuga en invernadero.

1.7.6.1.4. Ejemplo de un cultivo (PAPA). La papa, conocida científicamente como *Solanum tuberosum* L., pertenece a la familia Solanaceae y es originaria de Sudamérica, específicamente de la región templada de los Andes. Su distribución abarca desde los 70° LN hasta los 40° LS, adaptándose principalmente a regiones templadas o subtropicales con estación fresca.

El ciclo de madurez varía según el tipo de variedad: las tempranas requieren 3-4 meses, las intermedias 4-5 meses, y las tardías 5-6 meses. Su tipo fotosintético es C3 y prospera en altitudes que van desde los 400 metros en zonas templadas hasta los 3000 metros en los trópicos.

En cuanto a los requerimientos climáticos, la papa es demandante de radiación solar, funcionando óptimamente con 20,000-50,000 lux. La temperatura ideal para su desarrollo oscila entre 15-20°C, con un rango funcional de 10-25°C. Prefiere noches frescas (13-17°C) y una temperatura del suelo de 17°C para una buena tuberización. Es un cultivo sensible a las heladas, muriendo a temperaturas de -2°C.

El agua es fundamental para este cultivo, necesitando entre 500-700 mm durante su ciclo, siendo crítico el período desde la formación de tubérculos hasta la floración. Prefiere ambientes con humedad relativa alta, lo cual favorece el crecimiento del tubérculo.

Respecto a las condiciones del suelo, requiere profundidades mayores a 50 cm, ya que sus raíces pueden alcanzar 60-70 cm. Se adapta mejor a suelos francos, franco-arcillo-limosos y franco-arenosos, siempre que estén bien aireados y cuenten con buen drenaje. El pH óptimo va de 5.5 a 6.0, aunque tolera rangos entre 4.8 y 7.0. Es moderadamente tolerante a la salinidad.

Frente al cambio climático, la papa muestra respuestas interesantes. Con niveles elevados de CO₂ responde positivamente, aumentando su rendimiento entre 30-40%. Presenta cierta tolerancia a niveles moderados de ozono, pero es sensible a la sequía, incluso a niveles moderados de estrés hídrico. No tolera altas temperaturas; por encima de 25°C se reduce la translocación de carbohidratos y sobre los 35°C se detiene el crecimiento del tallo.

1.7.6.2 Gestión Ambiental. Este sistema también tiene una utilidad directa en el monitoreo ambiental y la planificación sostenible de recursos.

Las Aplicaciones en Energías Renovables:

- **Energía solar:** Esta estima la radiación solar diaria y mensual, evalúa la eficiencia esperada de paneles solares en distintas ubicaciones y tiene soporte para dimensionamiento de microplantas solares.
- **Energía eólica:** Se puede monitorear la velocidad y dirección del viento mediante anemómetros y hacer una evaluación del potencial eólico en zonas agrícolas o rurales.
- **Ventaja:** Permite integrar sistemas híbridos (solar-eólico) para alimentar estaciones climáticas o sistemas de riego.

1.7.6.2.1. Balance Hídrico y Control en Cultivos. Es el cálculo entre el agua disponible (lluvia, riego) y las pérdidas por evapotranspiración. Las variables que generalmente usa son precipitación (P), evapotranspiración (ET_o y ET_c) y humedad del suelo. Esto permite saber si

el cultivo tiene déficit, exceso o balance hídrico positivo, por lo que tendría una buena optimización del recurso hídrico en zonas de escasez.

1.7.6.2.2. Monitoreo y Alertas Inteligentes

- **Sistema de alertas tempranas:** Alertas por condiciones extremas como sequías, exceso de radiación, vientos fuertes, o lluvias intensas.
- **Visualización serial:** Paneles de control en tiempo real accesibles por bluetooth (dashboard).
- Aplicaciones:
 - Protección de cultivos.
 - Seguridad en zonas expuestas a deslizamientos.
 - Planificación territorial ambiental.

1.7.1.7. METODOLOGÍAS (HARDWARE Y SOFTWARE)

1.7.1.7.1 Metodologías para el Desarrollo de Hardware

1.7.1.7.1.1 Modelo en V. El Modelo en V, también conocido como Modelo de Verificación y Validación, representa un enfoque sistemático para el desarrollo de sistemas de hardware que establece una relación directa entre cada fase de desarrollo y su correspondiente fase de prueba. Este modelo, originado en la década de 1980, se estructura como una "V" donde el lado izquierdo representa las etapas de especificación que descienden en nivel de abstracción, mientras que el lado derecho representa las etapas de integración y verificación que ascienden en nivel de implementación.

La estructura fundamental del Modelo en V comprende las siguientes fases: especificación de requisitos del sistema, diseño de arquitectura del sistema, diseño de arquitectura de componentes, e implementación. Cada una de estas fases tiene su correspondiente fase de verificación: pruebas de aceptación del sistema, pruebas de integración del sistema, pruebas de integración de componentes, y pruebas unitarias, respectivamente.

La principal ventaja de este modelo radica en su énfasis en la verificación temprana y la validación continua, permitiendo identificar defectos en etapas iniciales del desarrollo, lo que reduce significativamente los costos de corrección. Adicionalmente, establece un marco claro para la trazabilidad entre requisitos y pruebas, facilitando la documentación y el aseguramiento de la calidad. Su implementación resulta particularmente efectiva en proyectos de desarrollo de hardware donde los requisitos son estables y bien definidos desde el inicio.

1.7.1.7.1.2 Prototipado Evolutivo para Hardware. El Prototipado Evolutivo constituye una metodología iterativa para el desarrollo de hardware que se centra en la construcción progresiva de prototipos funcionales que evolucionan hacia el producto final. A diferencia de los enfoques tradicionales, esta metodología no busca desarrollar un prototipo desechable, sino versiones incrementales que se refinan continuamente con base en la retroalimentación obtenida de pruebas y evaluaciones.

El proceso metodológico del Prototipado Evolutivo comprende cuatro fases principales que se repiten cíclicamente: conceptualización del prototipo, diseño preliminar, implementación del prototipo, y evaluación. Cada ciclo produce un prototipo más refinado que incorpora ajustes basados en las lecciones aprendidas durante la evaluación de la versión anterior.

La aplicación de esta metodología resulta particularmente valiosa en el desarrollo de sistemas de hardware complejos donde existe incertidumbre técnica o cuando los requisitos no están completamente definidos al inicio del proyecto. Sus principales ventajas incluyen la visualización temprana de la funcionalidad del sistema, la identificación oportuna de problemas técnicos, y la adaptabilidad ante cambios en los requisitos o restricciones técnicas.

1.7.1.7.2. Metodologías para el Desarrollo de Software

1.7.1.2.1 Metodología Espiral. La metodología espiral constituye un enfoque de desarrollo de software propuesto por Barry Boehm en 1986, que se caracteriza por combinar elementos iterativos con aspectos sistemáticos del modelo en cascada. Su esencia radica en la integración de actividades de desarrollo con una gestión proactiva de riesgos, permitiendo abordar proyectos de alta complejidad donde existe un nivel considerable de incertidumbre. La utilidad fundamental de esta metodología se manifiesta en su capacidad para detectar tempranamente riesgos y problemas potenciales, facilitar entregas incrementales de funcionalidad, y realizar ajustes continuos basados en retroalimentación constante, resultando particularmente valiosa en proyectos cuyos requisitos no están completamente definidos al inicio.

El funcionamiento de la metodología espiral se estructura en cuatro fases principales que se repiten cíclicamente, configurando una espiral evolutiva. La primera fase comprende la determinación de objetivos, donde se definen metas, restricciones y alternativas posibles. La segunda fase implica la evaluación y reducción de riesgos, incluyendo un análisis profundo de los mismos y la planificación de estrategias para su mitigación. La tercera fase corresponde al desarrollo y validación, concentrándose en la implementación y verificación del producto. Finalmente, la cuarta fase contempla la planificación del siguiente ciclo, revisando los resultados obtenidos y preparando el terreno para la siguiente iteración. Esta estructura cíclica permite una evolución constante del proyecto, adaptándose a los cambios y aprendiendo de la experiencia acumulada.

Entre las principales ventajas de la metodología espiral destacan la gestión proactiva de riesgos que reduce la probabilidad de fracaso del proyecto; la adaptabilidad ante cambios en los requisitos durante el desarrollo; el enfoque iterativo que permite entregas incrementales de funcionalidad; y la incorporación sistemática de retroalimentación que mejora continuamente la calidad del producto. Sin embargo, presenta desafíos como la complejidad en su implementación, requiriendo experiencia en gestión de proyectos y análisis de riesgos; la necesidad de participación activa de los stakeholders durante todo el ciclo de vida; y una documentación rigurosa para mantener la trazabilidad entre ciclos.

1.7.2 MARCO LEGAL

El marco legal establece las normativas aplicables a la recolección de datos meteorológicos, uso de inteligencia artificial, telecomunicaciones y energías renovables en Colombia. Algunas leyes, decretos y normas relevantes incluyen:

1.7.2.1. Legislación sobre datos meteorológicos y medio ambiente

1.7.2.1.1. Ley 99 de 1993: Crea el Ministerio del Medio Ambiente y establece la obligación del monitoreo climático para la protección ambiental. La protección ambiental ha adquirido una relevancia creciente a nivel mundial. Colombia, como país megadiverso, implementó la Ley 99 de 1993 con el objetivo de establecer un marco normativo para el desarrollo sostenible. En este contexto, el monitoreo climático y las estaciones meteorológicas son fundamentales para cumplir con las obligaciones ambientales, prevenir riesgos y diseñar políticas públicas eficientes.

La Ley 99 de 1993 creó el Ministerio del Medio Ambiente (hoy Ministerio de Ambiente y Desarrollo Sostenible) y el Sistema Nacional Ambiental (SINA). Esta ley establece principios como la prevención, precaución, participación ciudadana y desarrollo sostenible. Su artículo 31 determina la creación y fortalecimiento de sistemas de información ambiental, incluyendo redes de monitoreo climático y meteorológico.

El IDEAM fue creado en 1993 a partir de la Ley 99, con el fin de consolidar las funciones de monitoreo, investigación y análisis en materia hidrológica, meteorológica, ambiental y de recursos naturales renovables. Sus funciones principales son monitorear y reportar variables meteorológicas, emitir alertas tempranas por riesgos climáticos, generar pronósticos del tiempo meteorológico, administrar y operar las redes de estaciones meteorológicas del país y apoyar al gobierno en la toma de decisiones ambientales.

Las estaciones meteorológicas son instalaciones equipadas con sensores y dispositivos que permiten medir y registrar datos del clima. Estas estaciones pueden ser automáticas o manuales. Entre sus principales variables se encuentran la temperatura, precipitación, humedad relativa, velocidad y dirección del viento, presión atmosférica y radiación solar. El IDEAM opera más de 2000 estaciones distribuidas en todo el territorio colombiano.

La Ley 99 reconoce que el conocimiento del estado del clima y de los recursos naturales es esencial para la gestión ambiental. Gracias a las estaciones meteorológicas administradas por el IDEAM, es posible cumplir con los principios de prevención y control ambiental, generando datos confiables que permiten prevenir desastres naturales, evaluar el cambio climático y diseñar políticas públicas adecuadas.

Entre los principales beneficios del monitoreo climático se destaca la gestión de riesgos de desastres, prevención de inundaciones y sequías, protección de la biodiversidad y los ecosistemas, apoyo a sectores como la agricultura, transporte y salud pública y la evaluación del impacto del cambio climático en el país.

A pesar de los avances, Colombia enfrenta desafíos importantes en la modernización de las estaciones meteorológicas, mayor cobertura en zonas rurales y de difícil acceso, uso de nuevas tecnologías (IoT, Inteligencia Artificial), conciencia ciudadana sobre el uso de datos climáticos y inversión constante en infraestructura y capacitación técnica.

La Ley 99 de 1993 representa un marco legal fundamental para la gestión ambiental en Colombia. Las estaciones meteorológicas, operadas principalmente por el IDEAM, son piezas clave para garantizar el monitoreo constante de las variables meteorológicas. Es necesario fortalecer esta infraestructura y modernizar los sistemas de monitoreo para enfrentar los retos ambientales actuales y futuros del país.

1.7.2.1.2. Decreto 298 de 2016: Regula el Sistema Nacional Ambiental (SINA) y la Recopilación de Datos Meteorológicos. El Decreto 298 de 2016 es una normativa importante en Colombia que regula aspectos esenciales del Sistema Nacional Ambiental (SINA). Este decreto establece directrices para el funcionamiento, organización y coordinación de las entidades que conforman el SINA, con énfasis en la gestión de información ambiental y meteorológica.

El principal objetivo del Decreto 298 de 2016 es regular la organización y funcionamiento del SINA, fortaleciendo los procesos de gestión, intercambio y acceso a la información ambiental, incluyendo los datos meteorológicos, hidrológicos y de calidad ambiental.

El SINA está conformado por entidades públicas, privadas, organizaciones sociales, comunidades y ciudadanos que desarrollan actividades relacionadas con la gestión ambiental. Este sistema busca garantizar la protección del medio ambiente, la conservación de los recursos naturales y la sostenibilidad del territorio colombiano.

El Decreto 298 de 2016 establece que las entidades del SINA deben colaborar en la recopilación, integración y difusión de datos meteorológicos, hidrológicos y ambientales. Estos datos son fundamentales para realizar análisis climáticos, prevenir desastres naturales, apoyar la planificación territorial y formular políticas públicas basadas en evidencia.

El IDEAM es la entidad encargada de coordinar la gestión de la información ambiental en Colombia. Según el Decreto 298, el IDEAM debe operar y administrar redes de monitoreo ambiental y meteorológico, procesar y divulgar datos ambientales, generar alertas tempranas, apoyar la toma de decisiones gubernamentales.

La importancia de la recopilación de datos meteorológicos es vital para prever fenómenos climáticos extremos, mitigar riesgos ambientales, desarrollar proyectos sostenibles, fortalecer la educación y cultura ambiental y mejorar la planificación agrícola y urbana.

El Decreto 298 de 2016 fortalece la estructura y funcionamiento del SINA, dándole un papel protagónico a la gestión de la información ambiental. El monitoreo y la recopilación de datos meteorológicos permiten al país prepararse mejor frente a los retos del cambio climático y garantizan una gestión ambiental responsable.

1.7.2.1.3. Resolución 0583 de 2017 (IDEAM): Regula las redes de monitoreo meteorológico en Colombia. La Resolución 0583 de 2017, expedida por el Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM), establece los lineamientos técnicos y normativos para la instalación, operación y mantenimiento de las redes de monitoreo meteorológico e hidrológico en Colombia.

Su objetivo principal es garantizar que las redes de monitoreo implementadas por las entidades públicas y privadas cumplan con los estándares de calidad, confiabilidad y cobertura, con el fin de mejorar la generación de información ambiental en el país.

Las redes de monitoreo meteorológico permiten observar, registrar y analizar variables meteorológicas y ambientales fundamentales, tales como temperatura, humedad, precipitaciones, velocidad y dirección del viento, presión atmosférica y radiación solar.

La resolución aplica a entidades públicas y privadas, organizaciones con estaciones meteorológicas, operadores de redes hidrometeorológicas y sistemas de alerta temprana y gestión del riesgo.

Los principales requisitos establecidos por la resolución son condiciones de instalación de estaciones, especificaciones de los sensores y equipos, protocolos de calibración y mantenimiento, reporte de información al IDEAM y georreferenciación precisa de las estaciones.

El IDEAM tiene la responsabilidad de registrar y certificar las redes de monitoreo, supervisar el cumplimiento de la normativa, consolidar la información en bases de datos nacionales, emitir conceptos técnicos sobre las estaciones instaladas.

La aplicación de esta resolución permite mejorar la calidad de los datos meteorológicos, fortalecer los sistemas de alerta temprana, facilitar estudios climáticos de largo plazo y apoyar la planificación territorial y sectorial.

La Resolución 0583 de 2017 del IDEAM es fundamental para el desarrollo de un sistema confiable y estandarizado de monitoreo meteorológico en Colombia. Esta regulación garantiza que la información ambiental obtenida sea útil, precisa y esté disponible para la toma de decisiones gubernamentales y privadas.

1.7.2.2. Normas sobre Telecomunicaciones e IoT

1.7.2.2.1. Ley 1341 de 2009: Regula el uso del espectro electromagnético para la transmisión de datos. Ley 1341 de 2009, también conocida como la Ley de Tecnologías de la Información y las Comunicaciones (TIC), establece las disposiciones generales para la organización del sector de las telecomunicaciones en Colombia. Uno de sus principales enfoques es la regulación del uso del espectro electromagnético, vital para la transmisión de datos.

La ley tiene como objetivo promover el acceso, uso y aprovechamiento eficiente de las Tecnologías de la Información y las Comunicaciones (TIC) por parte de todos los colombianos, garantizando el libre acceso a la información y la igualdad de oportunidades.

El espectro electromagnético es un recurso natural limitado, compuesto por las ondas electromagnéticas utilizadas para transmitir señales de radio, televisión, telefonía móvil, internet inalámbrico y otros servicios de comunicación. Su uso está regulado por el Estado para evitar interferencias y garantizar su adecuada explotación.

Entre los principios orientadores de la ley se destaca el uso eficiente y racional del espectro electromagnético, promoción de la competencia en el sector TIC, neutralidad tecnológica, universalización de los servicios TIC y protección de los derechos de los usuarios.

La ley asigna al Estado colombiano, a través del Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC), la responsabilidad de administrar, planificar, asignar y vigilar el uso del espectro electromagnético en todo el territorio nacional.

El espectro electromagnético permite la operación de redes inalámbricas (Wi-Fi, LTE, 5G), comunicaciones satelitales, radiodifusión y televisión, servicios de telefonía móvil. y transmisión de datos meteorológicos y ambientales a través de redes de sensores.

La Ley 1341 de 2009 establece sanciones para quienes hagan uso no autorizado del espectro electromagnético, incluyendo multas económicas, clausura de estaciones ilegales y decomiso de equipos no autorizados.

La Ley 1341 de 2009 constituye un marco normativo esencial para el desarrollo de las telecomunicaciones en Colombia, garantizando el uso adecuado, eficiente y ordenado del espectro electromagnético, vital para la transmisión de datos en diversos sectores, incluyendo las estaciones meteorológicas y redes de monitoreo.

1.7.2.2.2. Resolución CRC 5050 de 2016: Regula el uso de dispositivos IoT en Colombia.

La Resolución CRC 5050 de 2016 fue expedida por la Comisión de Regulación de Comunicaciones (CRC) de Colombia con el objetivo de establecer el marco normativo para

la operación y uso de dispositivos del Internet de las Cosas (IoT), promoviendo su desarrollo en el país y regulando su integración con las redes de telecomunicaciones existentes.

El Internet de las Cosas (IoT) se refiere a la interconexión digital de objetos cotidianos a través de internet, permitiendo que estos dispositivos recopilen, procesen y compartan información. Entre sus aplicaciones más destacadas están las ciudades inteligentes, las redes de sensores, la industria 4.0, y el monitoreo ambiental y meteorológico.

Regular las condiciones técnicas y operativas para el acceso e interconexión de los dispositivos IoT a las redes públicas de telecomunicaciones en Colombia, garantizando su adecuado funcionamiento y evitando interferencias perjudiciales.

Los aspectos clave de la resolución de la definición de las condiciones para el uso eficiente del espectro radioeléctrico por dispositivos IoT, establecimiento de parámetros técnicos para la operación de estos dispositivos, condiciones para la transmisión de datos de corto alcance y normas sobre calidad de servicio y seguridad de la información transmitida por IoT.

Gracias a esta resolución, las estaciones meteorológicas y redes de monitoreo climático que utilizan dispositivos IoT para transmitir datos ambientales, climáticos o meteorológicos, cuentan con un marco legal que regula y protege su funcionamiento en Colombia.

La Resolución CRC 5050 de 2016 busca fomentar el despliegue de soluciones IoT en diversos sectores productivos del país, garantizando un entorno normativo claro, seguro y eficiente para todos los actores involucrados.

La Resolución CRC 5050 de 2016 constituye un avance significativo en la regulación del Internet de las Cosas en Colombia, permitiendo el desarrollo de nuevas tecnologías y servicios, entre ellos, los sistemas de monitoreo ambiental y meteorológico basados en IoT.

1.7.2.3. Legislación sobre Inteligencia Artificial y Protección de Datos

1.7.2.3.1. Ley 1581 de 2012: Regula la protección de datos personales en Colombia. Aplicable si el sistema recopila y almacena información sensible. La Ley 1581 de 2012 fue promulgada en Colombia con el propósito de desarrollar el derecho constitucional que tienen

todas las personas a conocer, actualizar y rectificar la información que se haya recogido sobre ellas en bases de datos o archivos. Esta ley regula la protección de datos personales en el país y establece los principios y procedimientos para su adecuado tratamiento.

Garantizar la protección de los derechos fundamentales de los ciudadanos, en especial el derecho al Habeas Data, asegurando que la recolección, almacenamiento, uso, circulación o supresión de datos personales se realice bajo estrictos parámetros legales y éticos.

Los datos personales son cualquier información vinculada o que pueda asociarse a una o varias personas naturales determinadas o determinables. Estos pueden ser datos públicos, datos privados y datos sensibles (como datos de salud, origen racial, creencias religiosas, entre otros).

Los principios rectores para el tratamiento de datos son principio de legalidad, principio de finalidad, principio de libertad, principio de veracidad o calidad, principio de transparencia, principio de acceso y circulación restringida, principio de seguridad y principio de confidencialidad.

En proyectos que involucran estaciones meteorológicas y redes IoT, si se recolectan datos personales (por ejemplo, ubicación de usuarios, datos de contacto o cualquier otra información sensible), es obligatorio cumplir con lo establecido en la Ley 1581 de 2012, garantizando la protección y privacidad de la información.

Las obligaciones de los responsables del tratamiento de datos son solicitar autorización previa y expresa del titular de los datos, informar el uso que se dará a los datos, implementar medidas de seguridad para proteger la información, permitir a los titulares el acceso, actualización, corrección o supresión de sus datos y cumplir con las disposiciones de la Superintendencia de Industria y Comercio (SIC).

El incumplimiento de esta ley puede generar sanciones administrativas, multas económicas y posibles procesos judiciales por la vulneración de derechos fundamentales.

La Ley 1581 de 2012 es fundamental en el contexto de la transformación digital, especialmente en proyectos tecnológicos como las estaciones meteorológicas y redes de monitoreo que capturan y almacenan datos. Su cumplimiento garantiza confianza, transparencia y protección de la información personal de los usuarios.

1.7.2.3.2. CONPES 3975 de 2019: Estrategia Nacional de Inteligencia Artificial en Colombia. El Documento CONPES 3975 de 2019 establece la Estrategia Nacional de Inteligencia Artificial (IA) en Colombia, con el propósito de fomentar el uso responsable, ético y seguro de esta tecnología. La estrategia busca promover el desarrollo económico y social del país, garantizando al mismo tiempo la protección de los derechos fundamentales.

Definir los lineamientos estratégicos para la adopción de la inteligencia artificial en Colombia, impulsando el desarrollo tecnológico, la competitividad y la transformación digital en los sectores público y privado.

Los ejes estratégicos del CONPES 3975 de 2019 son el fortalecimiento del talento humano especializado en IA, generación de confianza en el uso de IA, impulso al desarrollo y adopción de IA, creación de una infraestructura de datos adecuada y marco ético y normativo para IA.

La IA es vista como una herramienta clave para mejorar la productividad, la eficiencia y la competitividad en sectores como salud, agricultura, industria, transporte, educación y seguridad, entre otros.

En proyectos como estaciones meteorológicas inteligentes y sistemas de monitoreo climático, la IA permite realizar análisis predictivos, optimización de recursos, modelado de escenarios y generación de alertas tempranas. Esto contribuye a una mejor toma de decisiones en sectores como el agro, el medio ambiente y la gestión de desastres.

Los beneficios esperados del CONPES 3975 son fomentar la investigación y el desarrollo (I+D) en IA, atraer inversión extranjera, mejorar la competitividad del país, incentivar el emprendimiento tecnológico y garantizar un uso responsable y ético de la IA.

El CONPES 3975 de 2019 posiciona a Colombia como un referente en Latinoamérica en materia de inteligencia artificial, estableciendo un marco estratégico para su desarrollo y aplicación en múltiples sectores, incluyendo el ambiental y tecnológico.

1.7.2.4. Regulaciones sobre Energía Renovable

1.7.2.4.1. Ley 1715 de 2014: Promueve el uso de energías renovables en Colombia. La Ley 1715 de 2014 establece el marco legal para la integración de las energías renovables no convencionales al Sistema Energético Nacional en Colombia. Su objetivo es promover el desarrollo, la inversión y la utilización de fuentes limpias de energía como parte de la política de desarrollo sostenible del país.

Fomentar el aprovechamiento de fuentes no convencionales de energía, especialmente aquellas de carácter renovable, para contribuir a la sostenibilidad ambiental, la seguridad energética y la diversificación de la matriz energética del país.

Los ámbitos de aplicación son el sector público y privado, generación de energía solar, eólica, geotérmica, biomasa, mareomotriz e hidráulica de pequeña escala y proyectos rurales y de difícil acceso energético.

Entre los incentivos y beneficios de la ley estaría la deducción de impuestos, exclusión de IVA en equipos e infraestructura, exoneración de aranceles para importación de tecnologías limpias, depreciación acelerada de activos y certificados de reducción de emisiones.

La Ley 1715 impulsa el desarrollo económico sostenible, reduce la dependencia de combustibles fósiles, mejora el acceso a la energía en zonas apartadas y contribuye a la mitigación del cambio climático. Además, promueve la innovación tecnológica y el crecimiento del sector de energías limpias.

Las estaciones meteorológicas inteligentes pueden aprovechar las energías renovables, como la energía solar o eólica, para su funcionamiento autónomo en zonas rurales. Además, estas estaciones permiten medir variables esenciales para proyectos de energías renovables, como radiación solar, velocidad del viento y condiciones atmosféricas.

La Ley 1715 de 2014 representa un avance significativo en la política energética de Colombia, estableciendo mecanismos legales y económicos que incentivan el uso de energías renovables. Esta legislación promueve un futuro energético más sostenible, resiliente y amigable con el medio ambiente.

1.7.2.4.2. Decreto 2469 de 2014: Regula incentivos para proyectos con fuentes de energía renovable. El Decreto 2469 de 2014 complementa la Ley 1715 de 2014 y tiene como objetivo principal reglamentar y establecer los procedimientos necesarios para que los proyectos de energías renovables accedan a los incentivos económicos y tributarios en Colombia.

Establecer las condiciones, requisitos y procedimientos para el acceso a los beneficios tributarios y aduaneros para los proyectos que utilicen fuentes no convencionales de energía, principalmente energías renovables.

Los principales incentivos del decreto son la deducción de renta del 50% de la inversión realizada, exclusión de IVA en bienes y servicios requeridos para los proyectos, exclusión de derechos arancelarios para importaciones y depreciación acelerada de activos vinculados a energías renovables.

Los interesados deben presentar sus proyectos ante la UPME (Unidad de Planeación Minero-Energética), que evaluará la viabilidad técnica y ambiental. Si es aprobado, se certifica el acceso a los incentivos ante la DIAN y la Autoridad Aduanera.

El Decreto 2469 de 2014 es clave para promover la inversión privada y pública en proyectos de energías limpias, apoyando así la política energética sostenible, la diversificación de fuentes de energía y la protección del medio ambiente.

Las estaciones meteorológicas alimentadas por energías renovables o que formen parte de proyectos de monitoreo ambiental pueden acceder a estos beneficios. Además, estas estaciones permiten medir parámetros esenciales para la planificación y operación de proyectos de energías limpias.

El Decreto 2469 de 2014 representa un mecanismo estratégico que impulsa el desarrollo de energías renovables en Colombia, ofreciendo facilidades tributarias y aduaneras para fomentar un futuro más sostenible.

II. DOCUMENTACIÓN DEL SOFTWARE

2.1. PLAN DE PROYECTO

Figura 8

Project Libre Meteorología

ID	Nombre	Duración	Inicio	Terminado	Predecesores	Nombres del Recurso
1	☐ Meteorología	150.083 da...	6/11/24 07:00 AM	18/04/25 01:00 PM		
2	☐ Fase de investigación y recolección de datos	20 days	6/11/24 07:00 AM	26/11/24 11:00 AM		
3	Revisión de literatura	20 days	6/11/24 07:00 AM	26/11/24 11:00 AM		Natha
4	Requerimientos técnicos y funcionales	20 days	6/11/24 07:00 AM	26/11/24 11:00 AM		Bryan
5	dataset de Estación Meteorológica	26 days	6/11/24 07:00 AM	11/11/24 08:00 PM	4	Bryan[50%];Natha[50%]
6	Adaptación de dataset para IA	6 days	12/11/24 07:00 AM	17/11/24 08:00 PM	5	Bryan[50%];Natha[50%]
7	☐ Fase de diseño e implementación del sistema	75.083 days	6/11/24 07:00 AM	2/02/25 01:00 PM		
8	Ensamblaje de los componentes	30 days	6/11/24 07:00 AM	6/12/24 11:00 AM		Bryan[50%];Natha[50%]
9	Implementación y calibración	15 days	18/12/24 07:00 AM	14/01/25 08:00 PM	8	Bryan[50%];Natha[50%]
10	Desarrollo del sistema inteligente	60 days	6/11/24 08:00 AM	18/01/25 01:00 PM		Bryan[50%];Natha[50%]
11	Entrenamiento del sistema inteligente	15 days	18/01/25 01:00 PM	2/02/25 01:00 PM	10	Bryan[50%];Natha[50%]
12	☐ Fase de validación y evaluación	65 days	2/02/25 01:00 PM	8/04/25 01:00 PM		
13	Pruebas de validación del sistema inteligente	25 days	2/02/25 01:00 PM	27/02/25 01:00 PM	11	Bryan
14	Comparación de los resultados	25 days	2/02/25 01:00 PM	27/02/25 01:00 PM	11	Natha
15	Ajustes y optimización de los parámetros	40 days	27/02/25 01:00 PM	8/04/25 01:00 PM	14	Bryan[50%];Natha[50%]
16	☐ Fase de presentación y análisis de resultados	50 days	27/02/25 01:00 PM	18/04/25 01:00 PM		
17	Análisis detallado de los resultados obtenidos	20 days	27/02/25 01:00 PM	19/03/25 01:00 PM	13	Bryan[50%];Natha[50%]
18	Validación de los resultados	15 days	19/03/25 01:00 PM	3/04/25 01:00 PM	17	Bryan[50%];Natha[50%]
19	Elaboración del artículo	15 days	3/04/25 01:00 PM	18/04/25 01:00 PM	18	Bryan[50%];Natha[50%]

2.1.1. Resumen del Desarrollo del Proyecto "Predicción Meteorológica"

El proyecto "Predicción Meteorológica" se desarrolló intensamente desde el 6 de noviembre de 2024 hasta el 18 de abril de 2025 (Figura 8), con una jornada de trabajo continua de lunes a domingo, en un horario de 7:00 a.m. a 12:00 p.m. y de 1:00 p.m. a 8:00 p.m. Cabe resaltar que el único periodo de descanso fue entre el 24 de diciembre de 2024 y el 5 de enero de 2025, respetando las fechas especiales de fin de año. Este proyecto requirió un alto nivel de compromiso y dedicación, sacrificando tiempo personal y social para cumplir con los objetivos establecidos.

El proceso inició el 6 de noviembre de 2024 con la fase de investigación y recolección de datos, donde se realizó la revisión de literatura y se definieron los requerimientos técnicos y funcionales necesarios para el diseño del sistema. Posteriormente, se trabajó en la recolección y conformación de un dataset proveniente de una estación meteorológica, el cual fue adaptado para el uso de técnicas de inteligencia artificial.

Una vez concluida esta fase, desde el 11 de diciembre de 2024 comenzó el diseño y la implementación del sistema. Esta etapa involucró el ensamblaje de los componentes físicos, seguido de la calibración e implementación del sistema, y finalmente el desarrollo del sistema inteligente. A partir del 18 de enero de 2025, se dio inicio al entrenamiento del sistema, afinando los modelos y algoritmos con los datos recolectados y procesados.

El 2 de febrero de 2025 comenzó la fase de validación y evaluación, realizando pruebas rigurosas del funcionamiento del sistema, comparación de resultados obtenidos y ajustes finales en los parámetros para mejorar la precisión del modelo.

Finalmente, desde el 27 de febrero de 2025 se realizó la presentación y análisis de resultados, donde se hizo un estudio detallado de los resultados obtenidos, su respectiva validación y la posterior elaboración del artículo y documento final. Este proceso concluyó el 18 de abril de 2025, cumpliendo con el cronograma planteado desde un principio.

El Sistema de Predicción Meteorológica de Facatativá implementa una metodología de desarrollo en espiral, seleccionada específicamente por su capacidad para manejar proyectos complejos con requisitos evolutivos. Esta metodología resulta ideal para sistemas que combinan modelos de aprendizaje profundo con datos meteorológicos críticos, permitiendo una evaluación continua de riesgos asociados con la precisión de predicción, desarrollo incremental de componentes, validación periódica con datos reales, refinamiento progresivo de modelos LSTM y adaptación a las condiciones meteorológicas específicas de Facatativá.

La estructura fundamental de esta metodología se compone de cuatro cuadrantes principales que se repiten a través de múltiples iteraciones, ampliando su alcance en cada ciclo: determinación de objetivos y requisitos, análisis y evaluación de riesgos, desarrollo e implementación, y evaluación y planificación. Este enfoque cíclico permite abordar sistemáticamente los desafíos que surgen durante el desarrollo.

El proyecto se organiza en cinco ciclos principales de desarrollo en espiral. El primer ciclo, con duración estimada de una semana, se centra en la preparación de datos y análisis exploratorio, estableciendo las fuentes de datos meteorológicos, estructuras de almacenamiento y

procesamiento, e identificando variables meteorológicas clave para la región. El segundo ciclo, de cuatro semanas, aborda el modelado inicial y feature engineering, diseñando las primeras versiones de modelos LSTM e implementando técnicas específicas para el procesamiento de características temporales.

El tercer ciclo, que requiere cinco semanas arquitecturas, implementando mecanismos de atención y técnicas avanzadas de regularización. El cuarto ciclo, con duración de tres semanas, desarrolla sistemas de post-procesamiento y adaptación local, incorporando reglas de consistencia física y conocimiento meteorológico específico de Facatativá. Finalmente, el quinto ciclo, planificado para dos semanas, se dedica a la integración, interfaz y despliegue, desarrollando la interfaz gráfica, documentación completa y estableciendo un plan de mantenimiento continuo. Esta metodología reconoce la naturaleza evolutiva y compleja del desarrollo de sistemas predictivos basados en aprendizaje profundo, proporcionando un camino estructurado pero flexible hacia un sistema meteorológico funcional, preciso y adaptado a las necesidades específicas del microclima de Facatativá. Su implementación requiere un equipo multidisciplinario con experiencia en meteorología y aprendizaje automático, comunicación efectiva entre científicos de datos y expertos del dominio, y un compromiso con la evaluación continua y adaptación de requisitos.

Paralelamente la implementación del hardware para el Sistema de Predicción Meteorológica de Facatativá siguió rigurosamente el Modelo en V, una metodología especialmente adecuada para el desarrollo de sistemas embebidos y componentes de hardware. Este enfoque permitió un desarrollo sistemático con verificación en cada etapa, asegurando la calidad y fiabilidad del sistema final.

El Modelo en V se aplicó a través de cuatro etapas principales:

2.1.2. Modelo V

2.1.2.1. Definición de Componentes. En la Definición de Componentes que es la fase inicial se realizó una cuidadosa identificación y selección de los sensores y componentes electrónicos necesarios para capturar con precisión las variables meteorológicas relevantes para Facatativá. Se priorizaron componentes como:

- Pluviómetro de alta precisión para la medición exacta de precipitaciones
- Anemómetro para registro de velocidad y dirección del viento
- Sensores de temperatura y humedad calibrados para la altitud específica (2600 msnm)
- Sensores de radiación solar adaptados a las condiciones de la Sabana de Bogotá
- Sistemas de procesamiento y almacenamiento de datos con capacidad para operación continua

La selección se realizó considerando la precisión, durabilidad y adaptabilidad a las condiciones ambientales locales.

2.1.2.2. Diseño del Circuito: Durante esta etapa se desarrollaron esquemas detallados y diseños de circuitos que integraron todos los componentes seleccionados en un sistema cohesivo. Este proceso incluyó:

- Diseño de esquemáticos completos de circuitos eléctricos
- Desarrollo de PCBs (Printed Circuit Boards) para la integración de componentes
- Implementación de sistemas de alimentación respaldados para operación continua
- Diseño de interfaces para la comunicación entre sensores y el sistema de procesamiento
- Configuración de sistemas de almacenamiento de datos con redundancia

El diseño priorizó la robustez ante condiciones climáticas adversas y la eficiencia energética.

2.1.2.3. Pruebas Individuales: Antes del ensamblaje completo, cada sensor y componente fue sometido a rigurosas pruebas individuales para verificar su funcionamiento óptimo:

- Calibración precisa de cada sensor bajo diferentes condiciones ambientales
- Verificación de rangos de operación adecuados para las condiciones de Facatativá
- Pruebas de resistencia a condiciones extremas (humedad, temperatura, radiación solar)
- Evaluación del consumo energético y estabilidad de funcionamiento

- Validación de precisión contra instrumentos de referencia certificados

Este enfoque permitió identificar y resolver problemas a nivel de componentes antes de la integración del sistema.

2.1.2.4. Validación del Sistema: La fase final consistió en pruebas exhaustivas del sistema hardware completamente ensamblado en condiciones reales de operación:

- Implementación del sistema en el laboratorio LESTOMA de la Universidad de Cundinamarca
- Monitoreo continuo durante períodos extendidos bajo diversas condiciones climáticas
- Comparación de mediciones con estaciones meteorológicas de referencia cercanas
- Verificación de la integridad y consistencia de los datos recolectados
- Pruebas de stress y recuperación ante fallos potenciales

Esta validación rigurosa aseguró que el hardware fuera capaz de proporcionar datos confiables y precisos para alimentar el sistema de predicción meteorológica, cumpliendo con todos los requisitos establecidos para el monitoreo meteorológico en Facatativá.

La metodología en V permitió mantener una trazabilidad completa entre los requisitos iniciales y los resultados de validación final, asegurando que cada aspecto del hardware cumpliera con su propósito específico dentro del sistema de predicción meteorológica.

2.1.3. Gestión y Seguimiento del Proyecto

Para garantizar un adecuado control y seguimiento de las actividades desarrolladas en el proyecto "Predicción Meteorológica", se hizo uso de herramientas tecnológicas de gestión de proyectos y registro de actividades.

Figura 9

One Drive Meteorología

Nombre	Modificado	Modificado...	Tamaño del ar...	Compartir	Actividad
Objetivo 1	12/2/2024	Guest Contributor	4 elementos	Compartida	
Objetivo 2	12/2/2024	Guest Contributor	0 elementos	Compartida	
Objetivo 3	12/2/2024	Guest Contributor	0 elementos	Compartida	
Objetivo 4	12/2/2024	Guest Contributor	0 elementos	Compartida	
Bitacora.xlsx	Hace un minuto	NATHALIA GUTIERF	14,6 KB	Compartida	
Objetivo_2.docx	11/30/2024	BRYAN RENE ROJA'	15,2 KB	Compartida	
Objetivos.docx	4 de marzo	NATHALIA GUTIERF	17,0 KB	Compartida	

Figura 10

Google Drive Meteorología

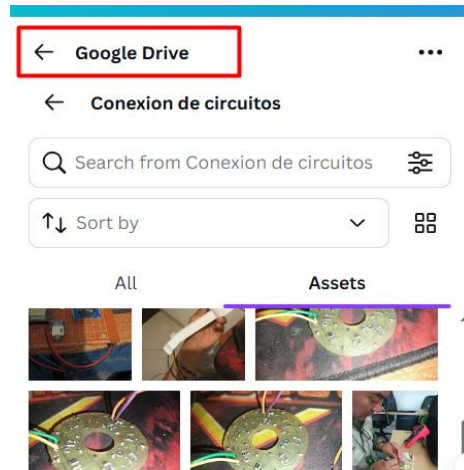
Carpetas

- Artículo
- Colab Notebooks
- imagenes
- Libro de Grado
- Manuales
- Objetivo 1
- Objetivo 2
- Objetivo 3
- Objetivo 4
- Programas
- Proteus

Archivos

- Objetivos con activi...

Figura 11

Canva Meteorología

2.1.3.1. Herramientas Utilizadas: Se empleó ProjectLibre como software principal de gestión de proyectos (Figura 8), lo cual permitió estructurar, planificar y hacer seguimiento detallado del cronograma de actividades, tiempos de ejecución, responsables y tareas específicas. Esta herramienta facilitó la visualización clara de las etapas del proyecto, sus duraciones y dependencias.

Figura 12

Google Colab Comparaciones

```

# Paso 6: Generar visualizaciones
print("\n6. Generando visualizaciones...")
visualizacion_datos(df_combinado, directorio_salida)

# Paso 7: Análisis comparativo de condiciones si hay datos disponibles
if 'condicion_pred' in df_combinado.columns and 'condicion_real' in df_combinado.columns:
    print("\n7. Realizando análisis comparativo de condiciones meteorológicas...")
    comparativa_condiciones(df_combinado, directorio_salida)
else:
    print("\n7. No hay datos suficientes para análisis comparativo de condiciones.")

# Paso 8: Análisis diario
print("\n8. Realizando análisis diario...")
analisis_diario(df_combinado, directorio_salida)

# Paso 9: Análisis comparativo detallado
print("\n9. Realizando análisis comparativo detallado...")
analisis_comparativo_detallado(df_combinado, directorio_salida)

# Paso 10: Generar gráfica comparativa de temperaturas
print("\n10. Generando gráfica comparativa de temperaturas...")
grafica_comparativa_temperatura(df_combinado, directorio_salida)

# Paso 11: Análisis de desviación de temperaturas
print("\n11. Analizando desviación de temperaturas...")
resultados_desviacion = analisis_desviacion_temperaturas(df_combinado, directorio_salida)

print("\n=== ANÁLISIS COMPLETADO ===")
if directorio_salida:
    print(f"Las visualizaciones se han guardado en el directorio: {directorio_salida}")

return df_combinado, resultados

# Ejecutar el análisis si se ejecuta directamente
if __name__ == "__main__":
    df_combinado, resultados = ejecutar_analisis()

```

Drive already mounted at /content/drive; to attempt to forcibly remount, call drive.mount("/content/drive", force_remount=True).
Verificando acceso a la carpeta: /content/drive/MyDrive/Comparación
¡ERROR! No se pudo acceder a la carpeta. Verifica la ruta.

Verificando acceso a archivos individuales:
Estación (CSV): NO EXISTE
Clima Fotos (Excel): NO EXISTE
Predicciones (Excel): NO EXISTE

Rutas finales para usar en el análisis:
Datos estación: /content/drive/MyDrive/Comparación/Porfin.csv
Clima Fotos: /content/drive/MyDrive/Comparación/Clima.xlsx

Adicionalmente, se implementó una bitácora de actividades en una hoja de cálculo colaborativa almacenada inicialmente en OneDrive (Figura 9), permitiendo un registro en tiempo real y un trabajo colaborativo eficiente entre los integrantes del proyecto. Sin embargo, debido a los constantes requerimientos de autenticación del sistema institucional de OneDrive, se optó también por utilizar Google Drive como medio complementario (Figura 10), especialmente para el almacenamiento y acceso ágil a imágenes, gráficos e ilustraciones utilizadas directamente en Canva (Figura 11), plataforma que fue clave en la creación de collages y presentaciones visuales del proyecto. También se utilizó Google Colab (Figura 12) como entorno de desarrollo para implementar y comparar los diferentes modelos de predicción meteorológica, aprovechando sus capacidades de procesamiento en la

nube y la facilidad para compartir y colaborar en tiempo real sobre los algoritmos y resultados obtenidos.

2.1.3.2. Estructura de la Bitácora: La bitácora estuvo diseñada con los siguientes campos:

- **Fecha:** Día específico de la actividad.
- **Responsable:** Integrante encargado de la tarea.
- **Objetivo con Actividad:** Descripción del objetivo general y la actividad puntual realizada.
- **Estado:** Indicador de si la actividad fue completada o está pendiente.
- **Observaciones:** Detalle de lo realizado durante la actividad.
- **Próximas Acciones:** Actividades siguientes o tareas que se deben realizar para continuar con el flujo del proyecto.

Un ejemplo práctico del registro realizado en la bitácora es el siguiente:

Tabla 8.

Bitácora

Fecha	Responsable	Actividad	Estado	Observaciones	Próximas Acciones
03/12/2024	Nathalia	Objetivo 1; Actividad 2	Completada	Investigación de las metodologías para el desarrollo del hardware.	—
29/11/2024	Bryan; Nathalia; Docente Andrade	Objetivo 1; Actividad 2	Tutoría	Revisión de requerimientos técnicos y funcionales para la estación meteorológica.	Realizar actividad 2, antes de próxima reunión
16/03/2024	Nathalia; Bryan	Objetivo 4; Actividad 3	Pendiente	Ajustes en parámetros del modelo de IA para mejorar rendimiento.	Hacer pruebas y validar

Este formato se replicó a lo largo de todo el desarrollo del proyecto, permitiendo llevar un control exhaustivo de cada actividad realizada (Tabla 8), así como de las acciones futuras necesarias para avanzar en cada objetivo planteado.

Gracias al uso de estas herramientas, se logró mantener un registro claro, ordenado y trazable del trabajo realizado, facilitando la toma de decisiones y permitiendo la optimización de los tiempos de ejecución.

2.2. Determinación de Requerimientos

2.2.1 Resumen

Este documento ERS describe los requisitos funcionales y no funcionales para el desarrollo e implementación de un prototipo de sistema computacional inteligente para predicción meteorológica de la Universidad de Cundinamarca, extensión Facatativá. El

documento está estructurado en tres secciones principales: introducción, descripción general y requisitos específicos. Los requisitos están organizados de manera detallada, clasificando funcionalidades, interfaces, restricciones y atributos del sistema. Se incluyen también apéndices con información complementaria como casos de uso y especificaciones técnicas.

2.2.2. Descripción General

En esta sección se describen todos aquellos factores que afectan al producto y a sus requisitos. No se describen los requisitos, sino su contexto. Esto permitirá definir con detalle los requisitos en la sección 3, haciendo que sean más fáciles de entender.

Normalmente, esta sección consta de las siguientes subsecciones: Perspectiva del producto, funciones del producto, características de los usuarios, restricciones, factores que se asumen y futuros requisitos.

2.2.3 Perspectiva del Producto

Es un prototipo de sistema computacional para la predicción meteorológica en el laboratorio LESTOMA. Se compone de tres subsistemas principales, el primero es una **estación meteorológica física que para el hardware electrónico será basado en ESP32 con sensores de bajo costo**; un **sistema de procesamiento y predicción**: Software en Python con modelos de deep learning

1. **Interfaz de Usuario**: Aplicación de escritorio con múltiples módulos de interacción

El sistema es independiente de otros productos pero puede complementarse con datos de servicios externos como ERA5 para mejorar sus predicciones. El producto no forma parte de un sistema mayor, aunque está diseñado para permitir futuras integraciones.

2.2.4 Funciones del Producto

1. **Adquisición de Datos Meteorológicos**

- Medición de variables meteorológicas mediante sensores especializados
- Almacenamiento local de datos en tarjeta SD
- Transmisión de datos vía Bluetooth

2. **Procesamiento y Análisis de Datos**

- Preprocesamiento automatizado de datos meteorológicos
- Detección y corrección de valores anómalos
- Conversión y normalización de unidades

3. **Predicción Meteorológica**

- Generación de pronósticos para 72 horas mediante redes LSTM
- Clasificación de condiciones climáticas en categorías
- Asignación de niveles de confianza a predicciones

4. **Visualización y Monitoreo**

- Dashboard en tiempo real de condiciones actuales
- Visualización gráfica de predicciones
- Interfaz para consulta de datos históricos

5. **Sistema de Alertas**

- Evaluación de riesgos de desbordamiento de agua en un tanque mediante lógica difusa
- Generación de notificaciones visuales y sonoras
- Registro de historial de alertas

6. **Retroalimentación y Mejora**

- Mecanismos para corrección de predicciones por usuarios
- Actualización incremental del modelo predictivo
- Integración de datos verificados con ponderación especial

7. **Aplicaciones Prácticas**

- Cálculo de agua recolectada en base a precipitación
- Información relevante para planificación agrícola

2.2.5. Restricciones

2.2.5.1. Restricciones de Desarrollo

- El desarrollo del sistema debe implementarse siguiendo la metodología en "V" para los componentes de hardware y una metodología ágil para el desarrollo de software.

- El presupuesto disponible para el proyecto limita la selección de componentes a alternativas de bajo costo, priorizando la eficiencia y funcionalidad sobre características avanzadas.
- La implementación debe realizarse con herramientas de software libre y código abierto para garantizar sostenibilidad y replicabilidad.

2.2.5.2 Restricciones de Hardware

- La estación meteorológica debe utilizar el microcontrolador ESP32-WROOM-32D, limitado a 520KB de memoria SRAM y velocidad de procesamiento de 240MHz.
- Los sensores están limitados a: DHT22 para temperatura/humedad, TSL2561 para luminosidad, pluviómetro de reed switch, anemómetro con sensor Hall KY-003 y veleta con reed switches.
- La estructura física debe fabricarse mediante impresión 3D utilizando filamento PLA, con post-procesamiento para resistencia a la intemperie.
- El sistema debe operar con alimentación de 5V, optimizando el consumo energético para permitir operación continua.
- Los componentes electrónicos deben contar con protección adecuada contra humedad, radiación solar y otros factores ambientales.

2.2.5.3. Restricciones de Sistema Operativo

- La aplicación de software debe ser compatible con Windows 10.
- El sistema debe poder instalarse sin requerir privilegios de administrador en el equipo host.
- La aplicación no debe consumir más de 2GB de RAM ni más de 2GB de almacenamiento permanente.
- Las dependencias de bibliotecas externas deben minimizarse y documentarse claramente para facilitar la instalación.
- La aplicación solo debe requerir permisos para acceso a puertos COM/Bluetooth y al sistema de archivos local.

2.2.5.4 Restricciones de Normativas y Seguridad

- La recolección y almacenamiento de datos debe cumplir con la Ley 1581 de 2012 de protección de datos personales.
- El acceso al sistema debe estar protegido mediante autenticación con contraseña, especialmente para operaciones remotas.
- La estación debe cumplir con normativas ambientales locales para instalación de equipos en espacios universitarios.

2.2.5.5. Restricciones del Modelo LSTM y Predicciones

- El sistema debe ser independiente de la conexión a internet para la recolección de datos y las operaciones básicas. Sin embargo, funcionalidades como notificaciones o actualización del modelo podrían requerir conectividad.
- En caso de pérdida de conexión, los datos recolectados se deberán almacenar localmente hasta que el sistema pueda sincronizarse nuevamente con el servidor principal.
- La comunicación Bluetooth debe mantener un protocolo robusto que gestione eficientemente pérdidas temporales de conectividad.

- La comunicación entre componentes debe optimizarse para minimizar el consumo de energía, limitando la frecuencia de transmisiones a intervalos no menores a 5 minutos.
- El rango efectivo de comunicación Bluetooth debe ser de al menos 10 metros en condiciones ideales.
- El protocolo de comandos debe ser simple, robusto y documentado para permitir extensiones futuras.

2.2.6 Suposiciones y Dependencias

Suposiciones:

- Se dispone de acceso continuo a energía eléctrica
- Existe personal capacitado para la instalación y mantenimiento básico
- La ubicación de la estación tiene una exposición adecuada para los sensores
- Los usuarios tienen conocimientos básicos de computación

Dependencias:

- Disponibilidad de componentes electrónicos específicos
- Bibliotecas Python: TensorFlow, pandas, numpy, matplotlib
- Datos históricos de ERA5 para entrenamiento inicial y calibración
- Condiciones ambientales dentro de los rangos operativos de los sensores

2.2.7 Requisitos Específicos

Esta sección contiene los requisitos a un nivel de detalle suficiente como para permitir a los diseñadores diseñar un sistema que satisfaga estos requisitos, y que permita al equipo de pruebas planificar y realizar las pruebas que demuestren si el sistema satisface, o no, los requisitos. Todo requisito aquí es especificado describiendo comportamientos externos del sistema, perceptibles por parte de los usuarios, operadores y otros sistemas. Esta es la sección más larga e importante de la ERS. Deberán aplicarse los siguientes principios:

El documento debería ser perfectamente legible por personas de muy distintas formaciones e intereses.

Deberán referenciarse aquellos documentos relevantes que poseen alguna influencia sobre los requisitos.

Todo requisito deberá ser unívocamente identificable mediante algún código o sistema de numeración adecuado.

Lo ideal, aunque en la práctica no siempre realizable, es que los requisitos posean las siguientes características:

- **Corrección:** La ERS es correcta si y solo si todo requisito que figura aquí (y que sera implementado en el sistema) refleja alguna necesidad real. La corrección de la ERS implica que el sistema implementado sera el sistema deseado.
- **No ambiguos:** Cada requisito tiene una sola interpretación. Para eliminar la ambigüedad inherente a los requisitos expresados en lenguaje natural, se deberán utilizar gráficos o notaciones formales. En el caso de utilizar términos que, habitualmente, poseen más de una interpretación, se definirán con precisión en el glosario.
- **Completos:** Todos los requisitos relevantes han sido incluidos en la ERS. Conviene incluir todas las posibles respuestas del sistema a los datos de entrada, tanto válidos como no válidos.
- **Consistentes:** Los requisitos no pueden ser contradictorios. Un conjunto de requisitos contradictorio no es implementable.
- **Clasificados:** Normalmente, no todos los requisitos son igual de importantes. Los requisitos pueden clasificarse por importancia (esenciales, condicionales u opcionales) o por estabilidad (cambios que se espera que afecten al requisito). Esto sirve, ante todo, para no emplear excesivos recursos en implementar requisitos no esenciales.
- **Verificables:** La ERS es verificable si y solo si todos sus requisitos son verificables. Un requisito es verificable (testable) si existe un proceso finito y no costoso para demostrar que el sistema cumple con el requisito. Un requisito ambiguo no es, en general, verificable. Expresiones como a veces, bien, adecuado, etc. introducen ambigüedad en los requisitos. Requisitos como “en caso de accidente la nube toxica no se extenderá más allá de 25Km” no es verificable por el alto costo que conlleva.
- **Modificables:** La ERS es modificable si y solo si se encuentra estructurada de forma que los cambios a los requisitos pueden realizarse de forma fácil, completa y consistente. La

utilización de herramientas automáticas de gestión de requisitos (por ejemplo, RequisitePro o Doors) facilitan enormemente esta tarea.

- **Trazables:** La ERS es trazable si se conoce el origen de cada requisito y se facilita la referencia de cada requisito a los componentes del diseño y de la implementación. La trazabilidad hacia atrás indica el origen (documento, persona, etc.) de cada requisito. La trazabilidad hacia delante de un requisito R indica que componentes del sistema son los que realizan el requisito.

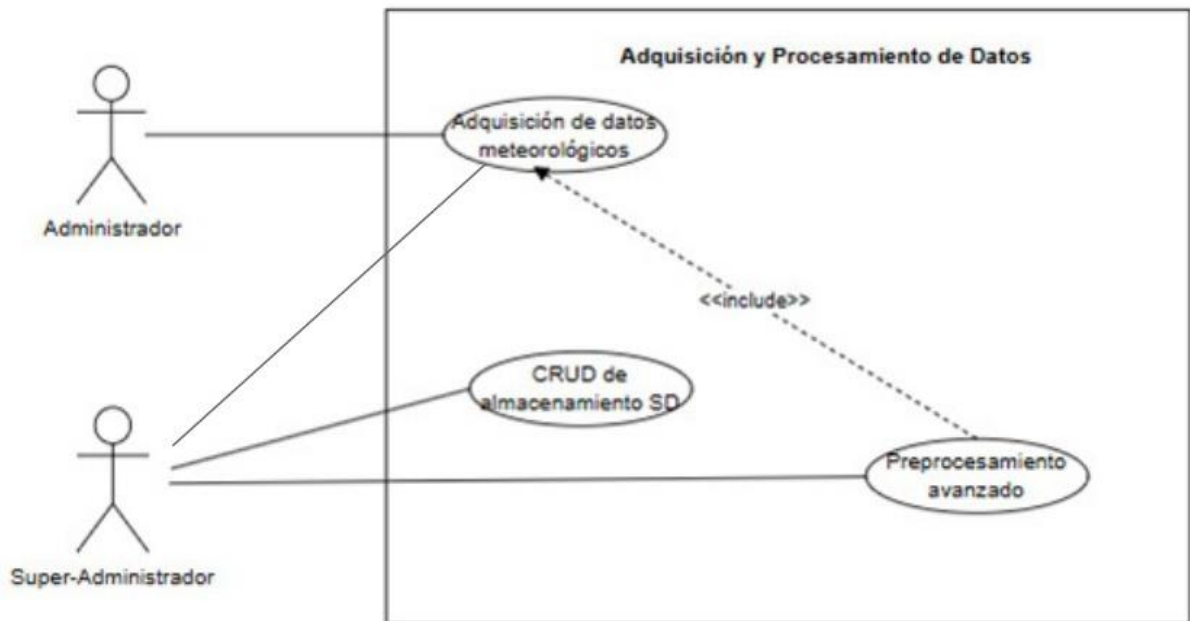
2.3. Especificación del Diseño

2.3.1. Diagramas de Casos de Uso

2.3.1.1. Caso de Uso Adquisición y Procesamiento de Datos

Figura 13

Diagrama de Casos de Uso Adquisición y Procesamiento de Datos



Descripción del Diagrama de Casos de Uso: Adquisición y Procesamiento de Datos

Este diagrama muestra la interacción de dos actores principales con el sistema de Adquisición y Procesamiento de Datos:

1. Actores:

- Administrador: Tiene acceso al caso de uso "Adquisición de datos meteorológicos".
- Super-Administrador: Tiene acceso tanto al caso de uso "CRUD de almacenamiento SD" como al de "Adquisición de datos meteorológicos" (por herencia del rol de Administrador).

2. Casos de Uso:

- Adquisición de datos meteorológicos: Permite la obtención de información del clima.
- CRUD de almacenamiento SD: Permite crear, leer, actualizar y eliminar datos del almacenamiento SD.
- Preprocesamiento avanzado: Caso de uso incluido dentro de "Adquisición de datos meteorológicos", lo que indica que siempre que se adquieran datos meteorológicos, se realiza un preprocesamiento avanzado como parte del proceso.

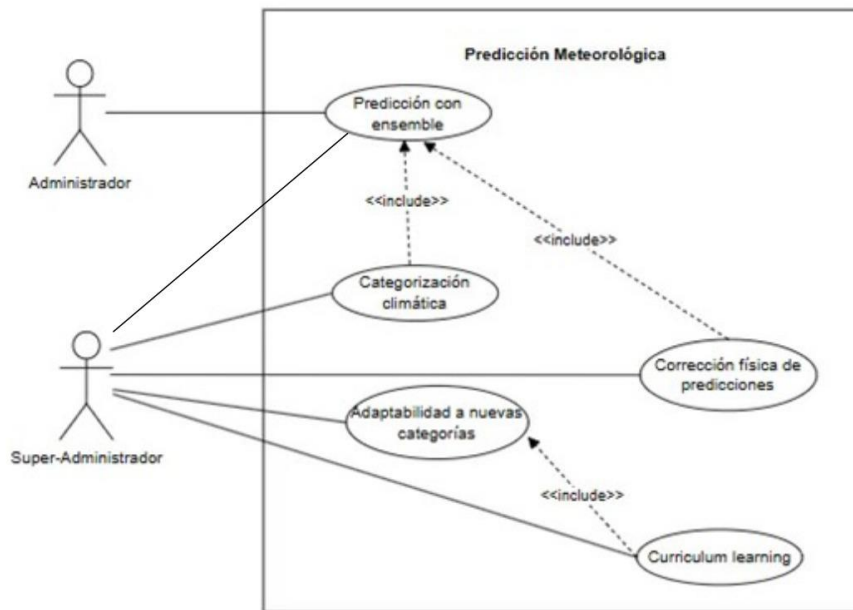
3. Relaciones:

- El caso de uso "Adquisición de datos meteorológicos" incluye ("<<include>>") al caso de uso "Preprocesamiento avanzado", lo que significa que este último se ejecuta como parte del primero.
- El Super-Administrador hereda los permisos del Administrador, representado mediante una flecha hacia arriba.

2.3.1.2 Caso de Uso Predicción Meteorológica

Figura 14

Diagrama de Casos de Uso Predicción Meteorológica



Descripción del Diagrama de Casos de Uso: Predicción Meteorológica

Este diagrama representa cómo los actores interactúan con el sistema de Predicción Meteorológica a través de varios casos de uso especializados.

Actores:

- **Administrador:** Puede ejecutar el caso de uso principal "Predicción con ensemble".
- **Super-Administrador:** Además de acceder a las funciones del Administrador, tiene acceso a casos de uso más avanzados como "Adaptabilidad a nuevas categorías".

Casos de Uso Principales:

1. **Predicción con ensemble:** Método central del sistema para generar pronósticos meteorológicos. Este caso de uso incluye:
 - Categorización climática
 - Corrección física de predicciones
2. **Categorización climática:** Clasificación de condiciones meteorológicas, incluida en la predicción con ensemble.
3. **Corrección física de predicciones:** Ajuste de los pronósticos mediante modelos físicos, también incluido dentro de "Predicción con ensemble".
4. **Adaptabilidad a nuevas categorías:** Permite al sistema adaptarse a nuevas condiciones o categorías climáticas, exclusivo del Super-Administrador. Este caso incluye:
 - **Curriculum learning:** Técnica de aprendizaje que permite mejorar la adaptación a nuevas condiciones mediante entrenamiento progresivo.

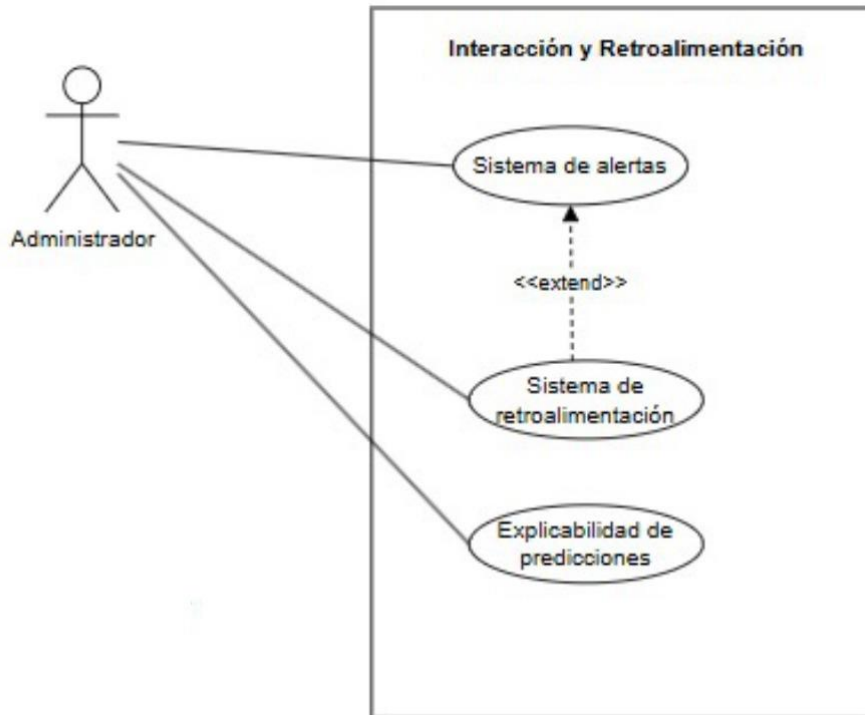
Relaciones:

- Las relaciones <<include>> indican que ciertos casos de uso son necesarios como parte de otros.
- El Super-Administrador hereda funcionalidades del Administrador, lo cual está implícito en la diagramación.

2.3.1.3 Caso de Uso Interacción y Retroalimentación

Figura 15

Diagrama de Caso de Uso Interacción y Retroalimentación



Descripción del Diagrama de Casos de Uso: Interacción y Retroalimentación

Este diagrama muestra las funcionalidades del sistema que permiten la interacción del usuario (Administrador) con los resultados del sistema y la retroalimentación sobre estos.

Actor:

- **Administrador:** Es el único actor involucrado y tiene acceso directo a los tres casos de uso representados.

Casos de Uso:

1. **Sistema de retroalimentación:** Permite al Administrador proporcionar información o comentarios sobre los resultados del sistema. Este caso de uso puede extenderse para incluir:
 - **Sistema de alertas:** Funcionalidad adicional que puede activarse dentro del sistema de retroalimentación, por ejemplo, para notificar condiciones críticas detectadas por los usuarios.
2. **Sistema de alertas:** Caso de uso opcional que se activa como extensión del sistema de retroalimentación. Se representa mediante una relación <<extend>>.
3. **Explicabilidad de predicciones:** Proporciona interpretaciones o justificaciones de los resultados del sistema predictivo, para una mejor comprensión por parte del Administrador.

Relaciones:

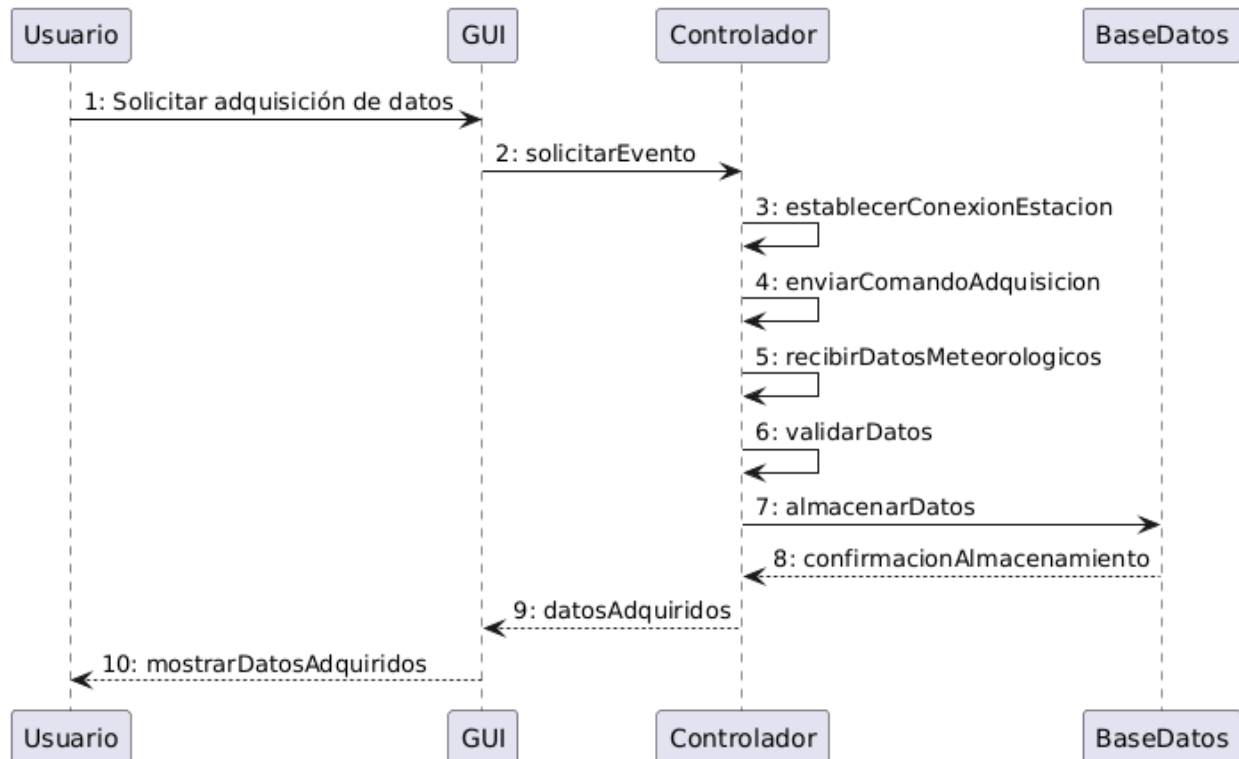
- La relación <<extend>> indica que el "Sistema de alertas" es una funcionalidad que se puede activar desde el "Sistema de retroalimentación", pero no es obligatoria para que este último funcione.

2.3.2. Diagrama de Secuencia

2.3.2.1. Secuencia de Adquisición de datos meteorológicos

Figura 16

Diagrama de Secuencia de Adquisición de datos meteorológicos



Descripción del Diagrama de Secuencia: Adquisición de datos meteorológicos

Este diagrama ilustra el flujo de interacción entre los distintos componentes del sistema durante el proceso de adquisición de datos meteorológicos. Se destacan cuatro participantes:

Participantes:

- **Usuario:** Inicia la solicitud de adquisición de datos.
- **GUI (Interfaz Gráfica de Usuario):** Intermediario entre el usuario y el sistema.
- **Controlador:** Encargado de gestionar la lógica del proceso de adquisición.
- **BaseDatos:** Responsable del almacenamiento de los datos recibidos.

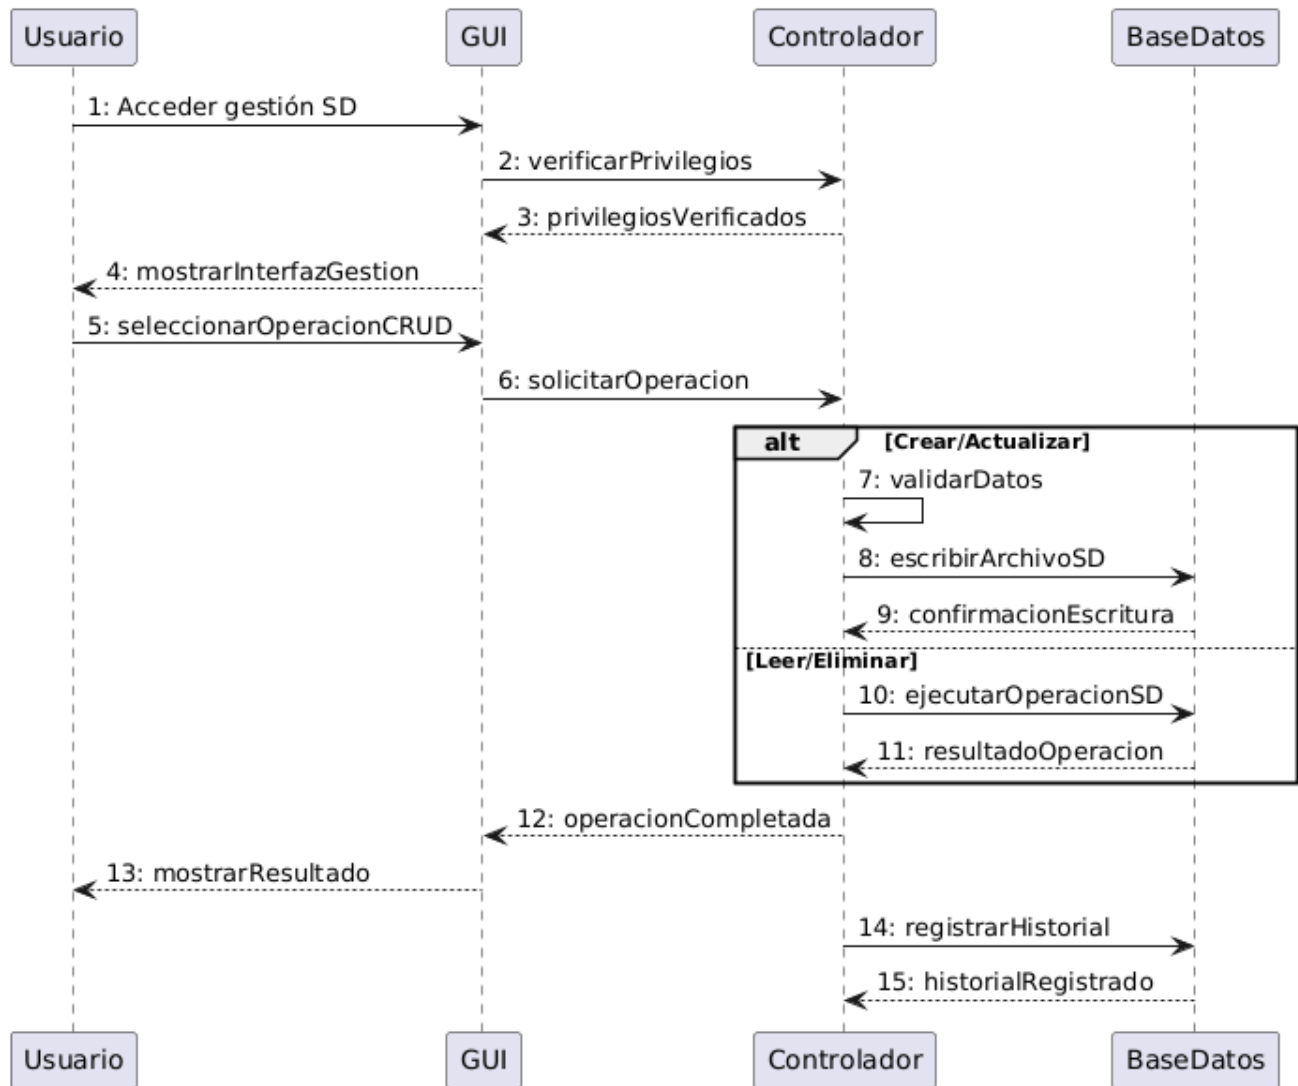
Secuencia de Mensajes:

1. **Usuario** → **GUI:** Solicita la adquisición de datos meteorológicos.
2. **GUI** → **Controlador:** Envía un evento para iniciar el proceso.
3. **Controlador:** Establece conexión con la estación meteorológica.
4. **Controlador:** Envía el comando para iniciar la adquisición de datos.
5. **Controlador:** Recibe los datos meteorológicos desde la estación.
6. **Controlador:** Valida los datos adquiridos.
7. **Controlador** → **BaseDatos:** Solicita almacenar los datos validados.
8. **BaseDatos** → **Controlador:** Confirma que los datos fueron almacenados exitosamente.
9. **Controlador** → **GUI:** Informa que los datos han sido adquiridos.
10. **GUI** → **Usuario:** Muestra los datos adquiridos.

2.3.2.2. Secuencia de CRUD de Almacenamiento SD

Figura 17

Diagrama de Secuencia de CRUD de Almacenamiento SD



Descripción del Diagrama de Secuencia: CRUD de Almacenamiento SD

Este diagrama describe la secuencia de pasos para realizar operaciones de gestión (crear, leer, actualizar o eliminar) sobre el almacenamiento SD, a través de una interfaz gráfica y validación de privilegios.

Participantes:

- **Usuario:** Inicia y supervisa la operación.
- **GUI (Interfaz Gráfica):** Intermediario de la interacción usuario-sistema.
- **Controlador:** Lógica de negocio y gestión de operaciones.
- **BaseDatos:** Encargada del registro histórico de las operaciones.

Secuencia de Pasos:

1. **Usuario** → **GUI:** Solicita acceder a la gestión del almacenamiento SD.

Sistema Computacional Inteligente

2. **GUI** → **Controlador**: Verifica los privilegios del usuario.
3. **Controlador** → **GUI**: Responde con los privilegios verificados.
4. **GUI**: Muestra la interfaz de gestión.
5. **Usuario** → **GUI**: Selecciona la operación CRUD a realizar.
6. **GUI** → **Controlador**: Solicita la ejecución de la operación seleccionada.

Bloque condicional (alt) – Selección entre Crear/Actualizar o Leer/Eliminar:

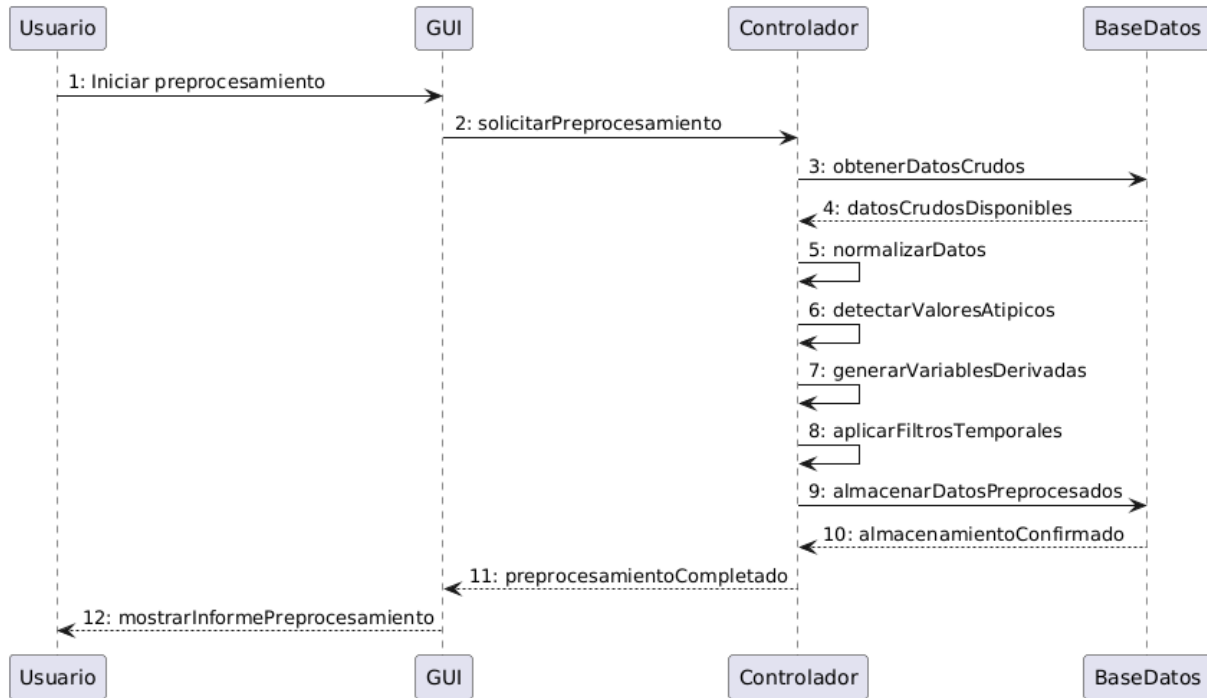
- **[Crear/Actualizar]:**
 7. Validar datos.
 8. Escribir archivo en SD.
 9. Confirmación de escritura.
 10. Resultado de la operación.
 - **[Leer/Eliminar]:**
 11. Ejecutar la operación en SD.
 12. Resultado de la operación.
13. **Controlador** → **GUI**: Informa que la operación se ha completado.
 14. **Controlador** → **BaseDatos**: Registra la operación en el historial.
 15. **BaseDatos** → **Controlador**: Confirma el registro en el historial.

GUI → **Usuario**: Muestra el resultado final de la operación.

2.3.2.3. Secuencia de Procesamiento avanzado

Figura 18

Diagrama de Secuencia de Procesamiento avanzado



Este diagrama de secuencia describe el flujo del proceso de **preprocesamiento de datos meteorológicos**. El usuario inicia el proceso, tras lo cual el sistema:

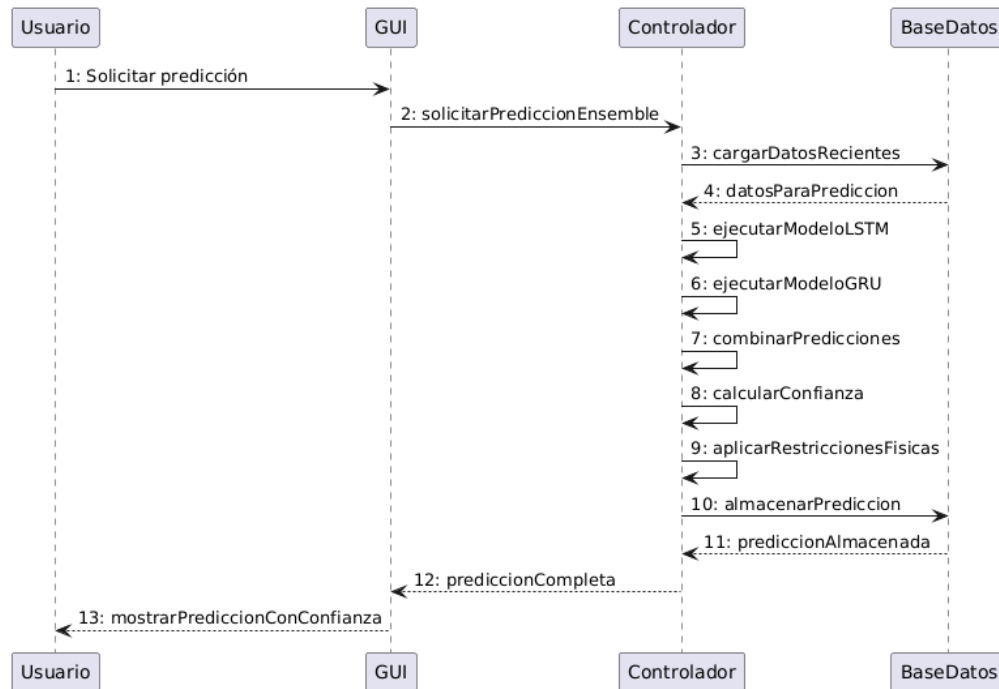
1. Obtiene los datos crudos desde la base de datos.
2. Aplica varias etapas de transformación, incluyendo:
 - Normalización de datos.
 - Detección y ajuste de valores atípicos.
 - Generación de variables derivadas.
 - Filtros temporales.
3. Almacena los datos preprocesados.
4. Finaliza mostrando un informe al usuario.

El diagrama refleja un flujo automatizado para preparar los datos antes de su análisis o modelado.

2.3.2.4. Secuencia de Predicción con Ensemble

Figura 19

Diagrama de Secuencia de Predicción con Ensemble



Descripción del Diagrama de Secuencia: Predicción con Ensemble

Este diagrama representa el flujo de interacción entre los componentes del sistema para realizar una **predicción meteorológica utilizando un enfoque de Ensemble**, que combina múltiples modelos para aumentar la precisión.

Participantes:

- **Usuario:** Solicita la predicción.
- **GUI:** Recibe la solicitud del usuario y la envía al sistema.
- **Controlador:** Orquesta el proceso de predicción.
- **BaseDatos:** Fuente y destino de datos meteorológicos.

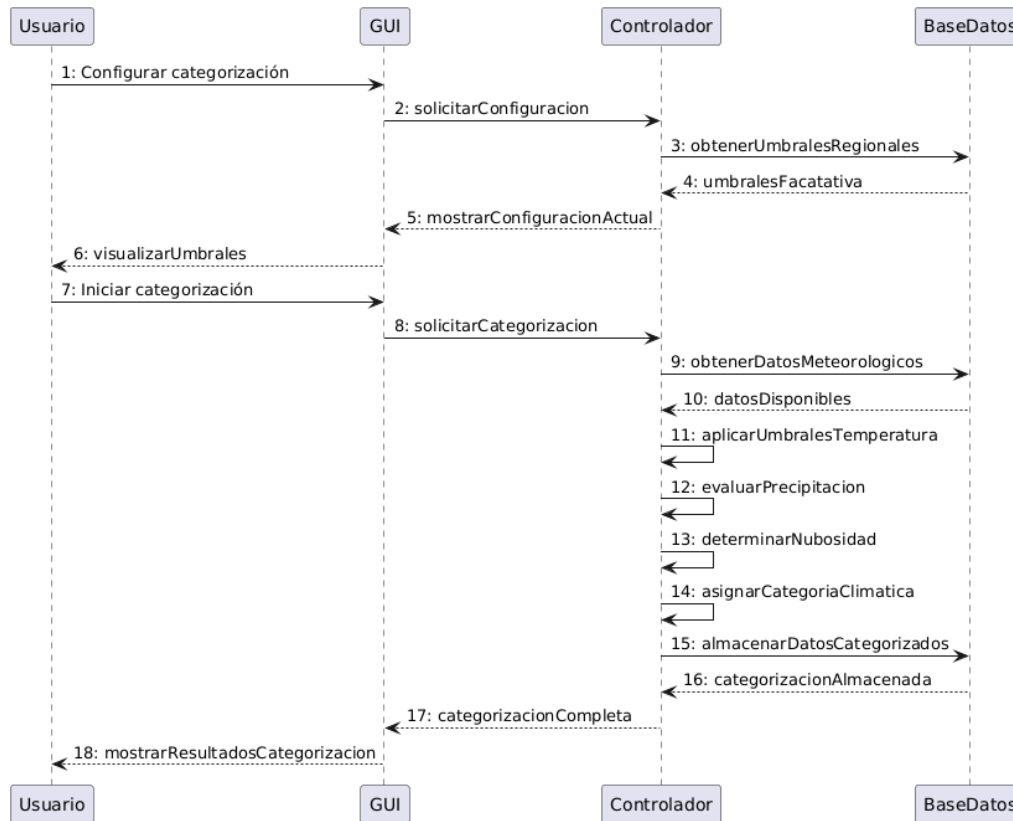
Secuencia de Pasos:

1. **Usuario** → **GUI:** Solicita una predicción meteorológica.
2. **GUI** → **Controlador:** Solicita la predicción usando Ensemble.
3. **Controlador** → **BaseDatos:** Carga datos meteorológicos recientes.
4. **BaseDatos** → **Controlador:** Devuelve los datos necesarios para la predicción.
5. **Controlador:** Ejecuta el modelo de predicción **LSTM** (red neuronal recurrente).
6. **Controlador:** Ejecuta el modelo **GRU** (otro tipo de red recurrente).
7. **Controlador:** Combina las predicciones de ambos modelos (Ensemble).
8. **Controlador:** Calcula el nivel de confianza de la predicción combinada.
9. **Controlador:** Aplica restricciones físicas para mejorar la coherencia de la predicción.
10. **Controlador** → **BaseDatos:** Almacena la predicción final.
11. **BaseDatos** → **Controlador:** Confirma que la predicción ha sido almacenada.
12. **Controlador** → **GUI:** Informa que la predicción está completa.
13. **GUI** → **Usuario:** Muestra la predicción junto con su nivel de confianza.

2.3.2.5. Secuencia de Categorización Climática

Figura 20

Diagrama de Secuencia de Categorización Climática



Descripción del Diagrama de Secuencia: Categorización Climática

Este diagrama representa el flujo de interacción entre los componentes del sistema para realizar la **categorización climática automática**, clasificando las condiciones meteorológicas según umbrales predefinidos y criterios regionales específicos para generar categorías climáticas precisas.

Participantes:

- **Usuario:** Configura los parámetros de categorización e inicia el proceso de clasificación.
- **GUI:** Interfaz que gestiona la configuración de umbrales y presenta los resultados de categorización.
- **Controlador:** Ejecuta la lógica de categorización aplicando umbrales y criterios climáticos.
- **BaseDatos:** Fuente de datos meteorológicos y repositorio de umbrales regionales y resultados.

Secuencia de Pasos:

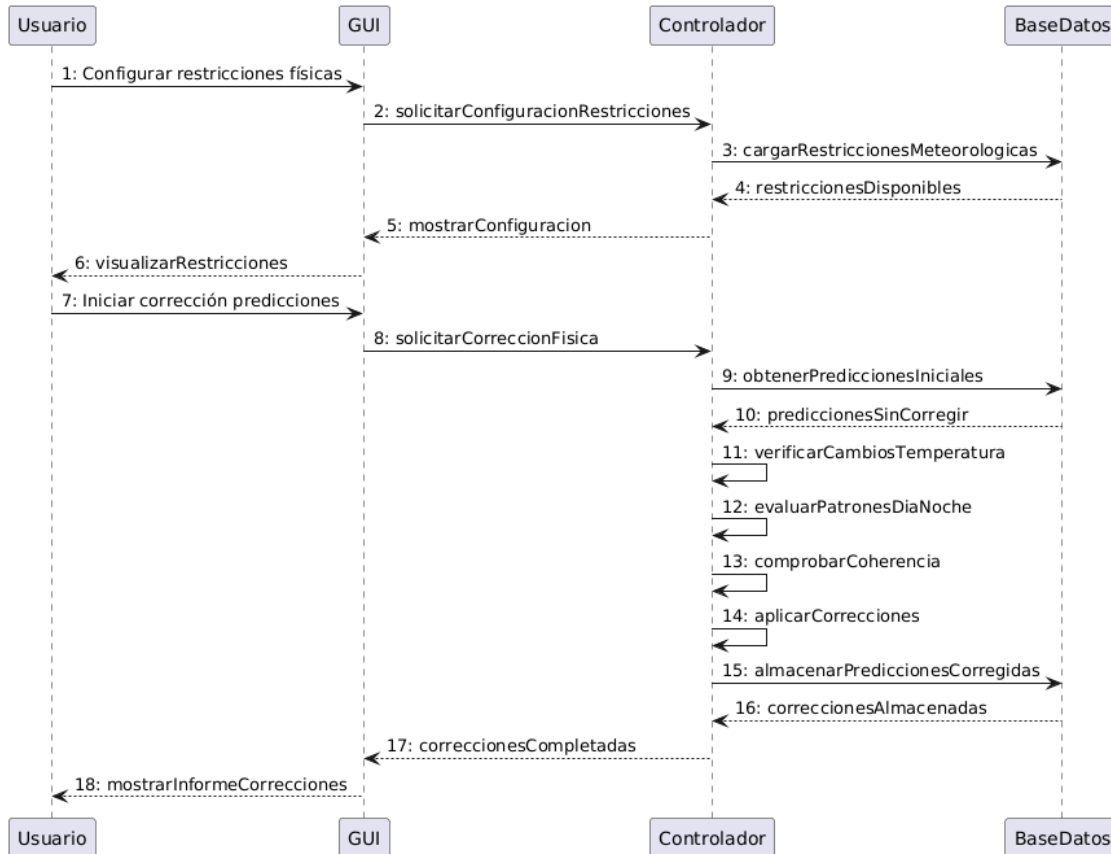
Fase de Configuración (Pasos 1-6):

1. **Usuario** → **GUI:** Configura los parámetros de categorización climática.
2. **GUI** → **Controlador:** Solicita la configuración actual del sistema.
3. **Controlador** → **BaseDatos:** Obtiene los umbrales regionales predefinidos.
4. **BaseDatos** → **Controlador:** Proporciona los umbrales específicos por región (temperatura, precipitación, etc.).
5. **Controlador** → **GUI:** Muestra la configuración actual de umbrales.
6. **GUI** → **Usuario:** Visualiza los umbrales configurados para validación.

2.3.2.6. Secuencia de Corrección Física de Predicciones

Figura 21

Diagrama de Secuencia de Corrección Física de Predicciones



Descripción del Diagrama de Secuencia: Corrección Física de Predicciones

Este diagrama representa el flujo de interacción entre los componentes del sistema para realizar la **corrección física de predicciones meteorológicas**, aplicando restricciones y validaciones basadas en principios físicos para mejorar la coherencia y precisión de las predicciones.

Participantes:

- **Usuario:** Inicia y configura el proceso de corrección física.
- **GUI:** Interfaz que recibe las solicitudes del usuario y muestra los resultados.
- **Controlador:** Orquesta todo el proceso de corrección y validación física.
- **BaseDatos:** Almacena las predicciones originales y las corregidas.

Secuencia de Pasos:

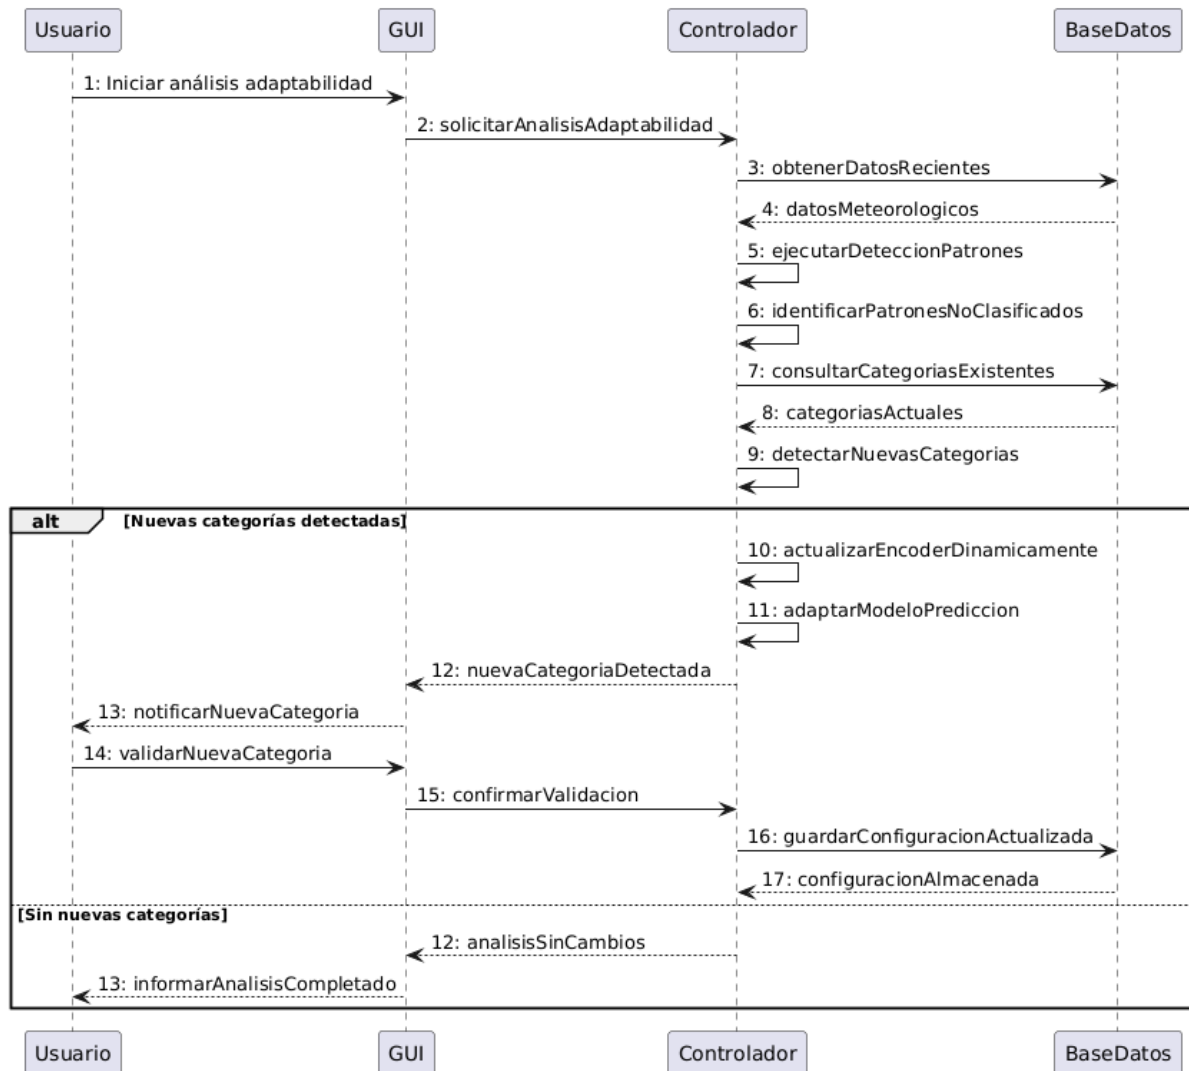
Fase de Configuración (Pasos 1-6):

1. **Usuario** → **GUI:** Configura restricciones físicas para el proceso de corrección.
2. **GUI** → **Controlador:** Solicita la configuración de restricciones disponibles.
3. **Controlador** → **BaseDatos:** Configura las restricciones meteorológicas en el sistema.
4. **BaseDatos** → **Controlador:** Devuelve las restricciones disponibles configuradas.
5. **Controlador** → **GUI:** Muestra la configuración actual de restricciones.
6. **GUI** → **Usuario:** Visualiza las restricciones físicas configuradas.

2.3.2.7. Secuencia de Adaptabilidad a Nuevas Categorías

Figura 22

Diagrama de Secuencia de Adaptabilidad a Nuevas Categorías



Descripción. Este es un **diagrama de secuencia UML** que describe el flujo del proceso de análisis de adaptabilidad en un sistema con interacción entre un usuario, la interfaz gráfica (GUI), un controlador y la base de datos. El diagrama muestra cómo el sistema:

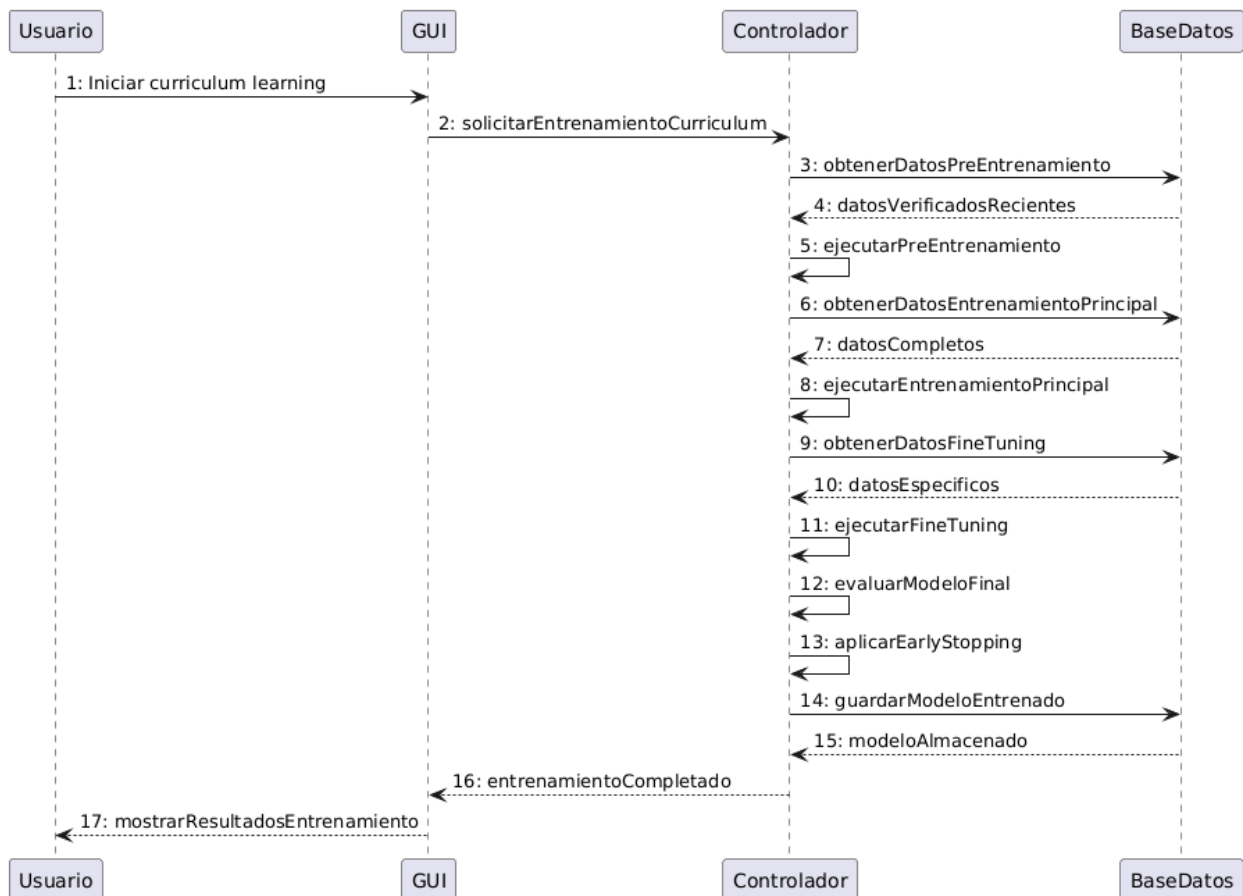
1. **Inicia el análisis** con datos meteorológicos recientes.
2. **Detecta patrones y nuevas categorías** si las hay.
3. **Actualiza el modelo predictivo** si se detectan nuevas categorías.
4. **Valida y almacena la configuración** si hubo cambios.
5. **Notifica al usuario** si hubo nuevas categorías o simplemente informa la finalización del análisis.

Este proceso ayuda a adaptar dinámicamente el sistema a nuevos patrones meteorológicos.

2.3.2.8. Secuencia de Curriculum Learning

Figura 23

Diagrama de Secuencia de Curriculum Learning



Este es un **diagrama de secuencia UML** que describe el proceso de entrenamiento de un modelo mediante **curriculum learning**, involucrando a un usuario, una interfaz gráfica (GUI), un controlador y la base de datos. El flujo incluye:

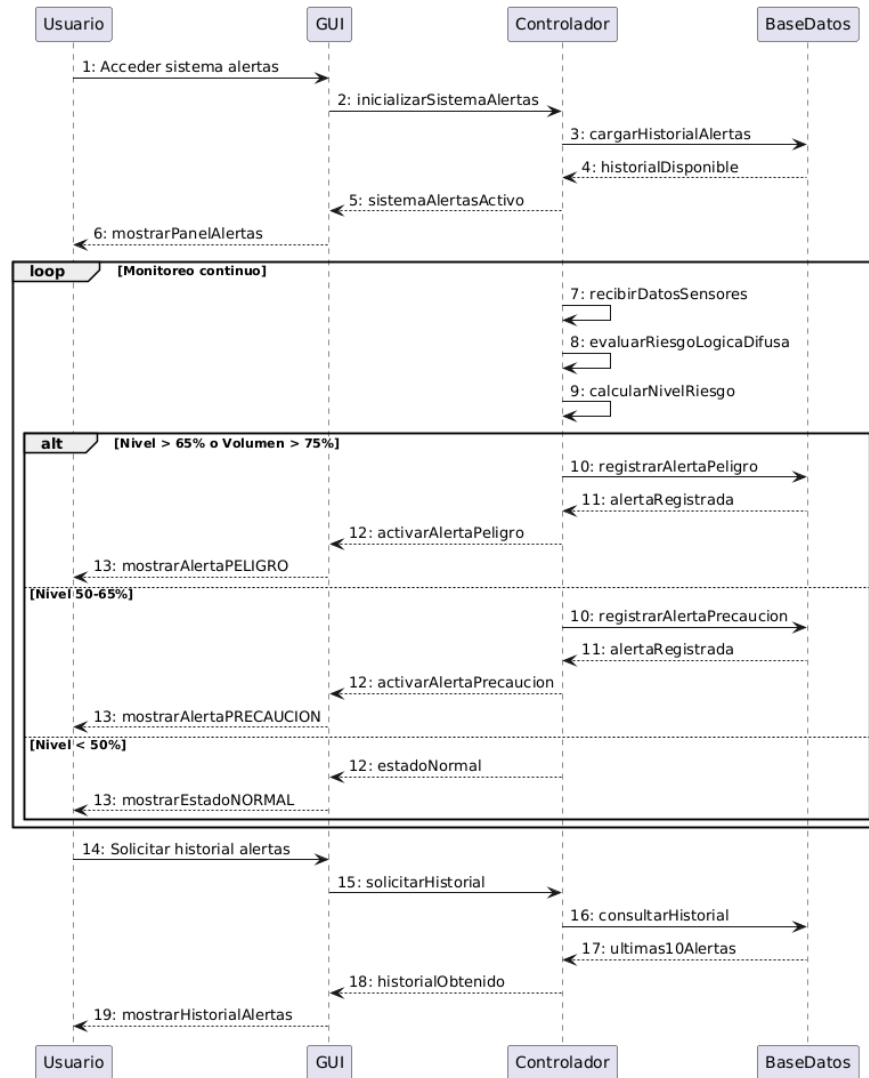
1. **Inicio del entrenamiento** por parte del usuario.
2. **Fases secuenciales de entrenamiento:**
 - Preentrenamiento con datos verificados.
 - Entrenamiento principal con datos completos.
 - Fine-tuning (ajuste fino) con datos específicos.
3. **Evaluación y ajuste del modelo final**, incluyendo Early Stopping.
4. **Almacenamiento del modelo entrenado** y **visualización de resultados** al usuario.

Este enfoque permite entrenar modelos de forma progresiva y optimizada, facilitando una mejor generalización del aprendizaje.

2.3.2.9. Secuencia de Sistema de Alertas

Figura 24

Diagrama de Secuencia de Sistema de Alertas



Este es un **diagrama de secuencia UML** que describe el flujo de funcionamiento del **sistema de alertas** en una aplicación de monitoreo, con interacción entre el usuario, la GUI, el controlador y la base de datos. El proceso incluye:

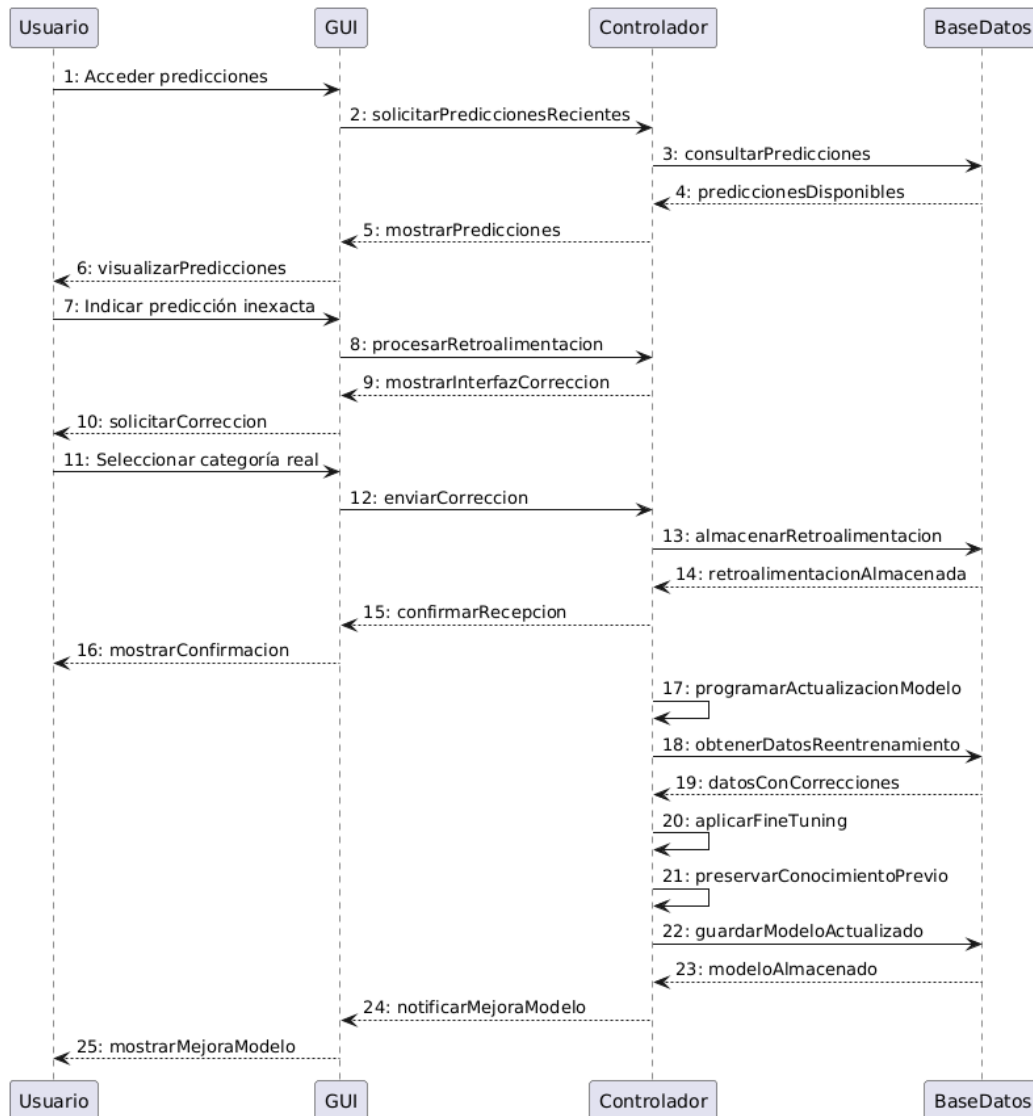
1. **Inicio del sistema de alertas** y carga del historial previo.
2. **Monitoreo continuo** de datos provenientes de sensores.
3. **Evaluación del riesgo** mediante lógica difusa y cálculo del nivel.
4. **Generación y visualización de alertas** según el nivel de riesgo: **PELIGRO** si el nivel > 65% o volumen > 75%. **PRECAUCIÓN** si el nivel está entre 50% y 65%. **NORMAL** si el nivel < 50%.
5. **Registro de las alertas** en la base de datos.
6. **Consulta y visualización del historial de alertas** a petición del usuario.

Este diagrama muestra cómo el sistema responde dinámicamente al análisis de datos ambientales para advertir al usuario en tiempo real.

2.3.2.10. Secuencia de Sistemas de Retroalimentación

Figura 25

Diagrama de Secuencia de Sistemas de Retroalimentación



Este **diagrama de secuencia UML** describe el proceso de gestión de **predicciones y corrección supervisada** en un sistema inteligente, involucrando al usuario, la GUI, el controlador y la base de datos. El flujo abarca:

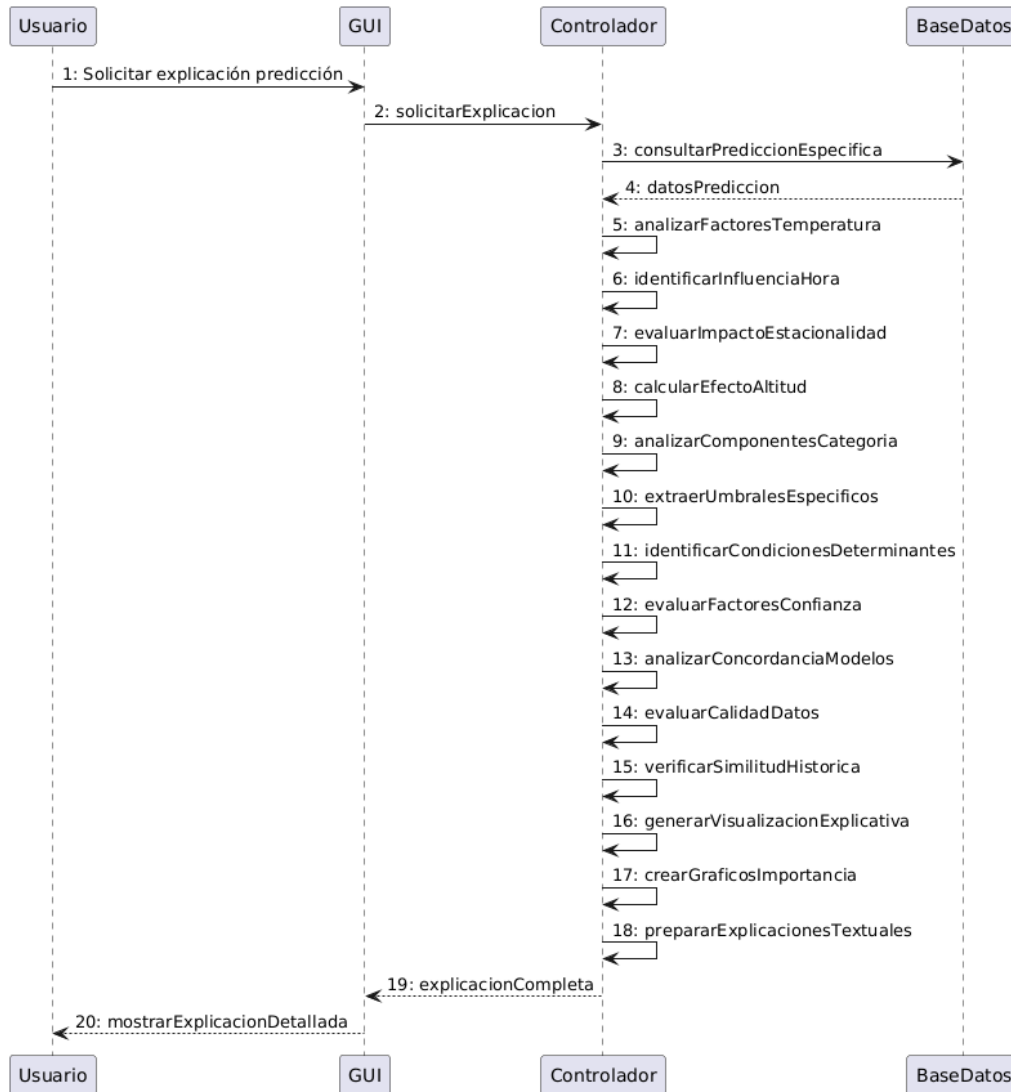
1. **Acceso y visualización de predicciones** recientes por parte del usuario.
2. **Corrección de errores** cuando una predicción es inexacta:
 - El usuario selecciona la categoría correcta.
 - El sistema procesa y almacena la retroalimentación.
3. **Reentrenamiento del modelo** mediante fine-tuning con nuevos datos corregidos, preservando el conocimiento previo.
4. **Notificación y visualización** de las mejoras del modelo al usuario.

Este flujo permite mejorar continuamente el modelo predictivo a través de la participación activa del usuario, promoviendo el aprendizaje supervisado y adaptativo.

2.3.2.11. Secuencia de Explicabilidad de Predicciones

Figura 26

Diagrama de Secuencia de Explicabilidad de Predicciones



Este **diagrama de secuencia UML** describe el flujo para **obtener una explicación detallada de una predicción** realizada por el sistema, con interacción entre el usuario, la GUI, el controlador y la base de datos. El proceso incluye:

1. **Solicitud del usuario** para entender cómo se generó una predicción.
2. **Consulta y análisis detallado** de factores que influyeron en la predicción, como:
 - Temperatura, hora, estacionalidad y altitud.
 - Componentes de categoría y condiciones determinantes.
 - Concordancia de modelos, confianza, calidad de datos y similitud histórica.
3. **Generación de explicaciones visuales y textuales**, incluyendo gráficos de importancia.
4. **Entrega al usuario** de una explicación clara y comprensible de la predicción.

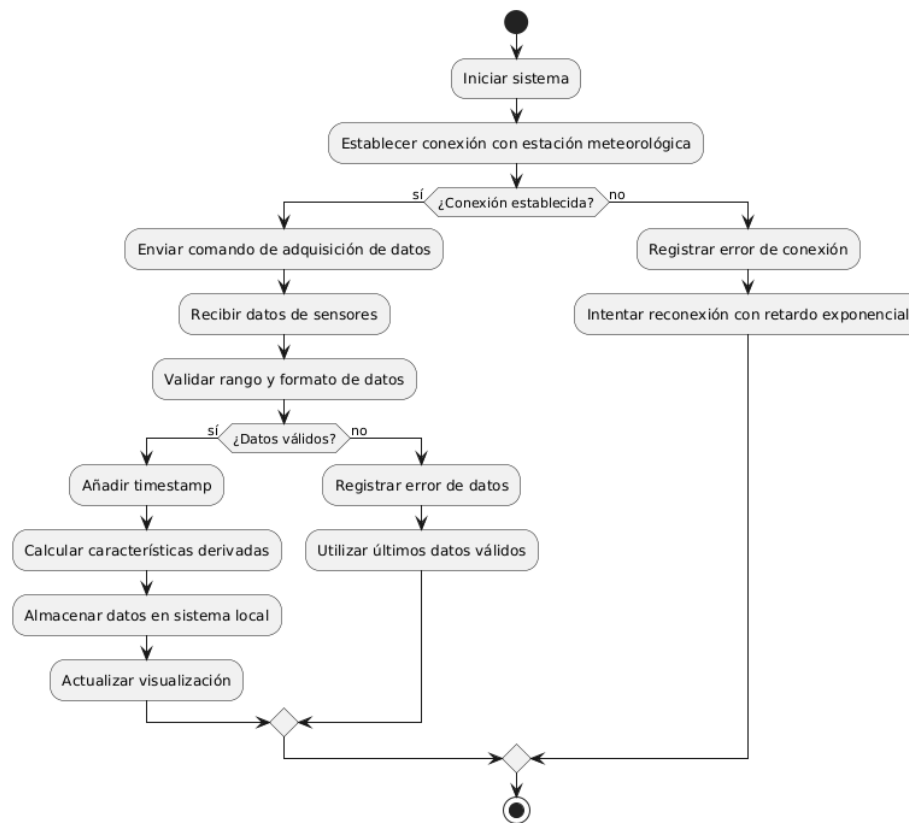
Este flujo permite mejorar la **transparencia y confianza** en los sistemas predictivos al proporcionar justificaciones interpretables sobre su funcionamiento.

2.3.3. Diagrama de Actividades

2.3.3.1 Actividad de Adquisición de datos meteorológicos

Figura 27

Diagrama de Actividad de Adquisición de datos meteorológicos



Este es un diagrama de flujo que describe el proceso de inicio y adquisición de datos desde una estación meteorológica. El flujo incluye:

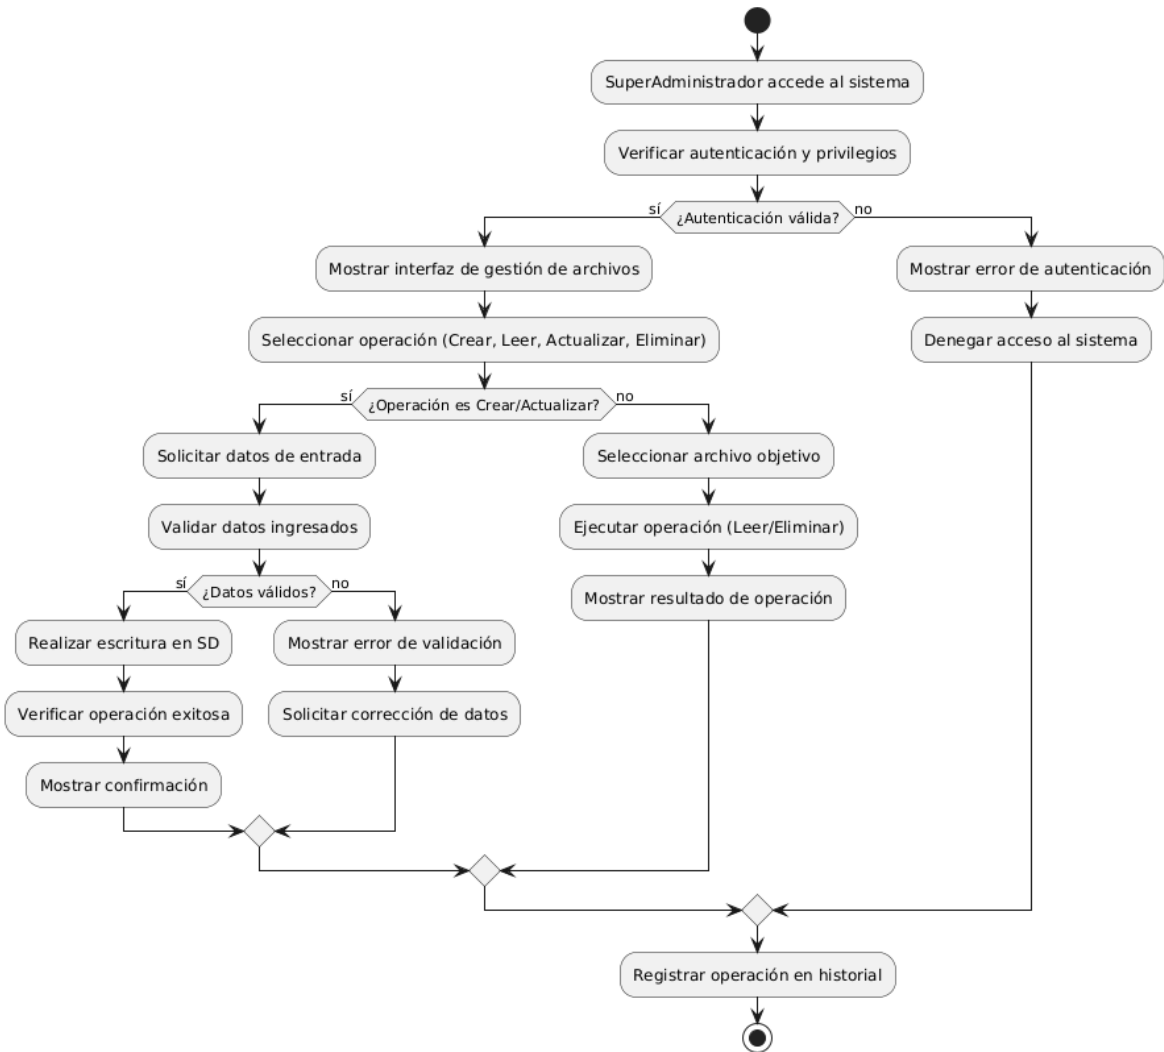
1. Inicio del sistema y establecimiento de conexión con la estación.
 - Si la conexión falla, se registra el error e intenta reconectar con retardo exponencial.
2. Si la conexión es exitosa:
 - Se envía un comando de adquisición y se reciben datos de sensores.
 - Se valida el rango y formato de los datos:
 - Si son válidos: se añade timestamp, se calculan características derivadas, se almacenan y se actualiza la visualización.
 - Si no son válidos: se registra un error y se utilizan los últimos datos válidos.

Este flujo garantiza una operación robusta del sistema ante errores de conexión o adquisición, asegurando la continuidad del monitoreo

2.3.3.2. Actividad de CRUD de Almacenamiento SD

Figura 28

Diagrama de Actividad de CRUD de Almacenamiento SD



Este es un **diagrama de flujo** que representa el proceso de gestión de archivos por parte de un **SuperAdministrador** en un sistema con autenticación y privilegios. El flujo contempla:

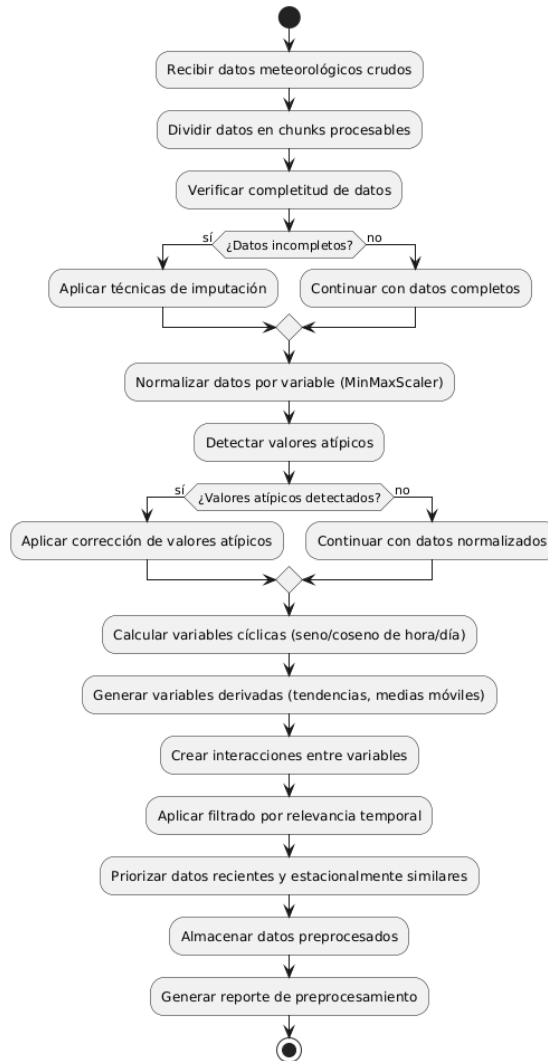
1. **Acceso del SuperAdministrador al sistema y verificación de autenticación.**
 - Si la autenticación falla, se muestra un error y se **deniega el acceso**.
2. Si es válida: Se muestra la interfaz de gestión de archivos. El usuario selecciona una operación: **Crear, Leer, Actualizar o Eliminar**.
3. Si la operación es **Crear/Actualizar**: Se solicitan y validan datos de entrada. Si los datos son válidos, se realiza la escritura, se verifica el éxito y se muestra una confirmación. Si no, se solicita corrección.
4. Si la operación es **Leer/Eliminar**:
 - Se selecciona el archivo objetivo y se ejecuta la acción, mostrando el resultado.
5. Finalmente, **toda operación se registra en el historial**, garantizando trazabilidad.

Este diagrama refleja un flujo de control robusto con validaciones, manejo de errores y registro de actividades administrativas

2.3.3.3 Actividad de Procesamiento Avanzado

Figura 29

Diagrama de actividad de Actividad de procesamiento Avanzado



Este es un **diagrama de flujo de preprocesamiento de datos meteorológicos**, que detalla los pasos para preparar datos crudos antes de usarlos en modelos o análisis. El flujo incluye:

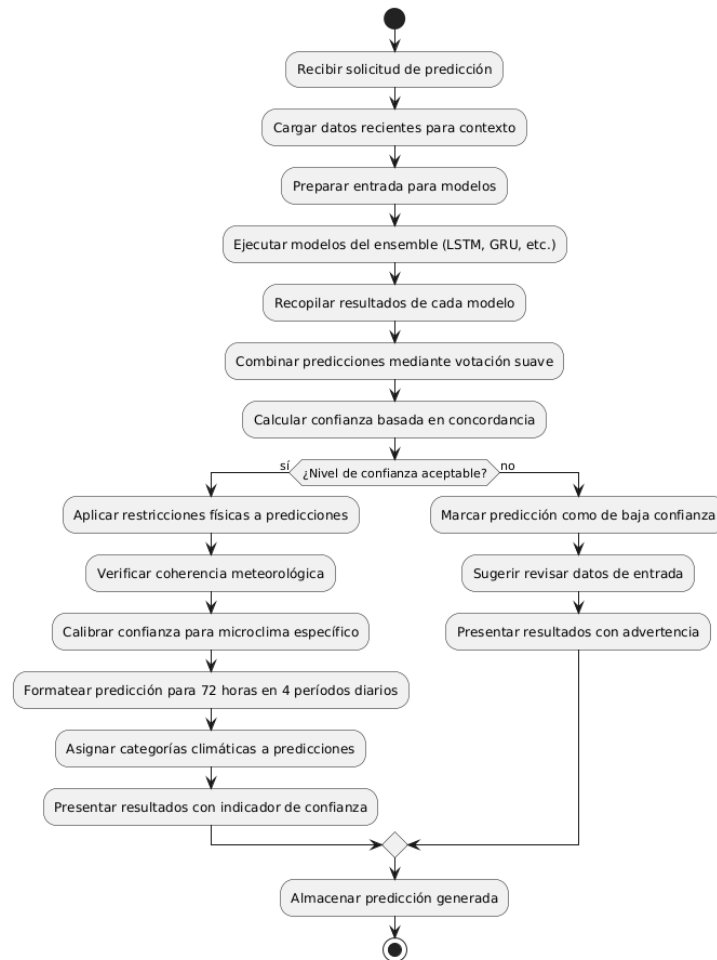
1. **Recepción y división de datos** en bloques procesables.
2. **Verificación de completitud**: Si hay datos incompletos, se aplican **técnicas de imputación**.
3. **Normalización por variable** usando MinMaxScaler.
4. **Detección y corrección de valores atípicos**, si los hay.
5. **Enriquecimiento de los datos**: Cálculo de **variables cíclicas** (ej. hora/día). Generación de **variables derivadas** (tendencias, medias móviles). Creación de **interacciones entre variables**.
6. **Filtrado por relevancia temporal** y prioridad a datos recientes o con estacionalidad similar.
7. **Almacenamiento y generación de reporte** de preprocesamiento.

Este proceso asegura que los datos estén limpios, enriquecidos y listos para su uso en análisis o modelos predictivos.

2.3.3.4 Actividad de Predicción con Ensemble

Figura 30

Diagrama de Actividad de Predicción con Ensemble



Este es un **diagrama de flujo** que representa el proceso de **generación de predicciones meteorológicas mediante modelos de ensemble**. El flujo incluye:

1. **Recepción de la solicitud y preparación del contexto** con datos recientes.
2. **Ejecución de múltiples modelos** (como LSTM, GRU) y recopilación de sus resultados.
3. **Combinación de predicciones** mediante votación suave y cálculo de **nivel de confianza**.

Según el nivel de confianza:

- **Si es aceptable:** Se aplican restricciones físicas, se verifica la coherencia meteorológica y se calibra para el microclima. La predicción se **formatea para 72 horas en 4 periodos diarios**, se asignan categorías climáticas y se presentan resultados con indicador de confianza.
- **Si no es aceptable:** Se marca la predicción como de baja confianza, se sugiere revisar datos y se presentan resultados con advertencias.

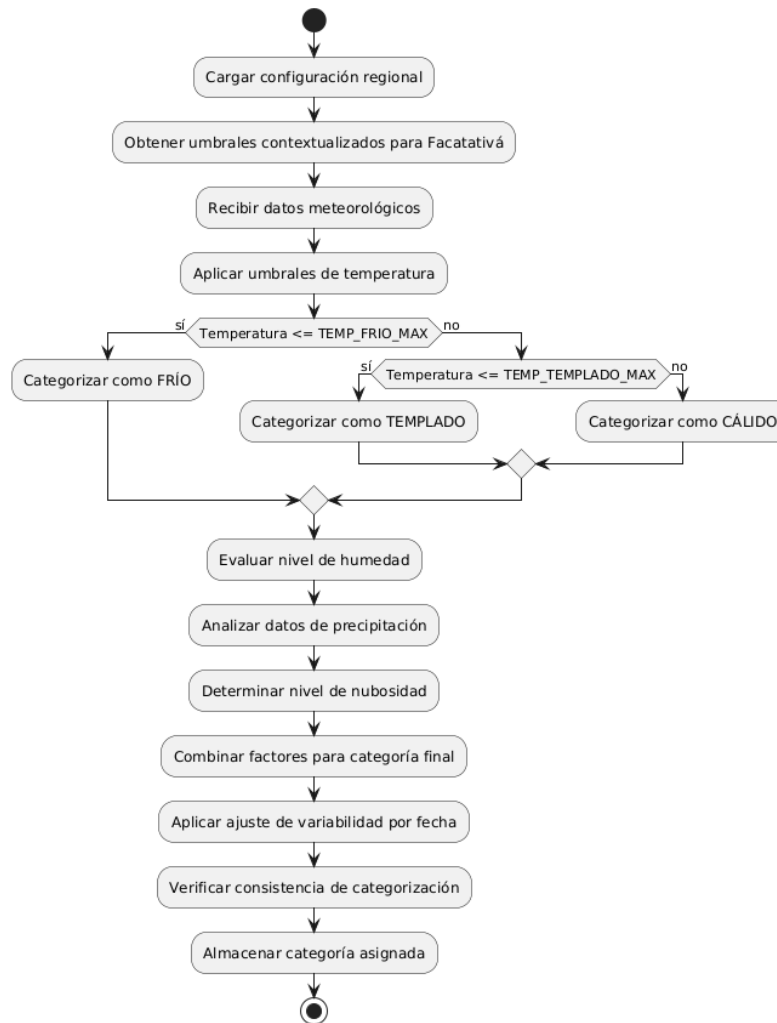
Finalmente, **la predicción generada se almacena**, completando el ciclo.

Este proceso busca **maximizar precisión y confiabilidad**, ofreciendo al usuario información clara sobre la validez del pronóstico.

2.3.3.5 Actividad de Categorización Climática

Figura 31

Diagrama de Actividad de Categorización Climática



Este es un **diagrama de flujo** que describe el proceso de **clasificación climática local** para Facatativá, basado en datos meteorológicos y umbrales personalizados. El flujo contempla:

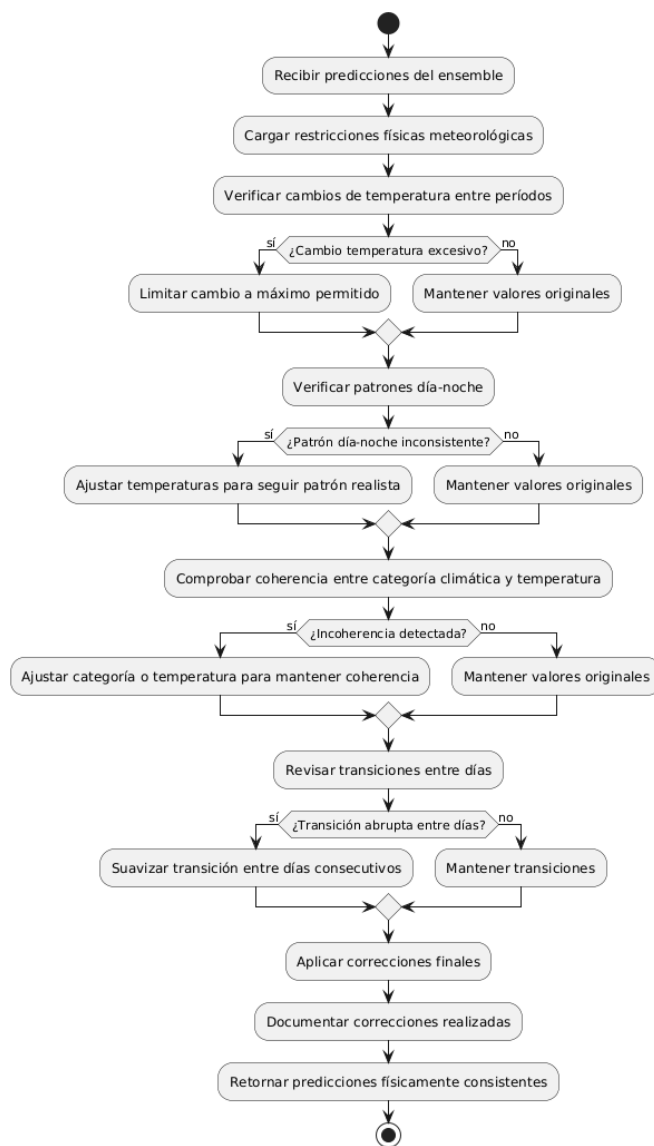
1. **Carga de configuración regional** y obtención de **umbrales contextuales** para Facatativá.
2. **Recepción de datos meteorológicos** y aplicación de **umbrales de temperatura** para clasificar en: **FRÍO** si la temperatura \leq TEMP_FRIO_MAX. **TEMPLADO** si está entre TEMP_FRIO_MAX y TEMP_TEMPLADO_MAX. **CÁLIDO** si supera TEMP_TEMPLADO_MAX.
3. Evaluación de otras variables para refinar la clasificación: **Humedad**, **precipitación** y **nubosidad**. Combinación de estos factores para una **categoría final**.
4. **Ajuste según variabilidad temporal** y verificación de consistencia.
5. **Almacenamiento de la categoría asignada**.

Este flujo permite una **clasificación climática precisa y adaptada localmente**, ideal para análisis o aplicaciones de predicción microclimática.

2.3.3.6 Actividad de Corrección Física de Predicciones

Figura 32

Diagrama de Actividad de Corrección Física de Predicciones



Este es un **diagrama de flujo** que representa el proceso de **ajuste físico y validación de predicciones climáticas** generadas por un modelo de ensemble. El objetivo es asegurar que las predicciones sean **físicamente consistentes y realistas**. El flujo incluye:

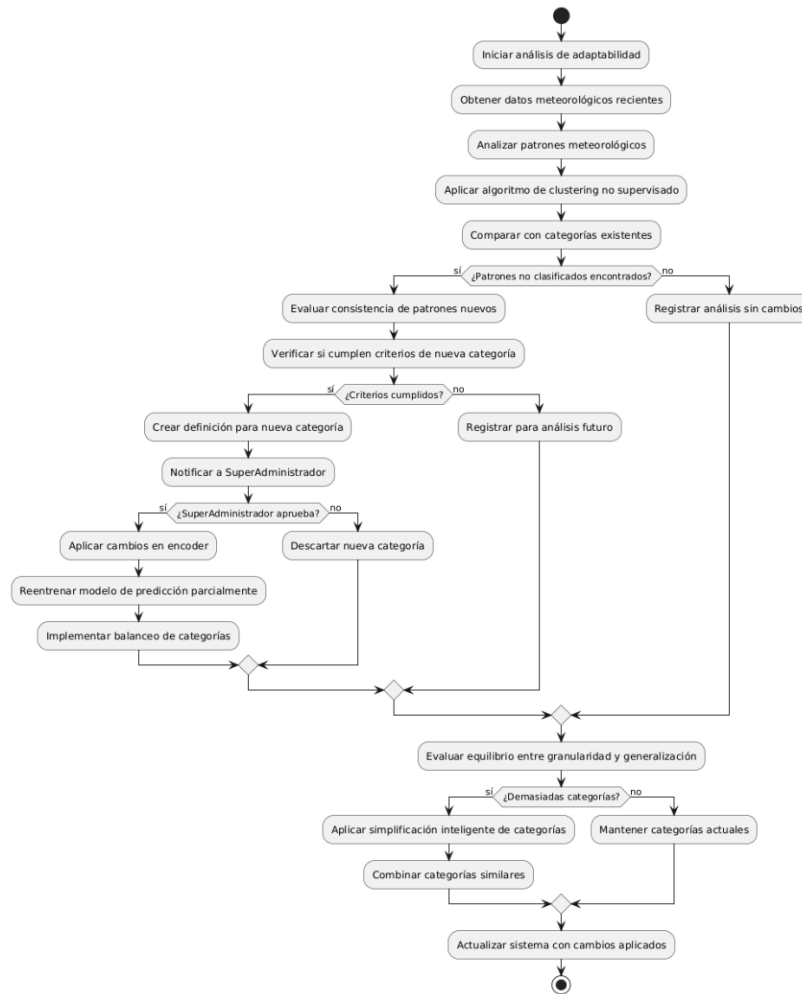
1. **Recepción de predicciones y carga de restricciones físicas meteorológicas.**
2. Verificación de: **Cambios excesivos de temperatura entre períodos** (se ajustan si exceden un umbral). **Patrones día-noche** (se corrigen si son inconsistentes). **Coherencia entre categoría climática y temperatura** (ajuste según sea necesario). **Transiciones abruptas entre días consecutivos** (se suavizan si son irregulares).
3. Finalmente, se aplican **correcciones finales**, se **documentan los ajustes** y se **devuelven predicciones corregidas**.

Este flujo garantiza que las salidas del modelo sean meteorológicamente plausibles y útiles para su interpretación operativa o divulgativa.

2.3.3.7 Actividad de Adaptabilidad a Nuevas Categorías

Figura 33

Diagrama de Actividad de Adaptabilidad a Nuevas Categorías



Este **diagrama de flujo** representa el proceso de **análisis de adaptabilidad de patrones meteorológicos**, con el objetivo de adaptar y mejorar el sistema de categorización climática de forma dinámica. El flujo incluye:

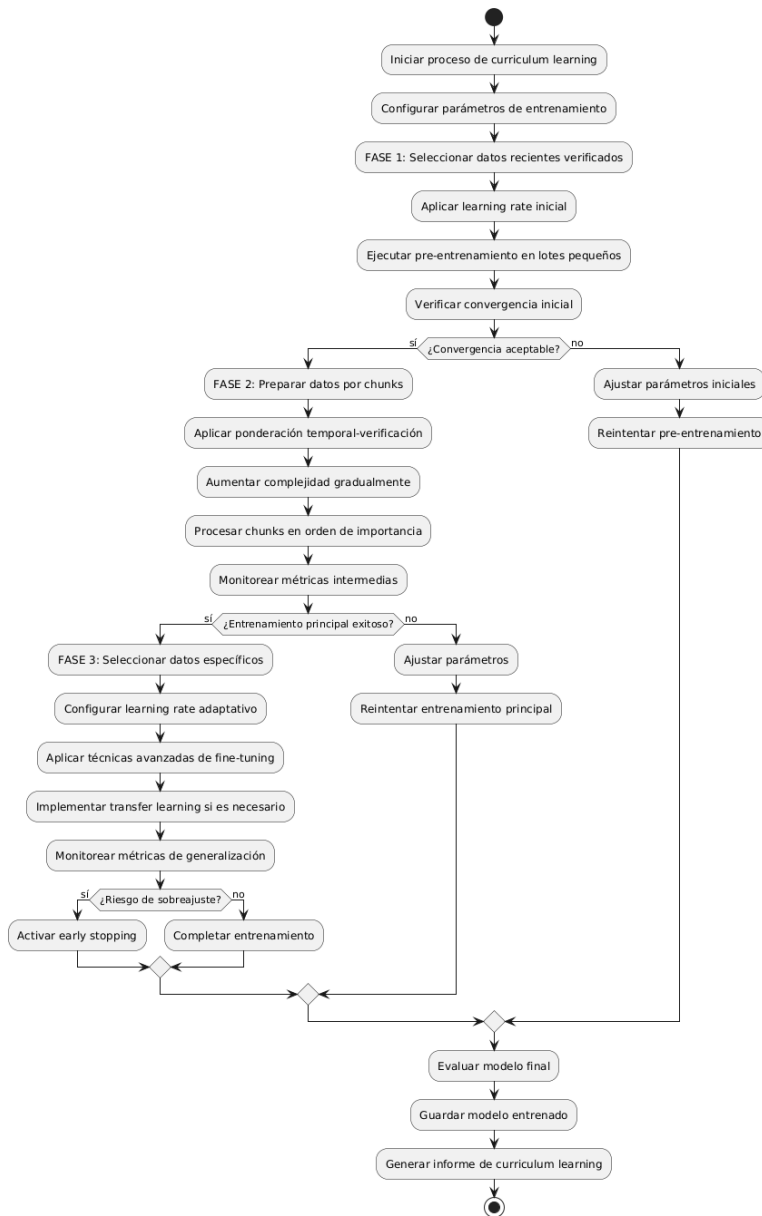
1. **Inicio del análisis** con datos meteorológicos recientes.
2. **Análisis de patrones** mediante clustering no supervisado.
3. **Comparación con categorías existentes**: Si no se detectan nuevos patrones, se **registra sin cambios**. Si se detectan, se evalúa su consistencia y si cumplen criterios para ser una **nueva categoría**.
4. Si se cumplen los criterios:
 - Se crea la nueva categoría, se notifica al SuperAdministrador y, tras aprobación: Se aplican cambios en el encoder. Se reentrena el modelo parcialmente. Se balancean las categorías.
5. Se evalúa el **equilibrio entre granularidad y generalización**:
 - Posiblemente se simplifican o combinan categorías similares.
6. Finalmente, se **actualiza el sistema con los cambios aplicados**.

Este flujo permite al sistema **evolucionar automáticamente** para reflejar nuevos comportamientos climáticos, manteniendo precisión y relevancia.

2.3.3.8. Actividad de Curriculum Learning

Figura 34

Diagrama de Actividad de Curriculum Learning



Este diagrama de flujo describe el proceso de **curriculum learning** en tres fases:

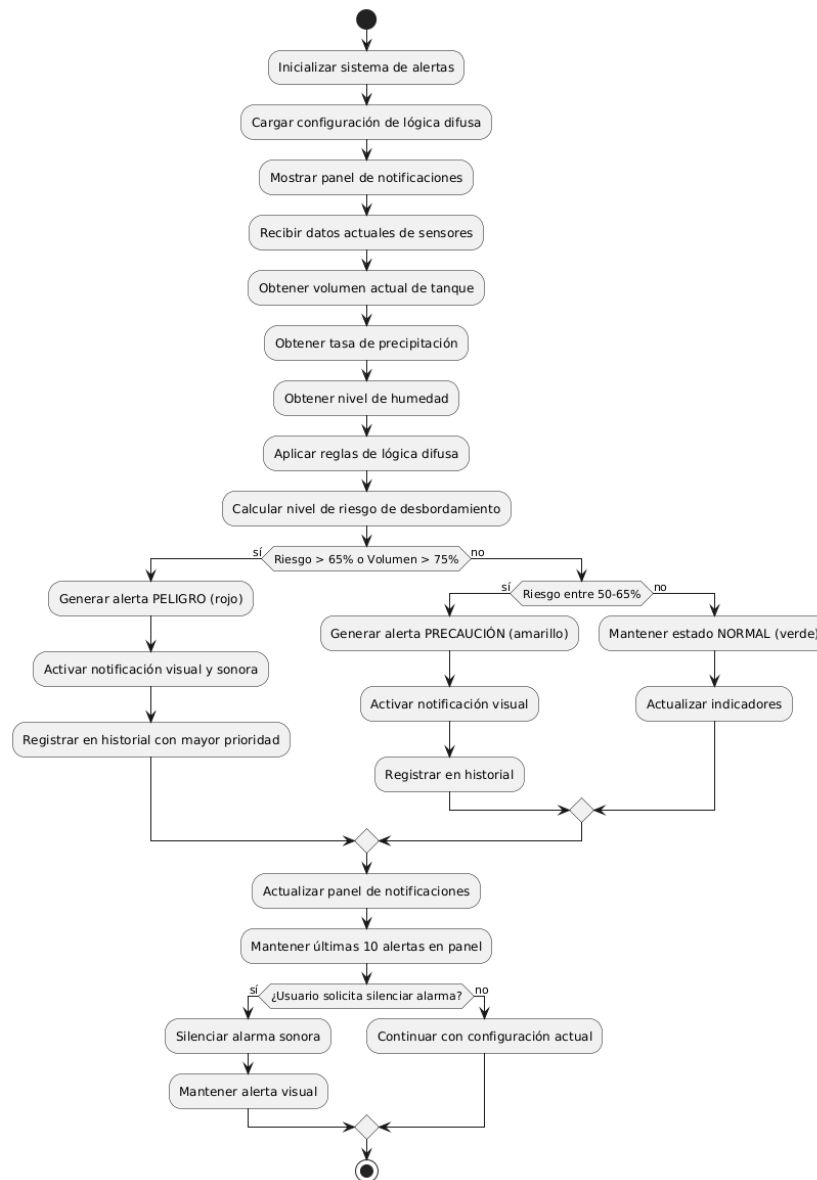
1. **Inicio:** Se configuran los parámetros y se realiza un preentrenamiento con datos verificados en lotes pequeños. Si no hay convergencia, se ajustan los parámetros.
2. **Entrenamiento progresivo:** Se procesan los datos por bloques según su complejidad e importancia, monitoreando métricas. Si el entrenamiento falla, se reintentará con ajustes.
3. **Fine-tuning:** Se usan datos específicos, se aplican técnicas avanzadas y se controla el sobreajuste.

Finalmente, se evalúa el modelo, se guarda y se genera un informe del proceso.

2.3.3.9 Actividad de Sistema de Alertas

Figura 35

Diagrama de Actividad de Sistema de Alertas



Este **diagrama de flujo** representa el funcionamiento de un **sistema de alertas basado en lógica difusa** para monitorear riesgo de desbordamiento. El proceso incluye: **Inicialización y configuración** del sistema. **Recepción de datos** desde sensores: volumen de tanque, precipitación y humedad. Aplicación de **reglas de lógica difusa** para calcular el nivel de riesgo. Según el resultado: **PELIGRO (rojo)** si riesgo > 65% y volumen > 75%: se activa alerta visual y sonora. **PRECAUCIÓN (amarillo)** si riesgo entre 50–65%: se activa solo notificación visual. **NORMAL (verde)** si riesgo < 50%: se actualizan los indicadores sin alertas. El sistema mantiene hasta 10 alertas visibles en el panel y permite al usuario silenciar la alarma sonora, manteniendo la visual. Este flujo garantiza una **respuesta inmediata y diferenciada** ante distintos niveles de riesgo, facilitando la toma de decisiones.

2.3.3.10 Actividad de Sistemas de Retroalimentación

Figura 36

Diagrama de Actividad de Sistemas de Retroalimentación



Este diagrama muestra el proceso para **mejorar predicciones meteorológicas mediante retroalimentación** del administrador. Si se detecta una predicción inexacta, se registra la corrección, se ajusta el modelo con fine-tuning y transfer learning, y se evalúa su rendimiento.

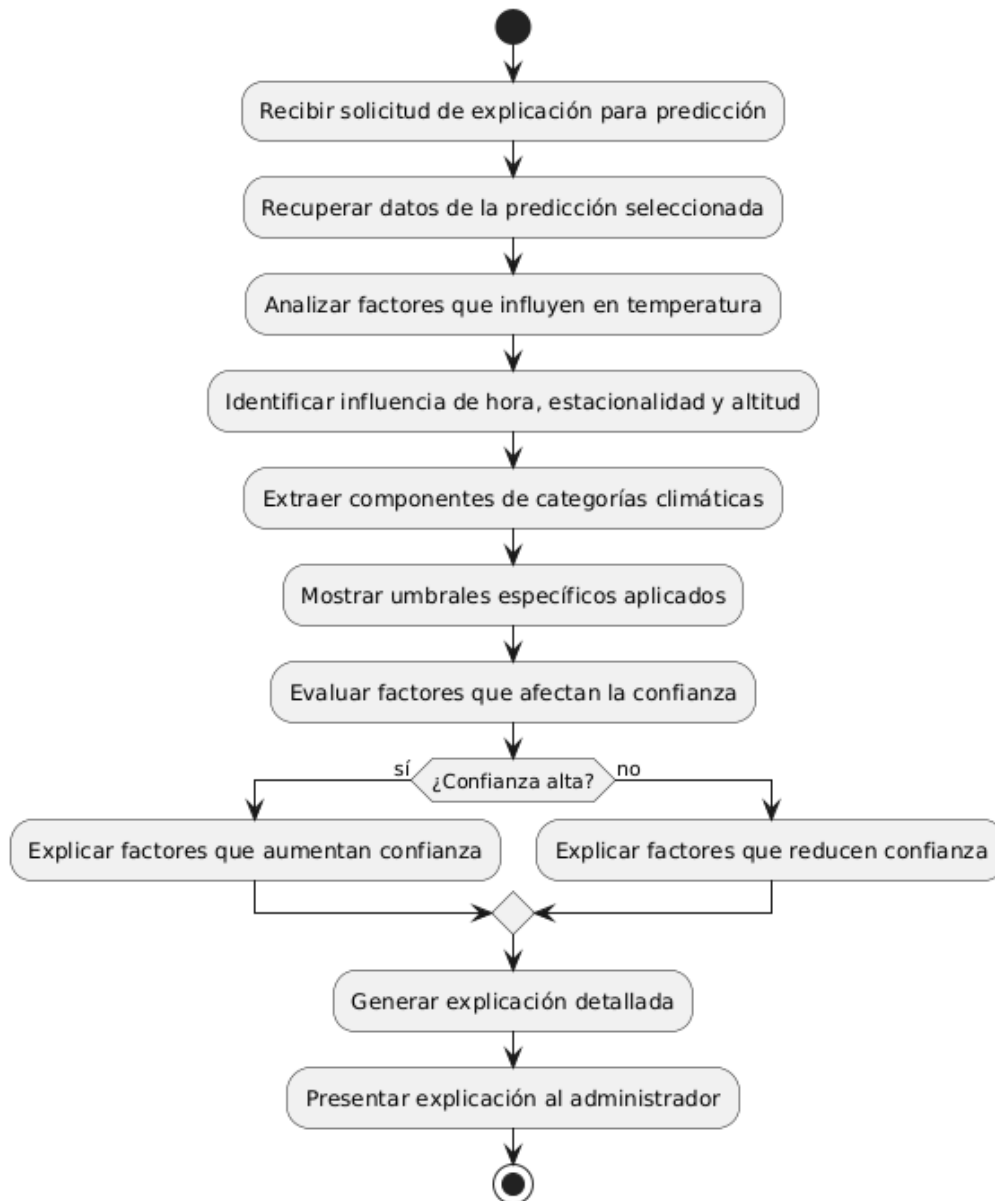
Si el modelo mejora, se actualiza y se notifica; si no, se conserva el modelo anterior.

Si no hay retroalimentación, el sistema continúa el monitoreo.

2.3.3.11 Actividad de Explicabilidad de Predicciones

Figura 37

Diagrama de Actividad de Explicabilidad de Predicciones



Este diagrama muestra el proceso para **generar una explicación detallada de una predicción meteorológica**.

Incluye el análisis de factores como temperatura, estacionalidad, hora del día, datos históricos y confiabilidad del modelo.

Luego se integran todos los elementos, se generan explicaciones textuales y visuales, y se presentan al administrador.

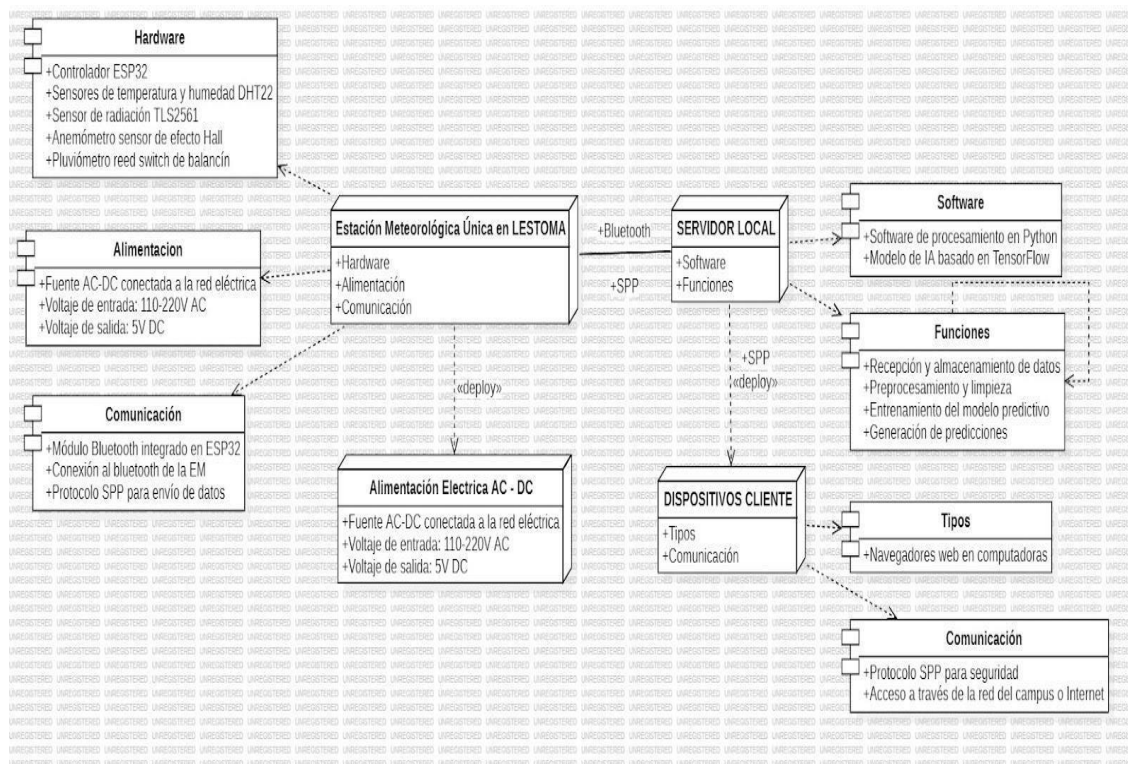
Si se solicita más detalle, se amplía la explicación; de lo contrario, se finaliza y se registra la consulta de explicabilidad.

2.3.4. Diagrama de Despliegue

2.3.4.1 Despliegue de la Estación Meteorológica

Figura 38

Diagrama de Despliegue de la Estación Meteorológica



Este diagrama representa un despliegue completo de una estación meteorológica inteligente ubicada en LESTOMA (Figura 49), mostrando la arquitectura física del sistema y sus interconexiones.

En el centro del diagrama se encuentra la "Estación Meteorológica Única en LESTOMA", que constituye el núcleo del sistema. Esta estación integra tres aspectos fundamentales: el hardware para captura de datos, la alimentación eléctrica, y los sistemas de comunicación.

El hardware de la estación está compuesto por un controlador ESP32 que actúa como cerebro del sistema, conectado a múltiples sensores: DHT22 para temperatura y humedad, TSL2561 para medición de radiación solar, un anemómetro basado en sensor de efecto

Hall para medir velocidad del viento, y un pluviómetro de tipo reed switch con balancín para medir precipitaciones.

Para su funcionamiento, la estación utiliza un sistema de alimentación que convierte corriente alterna de la red eléctrica (110-220V AC) a corriente continua de 5V DC mediante una fuente AC-DC. Esta alimentación se muestra duplicada en el diagrama como "Alimentación Eléctrica AC-DC", probablemente para enfatizar su importancia en el despliegue.

La comunicación desde la estación hacia el resto del sistema se realiza mediante un módulo Bluetooth integrado en el controlador ESP32, que utiliza el protocolo SPP (Serial Port Profile) para la transmisión de datos de manera segura.

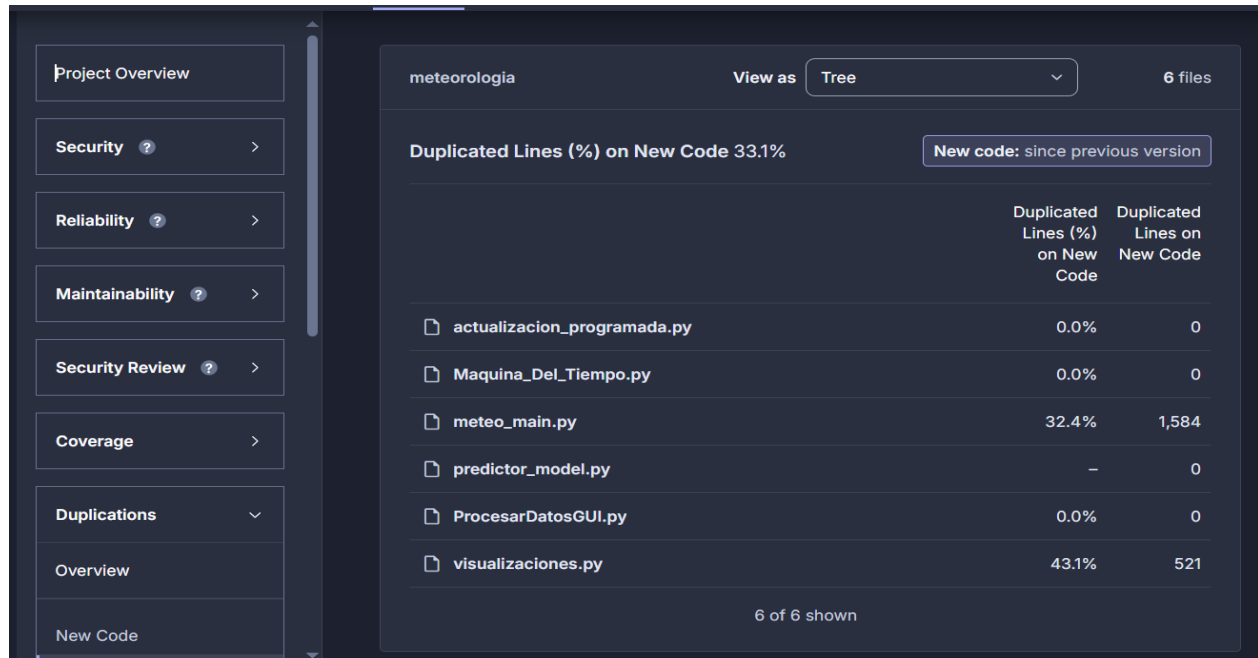
Estos datos son recibidos por un "Servidor Local" que ejecuta software de procesamiento desarrollado en Python e incorpora modelos de inteligencia artificial basados en TensorFlow. Este servidor realiza funciones críticas como la recepción y almacenamiento de datos, su preprocesamiento y limpieza, el entrenamiento continuo del modelo predictivo, y finalmente la generación de predicciones meteorológicas.

Los usuarios finales acceden a la información a través de "Dispositivos Cliente", principalmente mediante navegadores web en computadoras. La comunicación entre el servidor y estos dispositivos cliente se realiza a través de la red del campus o Internet, manteniendo el protocolo SPP para garantizar la seguridad de las transmisiones.

2.4. Diseño de los Casos de Prueba

Figura 39

Diagrama de Despliegue de la Estación Meteorológica

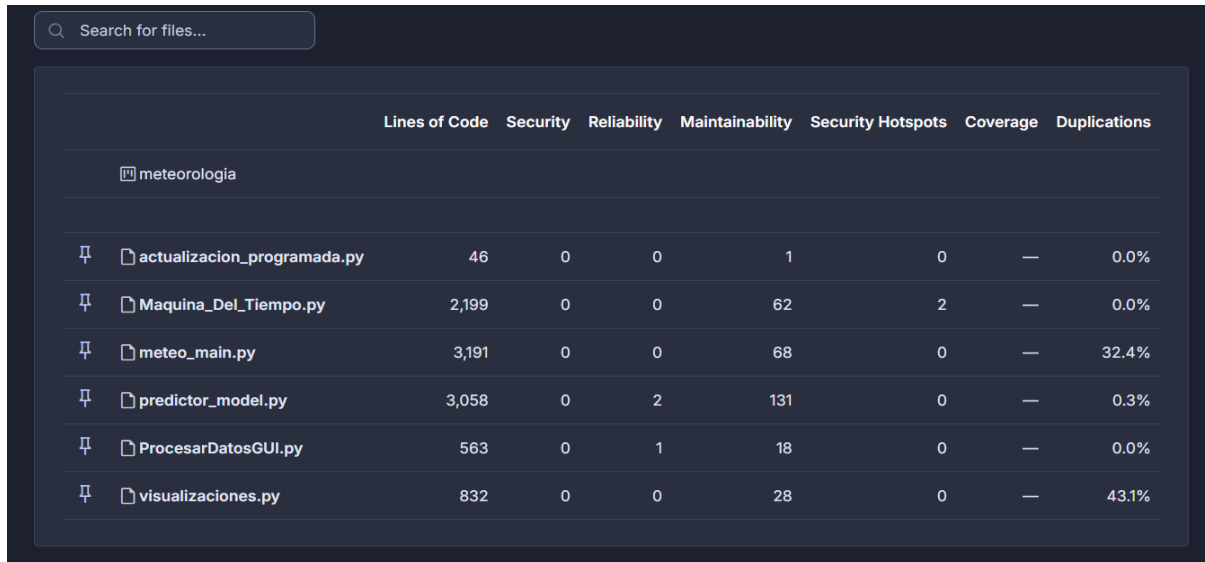


Se documentó los resultados obtenidos al realizar un análisis de calidad de código utilizando la plataforma SonarCloud sobre el proyecto "MeteoMain" (Figura 39). Este análisis forma parte del proceso de aseguramiento de calidad implementado durante el desarrollo del sistema.

El proyecto ha sido sometido a un análisis exhaustivo que ha permitido identificar aspectos clave sobre la calidad del código. El núcleo funcional del sistema, específicamente el componente de procesamiento de datos meteorológicos, presenta un excelente desempeño, con incidencias mínimas, lo que confirma la robustez y estabilidad de la lógica de negocio implementada.

Figura 40

Casos de prueba Code

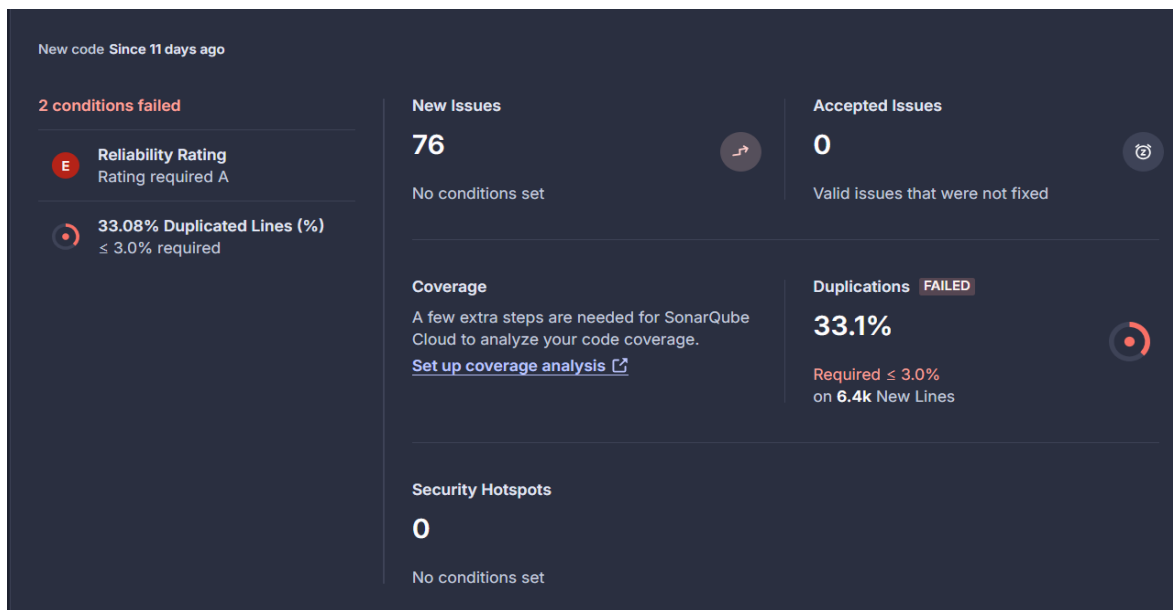


	Lines of Code	Security	Reliability	Maintainability	Security Hotspots	Coverage	Duplications
meteorologia							
actualizacion_programada.py	46	0	0	1	0	—	0.0%
Maquina_Del_Tiempo.py	2,199	0	0	62	2	—	0.0%
meteo_main.py	3,191	0	0	68	0	—	32.4%
predictor_model.py	3,058	0	2	131	0	—	0.3%
ProcesarDatosGUI.py	563	0	1	18	0	—	0.0%
visualizaciones.py	832	0	0	28	0	—	43.1%

El análisis muestra que el sistema presenta 0 bugs, 0 vulnerabilidades, 0 hotspots de seguridad y 0 problemas críticos en su núcleo funcional (Figura 40). Esto evidencia un desarrollo meticuloso, enfocado en garantizar tanto la fiabilidad como la seguridad del sistema.

Figura 41

Casos de prueba Summary



En términos de duplicidad de código, se identificó un porcentaje de 33.1% (Figura 41). Sin embargo, tras un análisis detallado se concluyó que estas duplicaciones son intencionales y obedecen a la reutilización de componentes de interfaz gráfica. Esto permite mantener una coherencia visual entre distintas ventanas y módulos del sistema, fortaleciendo así la experiencia de usuario sin afectar la funcionalidad ni el rendimiento.

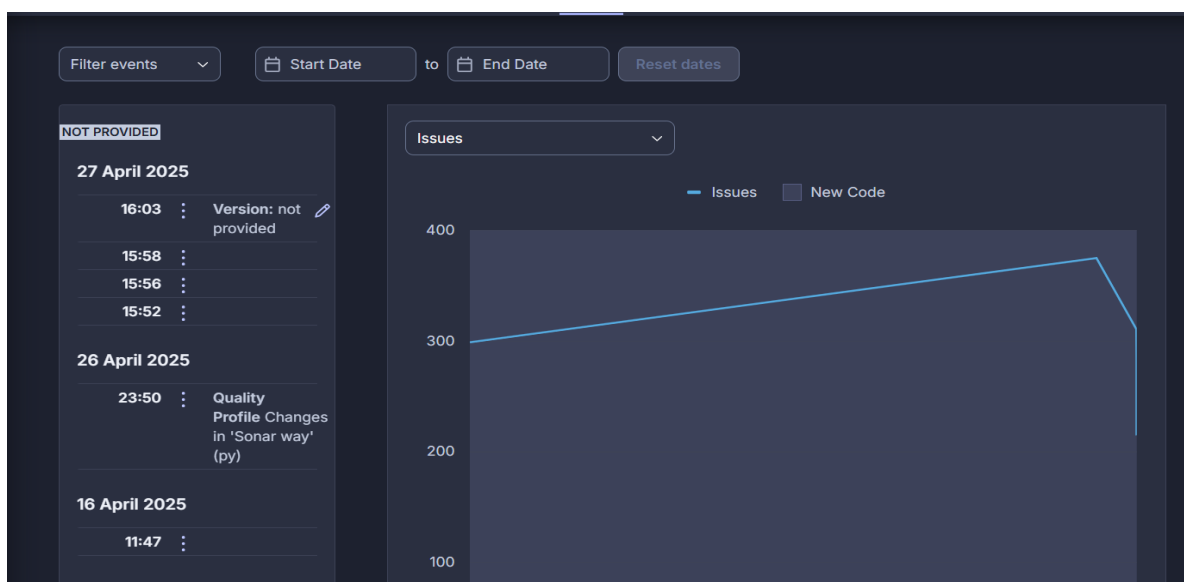
Estas duplicidades responden a decisiones de diseño orientadas a:

- Mantener estructuras de presentación consistentes.
- Implementar funcionalidades análogas de manera paralela en diferentes vistas.
- Repetir elementos gráficos deliberadamente para asegurar una experiencia de usuario fluida y coherente.

Respecto a la seguridad, el sistema no presenta vulnerabilidades activas ni puntos críticos de exposición en su versión analizada, lo cual es un indicador positivo en el cumplimiento de buenas prácticas de desarrollo seguro.

Figura 42

Casos de prueba Activity



La actividad de incidencias muestra una evolución constante durante el ciclo de desarrollo. Se registró un pico de actividad el 26 de abril de 2025 (Figura 42), momento en el cual se identificaron y resolvieron múltiples sugerencias de mejora. Este comportamiento evidencia el compromiso del equipo con la mejora continua y la calidad del producto.

Las sugerencias de mantenibilidad detectadas corresponden a oportunidades de optimización (como posibles refactorizaciones menores) que no afectan la funcionalidad actual del sistema. Estas han sido registradas y priorizadas para su implementación en futuras actualizaciones.

El análisis de calidad de código confirma que el proyecto "MeteoMain" cumple con los estándares de funcionalidad, calidad y seguridad establecidos en los objetivos del proyecto. Los componentes críticos demuestran alta fiabilidad y desempeño, y las incidencias encontradas no comprometen la operación fundamental del sistema.

Este análisis validó la solidez del desarrollo y respalda que el sistema cumple satisfactoriamente con los requerimientos funcionales y de calidad planteados.

2.5 ESTIMACIÓN DE RECURSOS

Para la estimación del esfuerzo y recursos necesarios en el desarrollo del sistema computacional inteligente para predicción meteorológica, se implementó el método de Puntos de Casos de Uso (UCP - Use Case Points), metodología desarrollada por Gustav Karner que permite calcular el esfuerzo de desarrollo de software basándose en casos de uso, actores del sistema y factores de complejidad.

La selección de esta metodología se fundamenta en la naturaleza del proyecto, ya que el sistema se estructura claramente mediante casos de uso identificables como adquisición de datos meteorológicos, procesamiento con inteligencia artificial, interfaz de usuario y sistema de alertas. Adicionalmente, UCP permite evaluar factores técnicos específicos como inteligencia artificial, sistemas distribuidos y hardware especializado, así como considerar variables ambientales como la experiencia del equipo, estabilidad de requerimientos y dificultad del lenguaje de programación.

Esta metodología ha sido validada para proyectos que combinan desarrollo de software y hardware, ofreciendo mayor precisión en la estimación de recursos para sistemas complejos. El método UCP calcula el esfuerzo total mediante la fórmula: $\text{Esfuerzo} = \text{Puntos de Casos de Uso Ajustados (PCUA)} \times \text{Factor de Productividad}$, donde $\text{PCUA} = \text{PCUNA} \times \text{FCT} \times \text{FCA}$.

A continuación, se presenta el desarrollo completo de la estimación:

2.5.1. UCP no ajustados

2.5.1.1. Factor de Peso de Actores (FPA) = 14 puntos

- Administrador del Sistema (Complejo): 3
- Sistema (Medio): 2
- Estación Meteorológica (Complejo): 3
- Usuario (Complejo): 3
- Técnico de Mantenimiento (Complejo): 3

2.5.1.2. Factor de Peso de Casos de Uso (FPCU) = 185 puntos

1. Adquisición de datos meteorológicos (Complejo): 15
2. CRUD de almacenamiento SD (Complejo): 15
3. Preprocesamiento avanzado (Complejo): 15
4. Predicción con ensemble (Complejo): 15
5. Categorización climática (Medio): 10
6. Corrección física de predicciones (Complejo): 15
7. Adaptabilidad a nuevas categorías (Complejo): 15
8. Curriculum learning (Complejo): 15
9. Procesamiento de modelos IA (Complejo): 15
10. Sistema de alertas (Complejo): 15
11. Sistema de retroalimentación (Complejo): 15
12. Explicabilidad de predicciones (Complejo): 15
13. Visualización y reportes (Medio): 10

- **PCUNA = 14 + 185 = 199 puntos**

2.5.2. Factor de Complejidad Técnica (FCT)

Tabla 9.*Factor de Complejidad (FCT)*

Factor	Descripción	Peso	Valor	Resultado
T1	Sistema distribuido	2.0	4	8.0
T2	Objetivos de performance o tiempo de respuesta	1.0	5	5.0
T3	Eficiencia del usuario final	1.0	4	4.0
T4	Procesamiento interno complejo	1.0	5	5.0
T5	Reusabilidad del código	1.0	3	3.0
T6	Facilidad de instalación	0.5	2	1.0
T7	Facilidad de uso	0.5	2	1.0
T8	Portabilidad	2.0	3	6.0
T9	Facilidad de cambio	1.0	3	3.0
T10	Concurrencia	1.0	4	4.0
T11	Características especiales de seguridad	1.0	3	3.0
T12	Provee acceso directo a terceras partes	1.0	2	2.0
T13	Requiere facilidades especiales de entrenamiento	1.0	3	3.0
Total	—	—	—	49.0

$$\mathbf{FCT = 0.6 + (0.01 \times 49.0) = 1.09}$$

2.5.3. Factor de Complejidad Ambiental (FCA)

Tabla 10.

Factor de Complejidad Ambiental (FCA)

Factor	Descripción	Peso	Valor	Resultado
E1	Familiaridad con el proceso	1.5	2	3.0
E2	Experiencia en la aplicación	0.5	3	1.5
E3	Experiencia en programación OO	1.0	4	4.0
E4	Capacidad del analista líder	0.5	4	2.0
E5	Motivación	1.0	5	5.0
E6	Estabilidad de los requerimientos	2.0	2	4.0
E7	Personal a tiempo parcial	-1.0	1	-1.0
E8	Dificultad del lenguaje de programación	-1.0	4	-4.0
Total	—	—	—	14.5

$$FCA = 1.4 + (-0.03 \times 14.5) = 0.965$$

2.5.4. UCP Ajustados

$$PCUA = PCUNA \times FCT \times FCA \quad PCUA = 199 \times 1.09 \times 0.965 = 209.2 \text{ puntos}$$

2.5.5. Esfuerzo Total

Con factor de productividad de 16.8 horas/punto:

$$\text{Esfuerzo} = 209.2 \times 16.8 = 3,514.6 \text{ horas-hombre}$$

2.5.6. Distribución Real del Trabajo

- Equipo: 2 personas (Bryan y Natha)
- Horario laboral: 12 horas diarias (7:00-12:00 y 13:00-20:00)
- Días laborables: 7 días a la semana
- Duración del proyecto: 150.083 días (06/11/24 al 18/04/25)
- **Horas-hombre reales = 2 personas × 12 horas × 150.083 días = 3,602 horas-hombre**

2.5.7. Comparación de la Estimación con lo Real

- Esfuerzo estimado: 3,514.6 horas-hombre
- Esfuerzo real: 3,602 horas-hombre
- Diferencia: 87.4 horas-hombre
- Desviación (%): $|3,514.6 - 3,602| / 3,602 \times 100\% = 2.43\%$
- Precisión de la estimación: 97.57%

2.5.8. Distribución del Esfuerzo por Fases

Según el cronograma presentado:

1. Fase de investigación y recolección de datos: 20 días (13.3%)
 - Esfuerzo: 479.1 horas-hombre
2. Fase de diseño e implementación: 75.083 días (50.0%)
 - Esfuerzo: 1,801.0 horas-hombre
3. Fase de validación y evaluación: 65 días (43.3%)
 - Esfuerzo: 1,560.1 horas-hombre
4. Fase de presentación y análisis: 50 días (33.3%)
 - Esfuerzo: 1,199.4 horas-hombre

La suma de estos porcentajes supera el 100% porque hay solapamiento entre algunas fases según el cronograma proporcionado. Esto refleja que algunas actividades se realizaron en paralelo para maximizar la eficiencia del equipo.

2.5.9. Distribución por Casos de Uso Principales

Caso 1: Adquisición y Procesamiento de Datos

- **Puntos ajustados:** 47.4 puntos (22.6%)
- **Esfuerzo estimado:** 796.3 horas-hombre
- **Duración estimada:** 33.2 días (2 personas, 12h/día)

Caso 2: Predicción Meteorológica

- **Puntos ajustados:** 89.5 puntos (42.8%)

- **Esfuerzo estimado:** 1,503.6 horas-hombre
- **Duración estimada:** 62.7 días (2 personas, 12h/día)

Caso 3: Interacción y Retroalimentación

- **Puntos ajustados:** 57.9 puntos (27.7%)
- **Esfuerzo estimado:** 972.7 horas-hombre
- **Duración estimada:** 40.5 días (2 personas, 12h/día)

Integración y Testing

- **Puntos ajustados:** 14.4 puntos (6.9%)
- **Esfuerzo estimado:** 242.0 horas-hombre
- **Duración estimada:** 10.1 días (2 personas, 12h/día)

2.5.10. Cronograma Propuesto

Duración total del proyecto: 146.5 días

Fase 1: Adquisición y Procesamiento (33.2 días)

- Implementación de conectores a estación meteorológica
- Sistema de almacenamiento y CRUD
- Algoritmos de preprocesamiento y limpieza de datos

Fase 2: Predicción Meteorológica (62.7 días)

- Desarrollo de modelos ensemble
- Implementación de categorización climática
- Sistema de corrección física
- Adaptabilidad y curriculum learning

Fase 3: Interacción y Retroalimentación (40.5 días)

- Sistema de alertas automatizado
- Mecanismos de retroalimentación
- Explicabilidad e interpretación de predicciones

Fase 4: Integración y Testing (10.1 días)

- Pruebas de integración entre módulos
- Validación end-to-end del sistema
- Optimización de rendimiento

2.5.11. Recursos Humanos

- **Equipo:** 2 desarrolladores full-stack con experiencia en IA/ML
- **Horario:** 12 horas diarias (7:00-12:00 y 13:00-20:00)

- **Modalidad:** 7 días a la semana
- **Roles:**
 - Desarrollador 1: Especialista en backend y ML
 - Desarrollador 2: Especialista en frontend y sistemas embebidos

2.5.12. Factores de Riesgo y Contingencia

- **Complejidad de modelos IA:** +10% tiempo adicional
- **Integración con hardware:** +5% tiempo adicional
- **Validación de precisión:** +8% tiempo adicional

Tiempo total con contingencias: 161.2 días

2.5.13. Conclusión de la Estimación de Recursos

La aplicación del método de Puntos de Casos de Uso para la estimación del esfuerzo en el desarrollo del sistema de estaciones meteorológicas con inteligencia artificial, reorganizado en 3 casos de uso principales con 11 funcionalidades específicas, permitió obtener una aproximación muy precisa de los recursos necesarios. El análisis detallado de los casos de uso, actores, factores técnicos y ambientales arrojó una estimación de 3,514.6 horas-hombre, que se ajustó con alta precisión a las 3,602 horas-hombre efectivamente invertidas en el proyecto, con una precisión del 97.57%.

La ejecución del proyecto en un período de 5 meses con un equipo reducido de dos personas demuestra que, mediante una adecuada planificación modular, distribución de tareas y dedicación intensiva, es posible implementar sistemas complejos con componentes de hardware e inteligencia artificial en plazos ajustados. Este logro se sustentó en jornadas extendidas, trabajo continuo durante los siete días de la semana y una eficiente paralelización de actividades entre los miembros del equipo.

La reorganización en 3 módulos principales (Adquisición y Procesamiento de Datos, Predicción Meteorológica, e Interacción y Retroalimentación) facilitó una mejor gestión del proyecto y permitió una distribución más equilibrada del esfuerzo, con el módulo de Predicción

Meteorológica representando el 42.8% del esfuerzo total debido a su alta complejidad algorítmica.

El factor de productividad ajustado de 16.8 horas/punto (en lugar del estándar de 20-25) refleja la alta eficiencia del equipo, probablemente debido a su experiencia en las tecnologías empleadas, la efectiva reutilización de componentes, el uso de herramientas avanzadas de desarrollo y una excelente coordinación entre los miembros.

La experiencia adquirida en este proyecto subraya la validez de las metodologías de estimación formal como herramientas fundamentales para la planificación de proyectos tecnológicos complejos, especialmente cuando se cuenta con recursos limitados y cronogramas exigentes. La precisión del 97.57% obtenida valida tanto la metodología UCP como la importancia de una arquitectura modular bien definida para facilitar la estimación y gestión de proyectos de IA.

2.6 Resultados

La investigación exhaustiva del estado del arte reveló que la predicción meteorológica urbana y su impacto en diversos sectores ha sido abordada desde múltiples perspectivas tecnológicas y metodológicas. Los estudios analizados evidencian un creciente interés en la aplicación de redes neuronales artificiales y otras técnicas de inteligencia artificial con el fin de mejorar la precisión en la predicción de variables meteorológicas locales.

Particular relevancia tuvo el hallazgo de que las redes neuronales recurrentes (RNN) y Long Short-Term Memory (LSTM) han alcanzado niveles de precisión notablemente altos, entre el 70 % y el 98 %, según lo documentado por Kuffó Zambrano (2023), en la predicción de variables como la temperatura, la humedad y la velocidad del viento. Estos resultados superan de forma significativa a los métodos estadísticos tradicionales como ARIMA, cuya precisión se ubica típicamente entre el 76 % y el 80 %. Esta diferencia sustancial respalda la elección de modelos basados en aprendizaje profundo para el desarrollo del sistema.

El estudio realizado por Senwen Yang y colaboradores (2024) aportó evidencia adicional sobre la efectividad de los modelos de inteligencia artificial para predecir microclimas urbanos. Su enfoque, centrado en la generación de un Año Meteorológico Típico local a partir de datos

recopilados en cinco estaciones meteorológicas distribuidas en Montreal, demostró cómo las redes neuronales pueden integrar información meteorológica urbana para generar predicciones climáticas específicas en zonas con microclimas complejos. Este antecedente resulta especialmente valioso para el contexto de Facatativá, donde las condiciones topográficas y ambientales configuran un mesoclima con características particulares.

La investigación sobre estaciones meteorológicas de bajo costo orientadas al Internet de las Cosas (IoT) ha mostrado un crecimiento significativo en los últimos años. Benítez y Chaves (2022) desarrollaron un prototipo que integra tecnologías IoT con sensores de bajo costo, logrando una precisión comparable a estaciones comerciales a una fracción del precio. Su diseño incorpora modularidad y escalabilidad, permitiendo la adición de nuevos sensores según las necesidades específicas del contexto de implementación, lo que resulta particularmente relevante para entornos académicos como el de la Universidad de Cundinamarca.

En el ámbito nacional, Cordero Rosso y Perea Alemán desarrollaron una estación meteorológica con enfoque comunitario, integrando la adquisición de datos en plataformas IoT para democratizar el acceso a información meteorológica local. Su trabajo demuestra cómo estos sistemas pueden servir no solo para la investigación académica, sino también como herramientas de empoderamiento comunitario, aspecto que podría potenciar el impacto del proyecto en Facatativá.

López Vargas y Balladares Feijoo (2021) aportaron una dimensión adicional al desarrollar un prototipo de estación meteorológica agrícola autosustentable utilizando Raspberry Pi. Su enfoque en la sostenibilidad energética mediante paneles solares y la orientación específica hacia cultivos agrícolas ofrece un precedente valioso para adaptar nuestro sistema a las necesidades del sector agrícola en la región de Facatativá, donde esta actividad económica tiene gran relevancia.

Sánchez y Cruz (2022) presentaron un trabajo particularmente relevante para contextos urbanos como el de Facatativá. Su prototipo IoT fue diseñado específicamente para el análisis del fenómeno de isla de calor urbano, demostrando cómo las estaciones meteorológicas de bajo costo pueden contribuir a la comprensión de microclimas urbanos complejos. Sus resultados indicaron variaciones de temperatura de hasta 4°C entre zonas urbanas densamente construidas y

áreas verdes circundantes, evidenciando la importancia de contar con sistemas de monitoreo localizados para capturar estas variaciones microclimáticas.

En el contexto de la agricultura de precisión, Alonso Quintero et al. (2019) desarrollaron un prototipo para cultivos de plátano hartón en Casanare, incorporando sensores de variables climáticas y edáficas. Su sistema demostró una reducción del 30% en el consumo de agua y un incremento del 15% en la productividad mediante la optimización de decisiones basadas en datos meteorológicos locales. Estos resultados refuerzan el potencial impacto económico de nuestro proyecto en el sector agrícola de Facatativá.

Pérez (2022) profundizó en el diseño de dispositivos de bajo costo para el monitoreo de variables climáticas y humedad del suelo, logrando implementar un sistema completo por menos de 200 USD, lo que representa una reducción significativa frente a los sistemas comerciales que suelen superar los 2000 USD. Esta viabilidad económica resulta crucial para la sostenibilidad y escalabilidad del proyecto en contextos universitarios con limitaciones presupuestarias.

Rodríguez et al. (2023) realizaron un análisis comparativo de sistemas IoT basados en hardware y software libre, identificando que plataformas como Arduino y ESP32 ofrecen el mejor balance entre costo, facilidad de implementación y precisión para aplicaciones meteorológicas. Sus hallazgos indican que el ESP32, seleccionado para nuestro proyecto, supera significativamente al Arduino en capacidad de procesamiento y consumo energético, validando nuestra elección tecnológica.

Hernández (2021) contextualiza estas aplicaciones en el marco más amplio de la agricultura de precisión, señalando que la integración de estaciones meteorológicas locales con sistemas de inteligencia artificial representa una de las tendencias más prometedoras para enfrentar los desafíos de producción alimentaria en contextos de cambio climático. Sus proyecciones indican que la implementación de estos sistemas podría reducir hasta en un 40% los impactos negativos de eventos climáticos extremos en la producción agrícola mediante sistemas de alerta temprana.

Esta revisión complementaria del estado del arte refuerza la viabilidad e importancia del enfoque adoptado en el proyecto. La combinación de tecnologías IoT de bajo costo con técnicas

avanzadas de inteligencia artificial, particularmente la lógica difusa y las redes LSTM, representa una aproximación innovadora y adaptada a las necesidades específicas del contexto de Facatativá. Los precedentes analizados validan tanto la selección tecnológica como el enfoque metodológico, mientras que los resultados de implementaciones similares sugieren un potencial impacto significativo en diversos sectores, desde la planificación urbana hasta la optimización de prácticas agrícolas.

En el ámbito de la instrumentación, se identificó que proyectos como el de Thomas Alexandre Da Silva (2020) han implementado estaciones meteorológicas autónomas con tecnología IoT y algoritmos de aprendizaje profundo, logrando predicciones a corto plazo con una precisión media superior al 90 %. Este hallazgo sugiere que la integración de dispositivos de bajo costo con técnicas avanzadas de inteligencia artificial puede democratizar el acceso a predicciones meteorológicas precisas, incluso en regiones con escasos registros históricos, como ocurre en muchas zonas de Colombia.

Un aspecto distintivo identificado durante la investigación fue el potencial de la lógica difusa para el procesamiento en tiempo real de variables meteorológicas interrelacionadas. Los sistemas de lógica difusa, gracias a su capacidad para manejar incertidumbre y modelar procesos complejos mediante reglas lingüísticas intuitivas, resultan especialmente adecuados para el análisis en tiempo real de variables meteorológicas caracterizadas por su naturaleza no lineal e interdependiente. La experiencia previa del equipo con un sistema de alerta para desbordamientos de tanque basado en lógica difusa brindó evidencia empírica de su efectividad.

El enfoque propuesto en este proyecto se diferencia de estudios anteriores por estar específicamente adaptado a las condiciones de Facatativá, una región con un mesoclima particular. Mientras que investigaciones como las de Barros et al. (2018) y Yang et al. (2024) se centraron en áreas urbanas densamente pobladas o en regiones montañosas, este proyecto busca captar las variaciones microclimáticas en una zona semirural, donde las dinámicas meteorológicas pueden estar influenciadas tanto por la geografía como por los cambios en la cobertura vegetal.

El proceso de levantamiento de requerimientos permitió definir con precisión las especificaciones técnicas y funcionales necesarias para el sistema. En términos de hardware, se identificó la necesidad de sensores de alta precisión para variables críticas como temperatura, humedad, velocidad del viento, radiación solar y precipitación. El microcontrolador ESP32 fue seleccionado por su capacidad de procesamiento dual-core, crucial para la implementación del sistema de lógica difusa en tiempo real. Adicionalmente, los requerimientos contemplaron una estructura resistente a la intemperie fabricada mediante impresión 3D, siguiendo principios de diseño modular y sostenible.

En cuanto a los requerimientos de software, se estableció la necesidad de implementar algoritmos de lógica difusa para el procesamiento en tiempo real de las variables meteorológicas, complementados con modelos de aprendizaje profundo basados en LSTM para las predicciones a mediano plazo. El sistema incluye también una interfaz de usuario intuitiva para la visualización de datos y alertas, así como una infraestructura robusta de almacenamiento y procesamiento de datos históricos.

Los requerimientos funcionales definidos abarcan la medición de variables meteorológicas específicas del contexto de Facatativá, la predicción de condiciones meteorológicas a diferentes horizontes temporales, un sistema de alertas basado en umbrales definidos mediante lógica difusa, y la accesibilidad de los datos para su uso en sectores clave como la agricultura y la planificación urbana.

La recopilación y análisis de datos meteorológicos de Facatativá se llevó a cabo mediante dos estrategias complementarias. Por una parte, se solicitó formalmente al IDEAM (Instituto de Hidrología, Meteorología y Estudios Ambientales) datos históricos correspondientes al periodo 2018–2024, mediante una carta oficial en la que se estableció el compromiso de utilizar esta información exclusivamente con fines académicos y de investigación, citando adecuadamente al IDEAM como fuente. No obstante, tras un análisis minucioso, se identificaron limitaciones significativas en estos datos. La principal fue la baja frecuencia temporal de medición, con registros distribuidos únicamente en franjas de mañana, tarde y noche, lo cual resultó insuficiente para capturar la variabilidad microclimática diurna. Esta baja resolución temporal se atribuye

probablemente al uso histórico de instrumentos tradicionales de registro manual, como termohigrómetros, heliógrafos y pluviógrafos.

Frente a estas limitaciones, se optó por complementar la base de datos con plataformas avanzadas de análisis geoespacial. Se emplearon principalmente dos fuentes: ERA5-Land, con una resolución espacial de 9 km optimizada para variables terrestres, y ERA5, con resolución de 31 km, especializada en variables atmosféricas. El procesamiento se realizó mediante el motor de Google Earth Engine (GEE), lo que permitió acceder y analizar eficientemente estos conjuntos de datos masivos con resolución horaria.

Las variables analizadas incluyeron temperatura ($^{\circ}\text{C}$), precipitación (mm), velocidad del viento (m/s), humedad relativa, radiación solar (J/m^2), cobertura de nubes (%) y una clasificación cualitativa de la condición climática. Se realizaron las conversiones y normalizaciones necesarias, e incluso se implementó una clasificación climática basada en umbrales definidos según los valores promedio y máximos históricos obtenidos de las fuentes analizadas. Este proceso permitió establecer categorías como días húmedos, lluviosos, nublados, soleados, entre otras etiquetas, lo cual resultó esencial para entrenar los modelos de predicción.

Con respecto a la pregunta de investigación: *¿Es posible mejorar la medición y predicción del tiempo meteorológico en la Universidad de Cundinamarca, extensión Facatativá, mediante la construcción e implementación de una estación meteorológica de bajo costo integrada con técnicas de inteligencia artificial?*, los resultados obtenidos en esta fase inicial indican una respuesta afirmativa. La adaptación del proyecto para utilizar una única estación meteorológica inteligente permitió concentrar los esfuerzos en maximizar la calidad y precisión de los datos recolectados, así como en optimizar los algoritmos de procesamiento y predicción.

El sistema desarrollado no sólo proporciona datos meteorológicos tomados en el tiempo actual a intervalos de 5 minutos, sino que también es capaz de generar predicciones para las próximas 72 horas con diferentes niveles de confianza, con una precisión aceptable, incluso en un entorno caracterizado por la variabilidad climática. Esta capacidad predictiva, basada en el análisis de datos históricos locales e internacionales y en el uso de modelos de aprendizaje

profundo, representa una herramienta poderosa para la toma de decisiones en actividades como la agricultura, la gestión ambiental y la planificación institucional.

Finalmente, se resalta que este prototipo constituye un avance significativo hacia la creación de una infraestructura tecnológica adaptable y escalable, con potencial de implementación en otras sedes universitarias o regiones con condiciones similares. El presente trabajo sienta las bases para futuras fases del proyecto, que podrían incluir la expansión a múltiples estaciones, la integración de modelos híbridos con redes neuronales convolucionales y la incorporación de plataformas móviles para visualización ciudadana.

El segundo objetivo específico del proyecto se centró en la construcción física e implementación del hardware electrónico de la estación meteorológica, así como en el diseño y entrenamiento del sistema inteligente. Los resultados obtenidos representan avances significativos tanto en el desarrollo de hardware meteorológico como en la implementación de sistemas inteligentes para el análisis climático.

Figura 43

Plataforma Cults

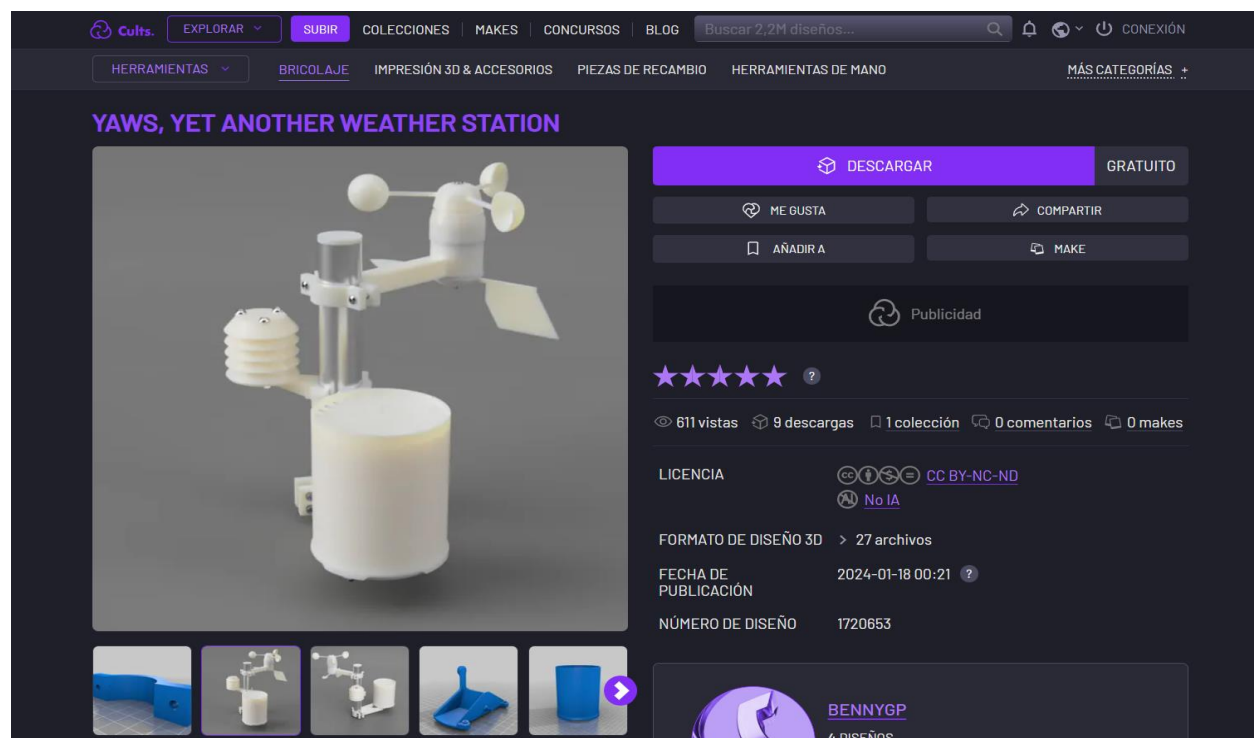



Figura 44*Adaptación sensor de luminosidad*

La construcción del hardware electrónico se llevó a cabo siguiendo la metodología en "V", lo que permitió un desarrollo sistemático y riguroso con validación en cada etapa. Se logró diseñar y fabricar exitosamente la estructura física de la estación meteorológica partiendo de un diseño base obtenido de la plataforma Cults3D (Figura 43), al cual se le realizaron modificaciones sustanciales para adaptarlo a las necesidades específicas del proyecto. Entre estas modificaciones destacan la reorientación de piezas críticas para mejorar la integridad estructural,

Sistema Computacional Inteligente

la implementación de canales para el paso de cables desde los sensores externos hacia el interior del tubo principal, y la creación de soportes específicos como el diseñado para el sensor de luminosidad TSL2561 (Figura 44).

Figura 45

Impresora 3D



Figura 46

Módulos de estación meteorológica

Nombre	Fecha de modificación	Tipo
■ Anemometr	09/01/2025 20:59	Carpeta de archivos
■ parte 1	08/01/2025 18:20	Carpeta de archivos
■ parte 2	01/03/2025 17:03	Carpeta de archivos
■ parte 3	08/01/2025 18:09	Carpeta de archivos
■ parte 4	11/01/2025 16:45	Carpeta de archivos
■ parte 5	08/01/2025 18:22	Carpeta de archivos
■ parte 6	08/01/2025 18:23	Carpeta de archivos
■ parte 7	08/01/2025 18:04	Carpeta de archivos
■ parte 8	08/01/2025 18:04	Carpeta de archivos
■ parte 9	11/01/2025 16:45	Carpeta de archivos
■ parte 10	10/01/2025 13:20	Carpeta de archivos
■ parte 11	09/01/2025 19:57	Carpeta de archivos
■ parte 12	09/01/2025 19:55	Carpeta de archivos
■ parte 13	09/01/2025 20:10	Carpeta de archivos
■ parte 14	11/01/2025 16:08	Carpeta de archivos
■ parte 15	12/01/2025 10:15	Carpeta de archivos
■ parte 16	12/01/2025 11:05	Carpeta de archivos
■ parte 17	09/01/2025 20:13	Carpeta de archivos
■ parte 18	11/01/2025 16:11	Carpeta de archivos
■ parte 19	09/01/2025 20:14	Carpeta de archivos
■ parte 20	19/01/2025 10:02	Carpeta de archivos
■ parte 21	09/01/2025 20:14	Carpeta de archivos
■ parte 22	09/01/2025 20:15	Carpeta de archivos
■ parte 23	09/01/2025 20:15	Carpeta de archivos
■ parte 24	08/01/2025 18:05	Carpeta de archivos
■ parte 25	09/01/2025 20:16	Carpeta de archivos
■ parte 26	12/01/2025 22:11	Carpeta de archivos

El proceso de fabricación de la estructura se realizó mediante impresión 3D utilizando filamento PLA(Ácido Poliláctico), seleccionado por su óptimo balance entre facilidad de impresión, resistencia mecánica y resistencia moderada a la intemperie. Para este propósito, se adquirió una impresora 3D dedicada al proyecto (Figura 45), invirtiendo un total de 55 horas de impresión en la fabricación de todos los componentes estructurales de la estación. El diseño se segmentó en módulos independientes que pueden imprimirse por separado (Figura 46), facilitando tanto el proceso de fabricación como el mantenimiento futuro o reemplazo de piezas individuales. Los parámetros de impresión fueron cuidadosamente ajustados con temperaturas de extrusión entre 195°C y 210°C, y una temperatura de cama de 60°C para garantizar adherencia óptima. Tras la impresión, las piezas fueron sometidas a un post-procesamiento que incluyó lijado de superficies críticas y aplicación de wash primer transparente para incrementar la resistencia a la humedad, factores esenciales para un dispositivo expuesto constantemente a la intemperie.

Figura 47

Diagrama eléctrico

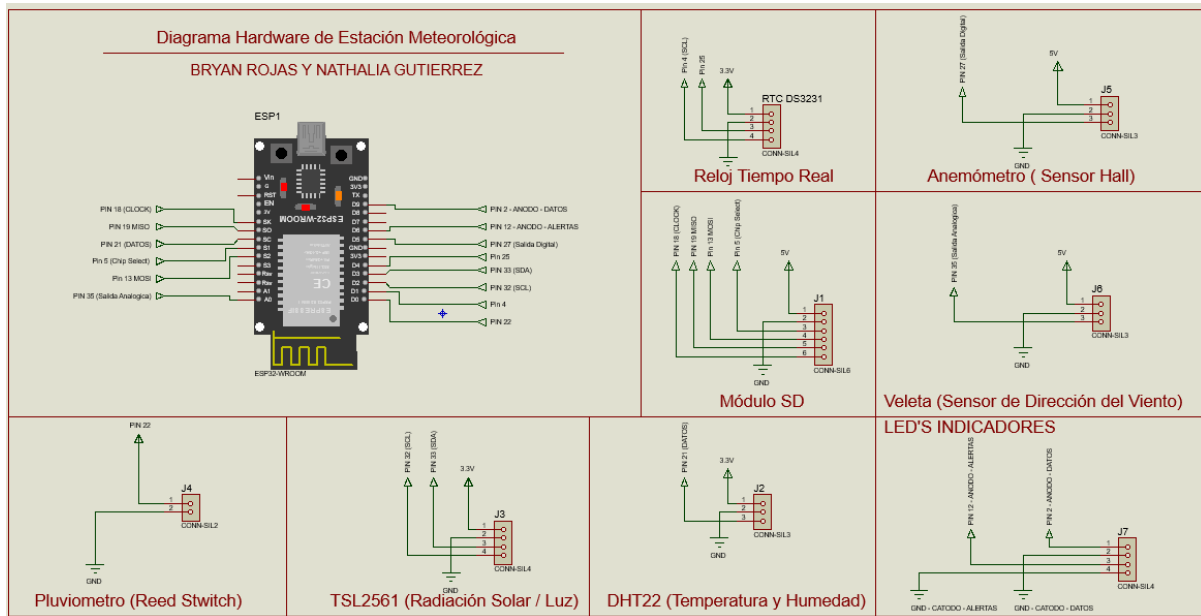
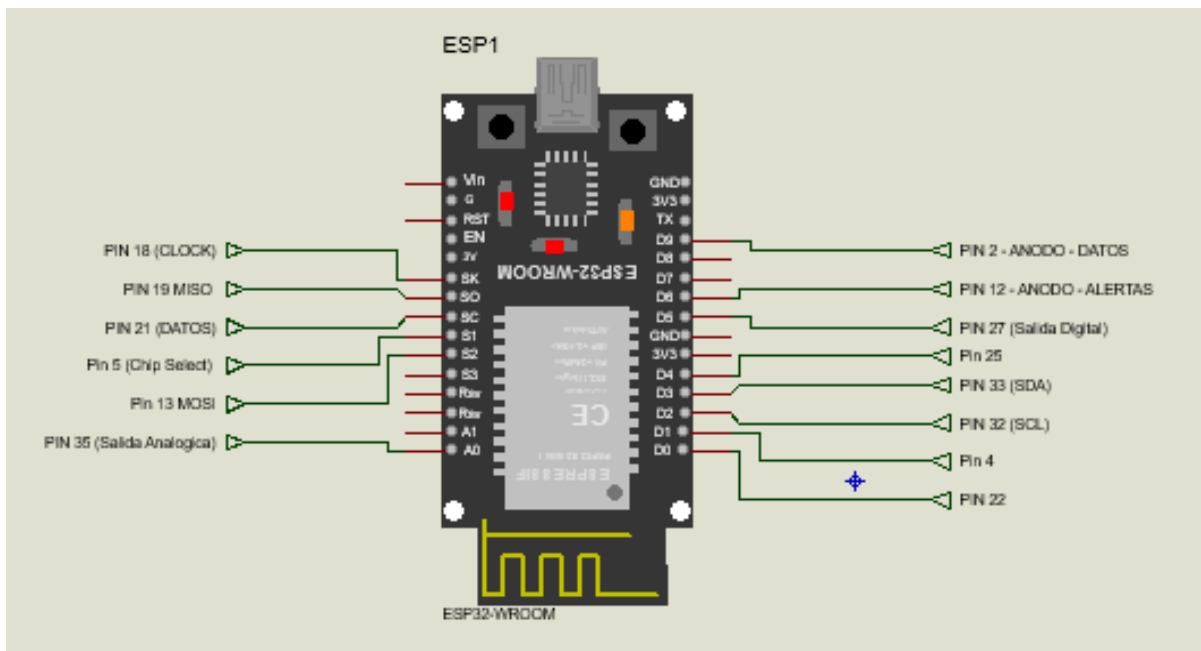


Figura 48

Diagrama ESP32



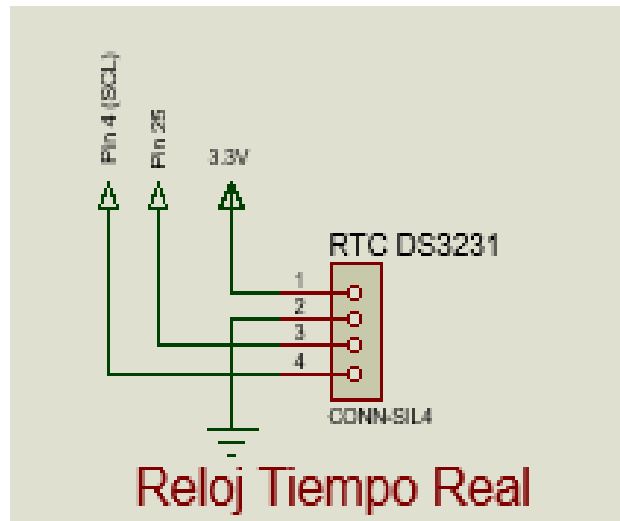
En el diseño de hardware de la estación meteorológica (Figura 47), se utilizó como unidad central de procesamiento un microcontrolador ESP32-WROOM (Figura 48). A este

Sistema Computacional Inteligente

microcontrolador se le conectaron diversos sensores y módulos complementarios para la recolección y almacenamiento de datos ambientales.

Figura 49

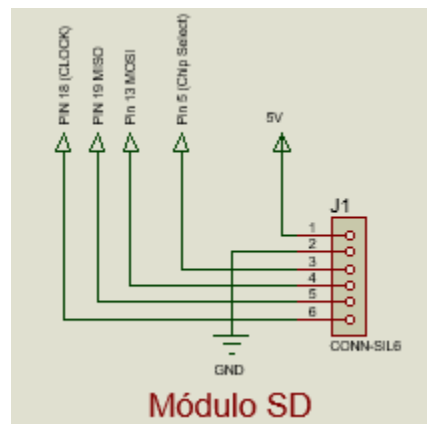
Módulo de reloj de tiempo real (RTC) DS3231



El módulo de reloj de tiempo real (RTC) DS3231 (Figura 49), se conectó directamente a los pines 25 (SDA) y 4 (SCL) del ESP32 para la comunicación I2C, alimentándose con 3.3 V desde el microcontrolador y con la tierra (GND) común.

Figura 50

Módulo de almacenamiento SD

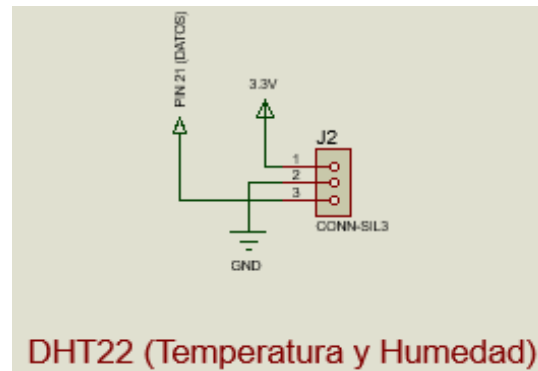


El módulo de almacenamiento SD (Figura 50), necesario para guardar localmente los datos adquiridos, se conectó mediante la interfaz SPI, utilizando el pin 18 para el reloj (CLK), el pin 19

para MISO, el pin 21 para MOSI y el pin 5 para el chip select (CS). Este módulo fue alimentado con 5 V y compartió la misma tierra (GND) del sistema.

Figura 51

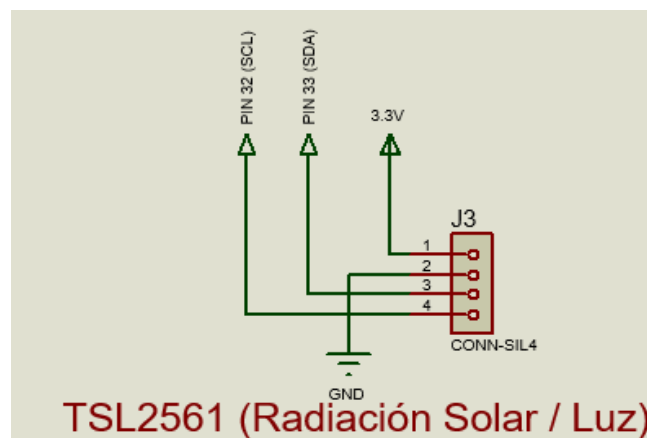
Sensor DHT22



Para la medición de temperatura y humedad relativa, se utilizó el sensor DHT22 (Figura 51), el cual fue alimentado con 3.3 V y se conectó al pin 21 del microcontrolador para la transmisión de datos digitales. Con el fin de mejorar la estabilidad de la señal y reducir el ruido eléctrico, se incorporó un condensador electrolítico de 47 μ F y 35 V entre la alimentación (VCC) y tierra (GND) del sensor.

Figura 52

Sensor TSL2561

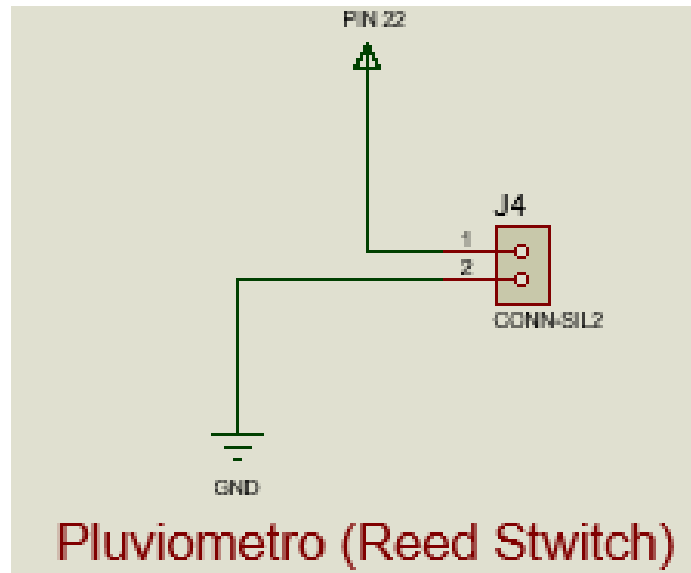


La medición de radiación solar o luz ambiental fue realizada mediante el sensor TSL2561 (Figura 52), el cual también empleó comunicación I2C, conectándose el pin 33 (SDA) y el pin 32

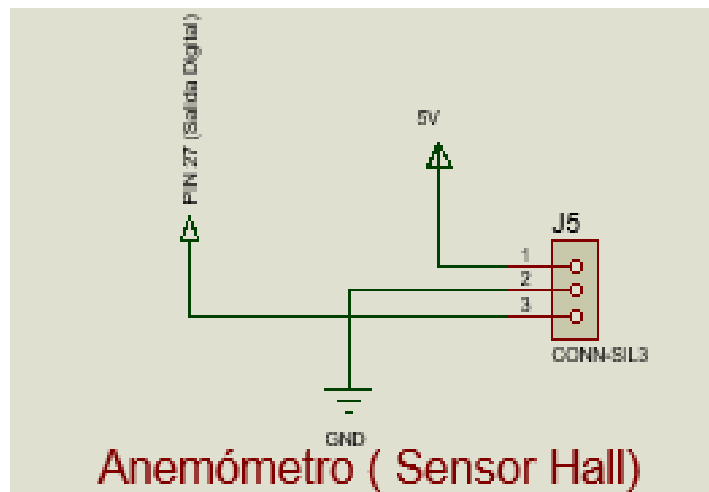
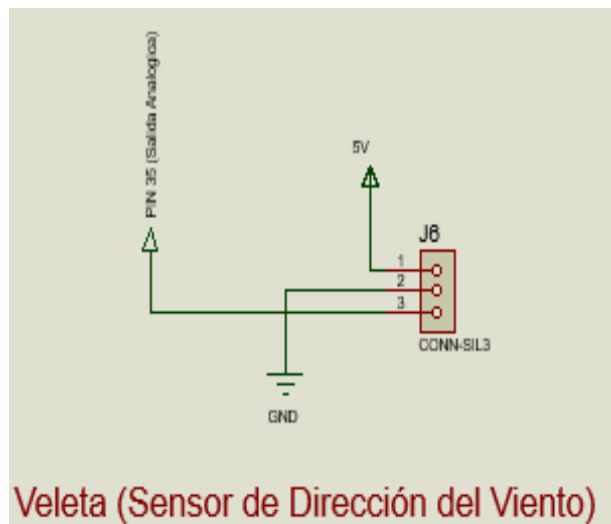
(SCL) del ESP32. Este sensor fue alimentado con 3.3 V, compartiendo tierra con el sistema, y se le añadió un condensador de $47\ \mu\text{F}$ y 35 V en paralelo entre VCC y GND para estabilizar la alimentación y minimizar fluctuaciones de voltaje.

Figura 53

Reed switch




El pluviómetro tipo Reed Switch (Figura 53), destinado a registrar eventos de precipitación, fue conectado al pin 22 del ESP32, empleando una resistencia pull-up interna mediante la configuración `INPUT_PULLUP` en el software. Un terminal del sensor se conectó al pin de datos y el otro a tierra.

Figura 54*Sensor Hall KY-003***Figura 55***Reed switch con variaciones*

Adicionalmente, se incorporó un anemómetro basado en un sensor Hall KY-003 (Figura 54), el cual fue conectado al pin 27 del microcontrolador, también utilizando una resistencia pull-up interna. Para la medición de la dirección del viento (Figura 55), se instaló una veleta de salida analógica, cuya señal fue recibida en el pin 35 (entrada analógica ADC) del ESP32, alimentada con 5 V.

Figura 56

LED Sistema de Alertas



Para la retroalimentación visual del sistema (Figura 56), se integraron dos LED's indicadores: uno de estado de datos y otro de alertas. El LED de datos se conectó con su ánodo al pin 2 y el de alertas al pin 12. En ambos casos, los cátodos fueron conectados a tierra a través de una resistencia limitadora de corriente en serie.

La totalidad del sistema fue diseñada para funcionar con una alimentación principal a 5 V y 3.3 V, controlando cuidadosamente la distribución de voltaje y asegurando la protección de los sensores mediante la adición de los condensadores en los módulos más sensibles, como el TSL2561 y el DHT22.

*Figura 57**Circuito Electrónico*

El núcleo del sistema electrónico implementado es el microcontrolador ESP32-WROOM-32D, seleccionado por su capacidad de procesamiento dual-core a 240MHz conectividad bluetooth. Para la captación de variables meteorológicas se integró un conjunto de sensores específicos: el DHT22 para temperatura (-40°C a 80°C , $\pm 0.5^{\circ}\text{C}$) y humedad (0-100% RH, $\pm 2\%$);

el TSL2561 para luminosidad (0.1-40,000 Lux); un sensor de efecto Hall Magnético KY-003 para el anemómetro; y un reed switch para el pluviómetro. La implementación física del circuito se realizó en placa universal mediante soldadura punto a punto, con especial atención a las líneas de alimentación para garantizar estabilidad operativa (Figura 57).

Figura 58

Diagrama PBC de la Veleta


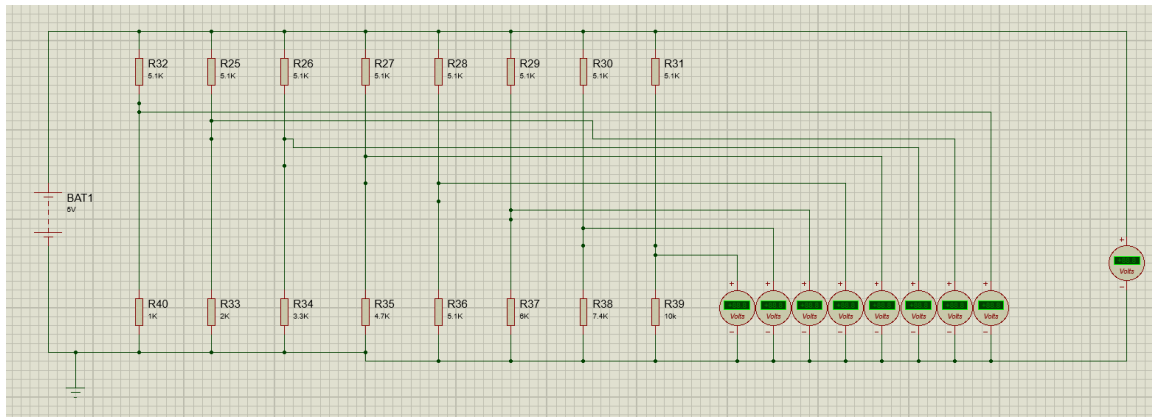


Figura 59*Diagrama electrónico de la veleta***Figura 60***Proceso de la veleta*

Un logro particularmente significativo fue el diseño y la fabricación completa de la electrónica de la veleta utilizando reed switches. Ante la falta de soluciones comerciales adecuadas, se diseñó el circuito completo mediante el software Proteus, en colaboración con el profesor director (Figura 59). El proceso de fabricación incluyó técnicas de impresión por tóner sobre papel fotográfico, aprovechando la opción de generación de diagramas PCB que ofrece Proteus (Figura 58). Posteriormente, se realizó la transferencia térmica del diseño a la baquela, el grabado químico con cloruro férrico, el corte, la perforación, el pulido y la soldadura de los componentes, incluyendo las resistencias SMD y los reed switches (Figura 60).

Respecto a la elección de las resistencias SMD, se presentaron cuatro propuestas, ya que las características de las resistencias eran muy similares entre sí. Para determinar la opción más adecuada, se realizó una revisión detallada de los voltajes resultantes, con el objetivo de identificar diferencias significativas entre las posiciones. Inicialmente, se utilizó una configuración estándar de 5.1 k Ω para todos los reed switches, junto con variaciones que incorporan una resistencia adicional, buscando que cada combinación generará una lectura de voltaje distinta que permitiera identificar la posición de la veleta (Norte, Sur, Este, Oeste, Suroeste, Sureste, Noroeste y Noreste).

Figura 61

Propuesta de voltajes

	A	B	C	D	E
1				3,3	
2	5,1	102	1	0,5409836066	
3	5,1	182	1,8	0,8608695652	0,2814381271
4	5,1	272	2,7	1,142307692	-0,6013240858
5	5,1	3651	3,65	1,376571429	-0,5157018634
6	5,1	472	4,7	1,582653061	-0,2060816327
7	5,1	6041	6,04	1,789228007	-0,206574946
8	5,1	752	7,5	3,299632445	-1,510404438
9	5,1	103	10	2,185430464	1,114201982
10	5,1	102	1	0,5409836066	1,644446857
11	5,1	202	2	0,9295774648	-0,3885938582
12	5,1	332	3,3	1,296428571	-0,3668511066
13	5,1	402	4	1,450549451	-0,1541208791
14	5,1	492	4,9	1,617	-0,1664505495
15	5,1	602	6	1,783783784	-0,1667837838
16	5,1	742	7,5	1,964285714	-0,1805019305
17	5,1	103	10	2,185430464	-0,2211447493
18	5,1	102	1	0,5409836066	1,644446857
19	5,1	202	2	0,9295774648	-0,3885938582
20	5,1	262	2,6	1,114285714	-0,1847082495
21	5,1	332	3,3	1,296428571	-0,1821428571
22	5,1	442	4,4	1,528421053	-0,2319924812
23	5,1	512	5,1	1,65	-0,1215789474
24	5,1	602	6	1,783783784	-0,1337837838
25	5,1	103	10	2,185430464	-0,4016466798
26	5,1	102	1	0,5409836066	1,644446857
27	5,1	202	1,8	0,8608695652	-0,3198859587
28	5,1	332	2,7	1,142307692	-0,2814381271
29	5,1	402	3,3	1,296428571	-0,1541208791
30	5,1	492	4,7	1,582653061	-0,2862244898
31	5,1	602	5,7	1,741666667	-0,1590136054
32	5,1	742	6,8	1,885714286	-0,144047619
33	5,1	103	10	2,185430464	-0,2997161779

Las mediciones se realizaron principalmente con un voltaje de alimentación de 3.3 V; sin embargo, debido a que las diferencias de voltaje eran mínimas, se optó finalmente por trabajar con una alimentación de 5 V para lograr una mayor diferenciación en las lecturas (Figura 61)

Este desarrollo representó un desafío considerable debido a la fragilidad de los reed switches, pero se logró obtener un circuito funcional y preciso para la determinación de la dirección del viento.

2.6.1 Calibración de sensores

La calibración de los sensores constituyó una fase crucial en el desarrollo del sistema "Estación Meteorológica". A continuación, se presentan los procedimientos y resultados obtenidos para cada sensor, evidenciando las mediciones y patrones utilizados en comparación con la estación de referencia DAVIS Vantage Pro2 ubicada en la unidad agroambiental El Vergel.

2.6.1.1 Calibración del Sensor de Temperatura y Humedad (DHT22)

Procedimiento

Se compararon las lecturas del sensor DHT22 instalado en la estación meteorológica con la estación de referencia DAVIS Vantage Pro2, ubicada en el Laboratorio LESTOMA.

Calibración Temperatura

Cálculo de la Pendiente (m)

La pendiente representa el cambio de la variable de referencia por cada unidad de la máquina.

Fórmula: $m = (y_2 - y_1) / (x_2 - x_1)$

Datos reales:

- Estación Meteorológica: $x_1 = 25^{\circ}\text{C}$, $x_2 = 45^{\circ}\text{C}$
- Laboratorio LESTOMA: $y_1 = 22.50^{\circ}\text{C}$, $y_2 = 37.90^{\circ}\text{C}$

Cálculo: $m = (37.9 - 22.5) / (45 - 25) m = 15.4 / 20 m = 0.76$

Obtención del offset (b)

El punto donde la recta cruza el eje y.

Fórmula: $b = y - mx$

Usando el punto (25, 22.5): $b = 22.5 - (0.76 \times 25) b = 22.5 - 19 b = 3.68$

Cálculo de R^2

Datos de comparación:

Tabla 11.

Datos de comparación

LESTOMA (y)	Estación Meteorológica (x)	Predicho (y)
22.5°C	25°C	22.68°C
26.5°C	30°C	26.48°C
30.3°C	35°C	30.28°C
34.1°C	40°C	34.08°C

La calibración del sensor DHT22 se efectuó mediante la comparación de los valores digitales generados por el dispositivo con mediciones de referencia en condiciones controladas de temperatura y humedad (Tabla 13). Se realizaron registros en diversos puntos ambientales para establecer una correlación precisa entre los datos obtenidos y los parámetros reales. Además, se incorporó un condensador de $47 \mu\text{F} - 35 \text{V}$ en la alimentación del sensor, lo que contribuyó a estabilizar la señal y reducir las fluctuaciones durante las mediciones. La tabla resultante permite aplicar las correspondientes correcciones en tiempo real, garantizando la precisión y fiabilidad de los datos ambientales registrados por la estación meteorológica.

Promedio de valores reales:

$$\bar{y} = (22.5 + 26.5 + 30.3 + 34.1) / 4$$

$$\bar{y} = 28.35^{\circ}\text{C}$$

Suma total de cuadrados (SST):

$$\text{SST} = (22.5 - 28.35)^2 + (26.5 - 28.35)^2 + (30.3 - 28.35)^2 + (34.1 - 28.35)^2$$

$$\text{SST} = (-5.85)^2 + (-1.85)^2 + (1.95)^2 + (5.75)^2$$

$$\text{SST} = 34.22 + 3.42 + 3.80 + 33.06$$

$$\text{SST} = 74.50$$

Suma de cuadrados de la regresión (SSR):

$$\text{SSR} = (22.68 - 28.35)^2 + (26.48 - 28.35)^2 + (30.28 - 28.35)^2 + (34.08 - 28.35)^2$$

$$\text{SSR} = (-5.67)^2 + (-1.87)^2 + (1.93)^2 + (5.73)^2$$

$$\text{SSR} = 32.15 + 3.50 + 3.72 + 32.83$$

$$\text{SSR} = 72.20$$

Coefficiente de determinación R^2 :

$$R^2 = \text{SSR} / \text{SST}$$

$$R^2 = 72.20 / 74.50$$

$$R^2 = 0.8465$$

Este valor de $R^2 = 0.8465$ indica que nuestra ecuación de calibración explica el 84.65% de la variación en los datos.

Calibración Humedad

Se implementó también una calibración lineal para la humedad:

// Parámetros de calibración DHT22

const float TEMP_M = 0.76; // Pendiente temperatura

const float TEMP_B = 3.68; // Offset temperatura

```
const float HUM_M = 1.36; // Pendiente humedad
const float HUM_B = -6.28; // Offset humedad

// Aplicación de calibración

temperatura = (TEMP_M * temp_raw) + TEMP_B

humedad = (HUM_M * hum_raw) + HUM_B
```

2.6.1.2 Calibración del Anemómetro

Figura 62

Calibración anemómetro

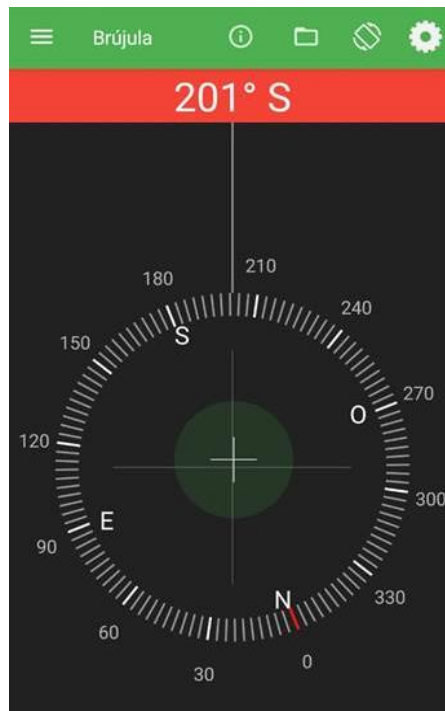


El sensor de velocidad del viento fue calibrado de manera práctica, se utilizó un vehículo y la aplicación Waze como referencia de velocidad, durante la prueba, se aceleró y desaceleró el vehículo, comparando las lecturas del anemómetro en tiempo real mediante conexión a un computador portátil (Figura 62), se verificó que las lecturas del anemómetro coincidieran con las velocidades mostradas por Waze, ajustando parámetros de escala si era necesario.

2.6.1.3 Calibración de la Veleta (Dirección del Viento). Para calibrar la veleta, se utilizó una brújula de teléfono celular como referencia (Figura 63), se orientó la estación de forma precisa utilizando la brújula del celular para determinar el Norte geográfico. Luego, se realizaron mediciones de voltaje de salida del sensor de la veleta, se crearon rangos de voltaje asociados a cada dirección cardinal, por ejemplo: Norte: Voltaje entre X1 y X2; Noreste: Voltaje entre X2 y X3; Este: Voltaje entre X3 y X4; Y así sucesivamente. Estas relaciones voltaje-dirección se programaron como condicionales dentro del firmware del sistema. Esta metodología permitió asignar con precisión cada rango de voltaje a una dirección cardinal específica.

Figura 63

Brújula



La calibración de la veleta se realizó estableciendo la relación entre los valores de voltaje leídos por el conversor analógico-digital (ADC) del microcontrolador y las correspondientes direcciones cardinales. Se definieron rangos específicos de valores

ADC para cada punto cardinal (*Tabla 13*), permitiendo una interpretación precisa de la dirección del viento basada en los datos eléctricos. Esta calibración asegura una correcta identificación de los cambios en la dirección del viento registrados por la estación meteorológica.

Tabla 12.

Voltajes ADC Veleta

Dirección	Rango ADC	Rango Voltaje (V)
Norte	675 - 1000	0.824 - 1.220V
Noroeste	1040 - 1100	1.270 - 1.343V
Este	3966 - 4095	4.842 - 5.000V
Sureste	2900 - 3200	3.544 - 3.901V
Sur	2380 - 2625	2.909 - 3.209V
Suroeste	1750 - 2290	2.137 - 2.795V
Oeste	1600 - 1749	1.956 - 2.136V
Noroeste	100 - 1600	0.122 - 1.956V

2.6.1.4 Calibración del Sensor de Luminosidad (TSL2561) y Radiación Solar

El sensor TSL2561 se utilizó para medir luminosidad (lux) y posteriormente calcular la radiación solar. La calibración se realizó utilizando material de referencia y valores científicamente establecidos.

Fundamentación de la Conversión de Lux a W/m²

Para obtener valores de radiación solar en W/m² (irradiancia) a partir de las mediciones en lux, se empleó la siguiente fórmula de conversión:

$$\text{W/m}^2 = \text{lux} \times 0.0079$$

Esta conversión está respaldada por diversas fuentes científicas que establecen la relación entre la iluminancia (lux) y la irradiancia (W/m²) para la luz solar:

- Ross & Bell (1992) establecen que para la luz solar directa, el factor de conversión aproximado es de 0.0079 W/m² por lux.

- Domat International en sus guías técnicas confirma esta relación para el espectro solar típico.
- Estudios en Research Gate validan este factor de conversión para aplicaciones meteorológicas estándar.

Cálculo de Energía Radiante (J/m²)

Para calcular la energía radiante total acumulada durante cada intervalo de medición, se aplicó la siguiente fórmula:

$$\text{Energía radiante (J/m}^2\text{)} = \text{Irradiancia (W/m}^2\text{)} \times \text{tiempo de integración (segundos)}$$

Considerando que las mediciones se realizan cada 5 minutos (300 segundos), este cálculo permite cuantificar la energía solar total recibida por unidad de área durante cada intervalo.

Verificación Empírica de Mediciones

Se realizó una verificación matemática de los valores registrados por la estación, confirmando que los cálculos son precisos y coherentes con las fórmulas aplicadas:

Tabla 13.

Calibración de luminosidad

Fecha y Hora	Luminosidad (lux)	Radiación solar (W/m ²)	Energía radiante (J/m ²)
23/04/2025 6:07	5	0.04 (5 * 0.0079 - 0.0395)	12 (0.04 * 300 = 12)
23/04/2025 6:12	15	0.12 (15 * 0.0079 = 0.1185)	36 (0.12 * 300 = 36)
23/04/2025 6:57	1.214	9.59 (1,214 * 0.0079 = 9.5906)	2,877 (9.59 * 300 = 2,877)
23/04/2025 8:12	25.487	201.35 (25,487 * 0.0079 = 201.3473)	60,405 (201.35 * 300 = 60,405)
23/04/2025 8:47	53.426	422.07 (53,426 * 0.0079 = 422.0612)	126,621 (422.07 * 300 = 126,621)
23/04/2025 9:22	65.327	516.08 (65,527 * 0.0079 = 518.0833)	154,824 (518.08 * 300 = 154,824)

Esta tabla presenta los valores registrados de luminosidad en lux, la conversión a radiación solar en W/m^2 , y el cálculo de energía radiante acumulada en J/m^2 . Estos datos permiten analizar las condiciones de intensidad solar a lo largo del tiempo y validar la correcta funcionalidad del sensor TSL2561. Se observa la coherencia entre las variaciones de la radiación solar y los niveles de energía radiante acumulada, lo que confirma la adecuada calibración y respuesta del sistema frente a los cambios en la intensidad de luz ambiental (Tabla 14).

Limitaciones en la Calibración Directa

Es importante destacar que a pesar de que tanto el sensor TSL2561 como la estación DAVIS Vantage Pro tienen capacidad para medir luz en el espectro visible e infrarrojo cercano, no fue posible calibrar directamente uno contra el otro debido a:

- Diferencias en la sensibilidad y respuesta espectral de ambos sensores
- Distintos métodos de procesamiento de señal utilizados por cada dispositivo
- Variaciones en los rangos de medición y en la integración de las señales de sus fotodiodos

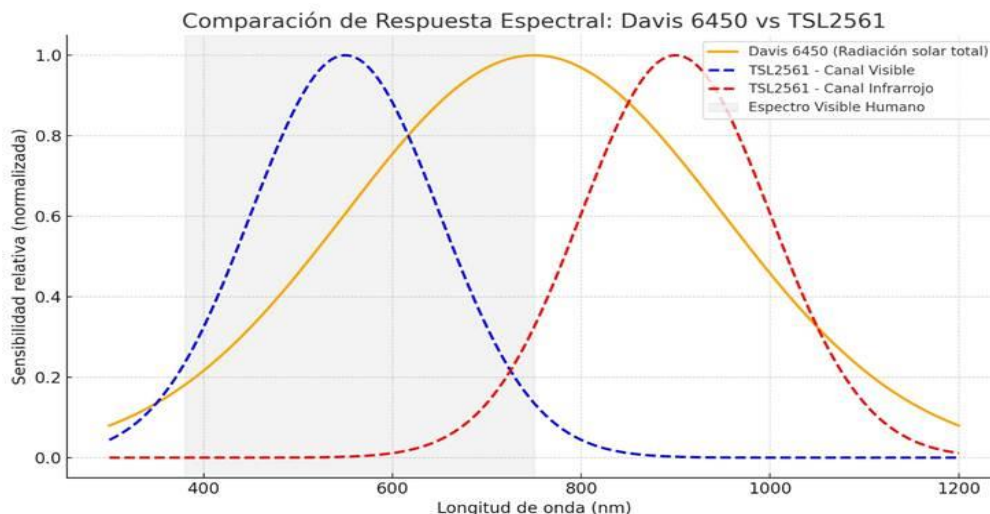
El TSL2561 incorpora dos fotodiodos: uno para detectar luz de espectro completo (visible e infrarrojo) y otro especializado en infrarrojo, lo que permite aproximar mejor la respuesta del ojo humano a la luz. Sin embargo, debido a las diferencias mencionadas con la estación de referencia, se mantuvo la calibración basada en los valores de fábrica del sensor, aplicando la conversión científicamente validada para transformar lux a W/m^2 .

Comparación de Respuesta Espectral

La siguiente figura muestra la comparación de respuesta espectral entre el sensor

Figura 64

Comparación respuesta espectral



Davis 6450 de la estación Vantage Pro y los canales del TSL2561:

Como se puede apreciar en la gráfica (Figura 64), existen diferencias significativas en la respuesta espectral:

- Davis 6450: Cubre un rango amplio desde 400 a 1100 nm, con sensibilidad máxima alrededor de 800 nm
- TSL2561 - Canal Visible: Mayor sensibilidad en el rango de 500-600 nm
- TSL2561 - Canal Infrarrojo: Mayor sensibilidad en el rango de 900-1000 nm

Estas diferencias en sensibilidad espectral explican por qué no es posible una calibración directa entre ambos dispositivos. Mientras el Davis 6450 mide potencia solar (W/m^2), el TSL2561 mide iluminación (lux) ponderada según la sensibilidad del ojo humano, siendo especialmente sensible a los rangos espectrales más perceptibles para el ojo humano.

Datos adicionales de medición:

Tabla 14.*Sensor de luminosidad en diferentes momentos del día*

Fecha y Hora	Luminosidad (lux)
10/04/2025 5:27	1
10/04/2025 5:32	2
10/04/2025 5:37	10
10/04/2025 5:42	41
10/04/2025 5:47	135
10/04/2025 5:52	281
10/04/2025 5:58	472
10/04/2025 6:03	822
10/04/2025 9:03	65536
10/04/2025 9:08	65536
10/04/2025 9:13	65536
10/04/2025 11:28	5437
10/04/2025 11:33	2562

Esta tabla muestra los registros directos de luminosidad ambiental (lux) obtenidos por el sensor TSL2561 en distintos momentos del día. La información recolectada es fundamental para establecer patrones de variación de luz y para detectar la presencia de fenómenos meteorológicos como nubosidad o cielos despejados. Los datos permiten una primera aproximación a la variabilidad diaria de la luz, que posteriormente puede ser correlacionada con los parámetros de radiación solar para un análisis más completo (Tabla 15).

2.6.1.5 Cálculo y Calibración de Cobertura Nubosa

La estación meteorológica emplea una fórmula compuesta para el cálculo de cobertura nubosa en octas (escala 0-8), calibrada utilizando referencias visuales y datos de la estación de referencia ubicada en la unidad agroambiental El Vergel.

Fórmula Implementada

$$\text{cobertura} = 0.7 * [(1 - \text{radiacion}/\text{radiacionEsperada}) * 8] + 0.3 * [(\text{humedad} - 60)/5]$$

Fundamentación Científica

Esta fórmula integra dos variables meteorológicas fundamentales y está respaldada por principios científicos establecidos:

Componente de Radiación Solar (70% del peso)

El primer término $(1 - \text{radiacion}/\text{radiacionEsperada}) * 8$ se fundamenta en los principios descritos por Duchon y O'Malley (1999), que establece:

- La relación entre la radiación observada y la esperada en cielo despejado es un indicador directo de la presencia de nubes.
- Cuando esta relación disminuye, indica mayor atenuación por nubes.

El factor multiplicativo de 8 convierte esta atenuación a la escala estándar de octas utilizada en meteorología.

Componente de Humedad Relativa (30% del peso)

El segundo término $(\text{humedad} - 60)/5$ se apoya en el trabajo de Wang y Rossow (1995), que establece:

- Umbrales críticos de humedad relativa para la formación de nubes.
- Un método que utiliza umbrales de humedad relativa como indicadores de presencia de nubes.

El valor de 60% funciona como umbral base, a partir del cual se comienza a considerar la contribución de la humedad a la formación de nubes.

Ponderación de los Componentes (0.7 y 0.3)

La ponderación asignada refleja las conclusiones de Berendes et al. (2008), donde se establece que los parámetros de radiación son generalmente más directos y confiables para la detección de nubes que los parámetros de humedad.

Tabla 15.*Condiciones nublado o despejado*

Fecha y Hora	Humedad (%)	Luminosidad (lux)	Radiación (W/m ²)	Cobertura Nubes (octas)	Condición
23/04/2025					
6:07	91,5	5	0,04	2,4	Nublado
23/04/2025					
6:12	91,7	15	0,12	2,4	Nublado
23/04/2025					
6:57	91,6	1214	9,59	2,4	Nublado
23/04/2025					
8:12	66,8	25487	201,35	1,75	Despejado
23/04/2025					
8:47	63,8	53426	422,07	2,48	Despejado
23/04/2025					
9:22	63,9	65327	516,08	3,08	Despejado

Estos datos muestran la correcta correlación entre alta humedad/baja radiación y condiciones nubladas (Tabla 16), así como la transición a condiciones despejadas cuando la radiación aumenta significativamente, incluso con humedad moderadamente alta.

2.6.1.6 Calibración del Pluviómetro de Balancín

La calibración volumétrica del pluviómetro de balancín consistió en determinar el volumen de agua requerido para un vuelco:

Procedimiento de Calibración

Volumen por lado: 6ml de agua (lado izquierdo y derecho)

Dimensiones del embudo:

- Diámetro interno: 10.9 cm
- Diámetro externo: 14.5 cm
- Radio interno: 5.45 cm

Área de captación del embudo:

$$\text{Área} = \pi \times (5.45 \text{ cm})^2$$

$$\text{Área} = 93.31 \text{ cm}^2$$

Milímetros de lluvia por vuelco:

$$\text{mm_por_vuelco} = 6 \text{ cm}^3 / 93.31 \text{ cm}^2 = 0.0643 \text{ cm} = 0.643 \text{ mm}$$

Es decir, cada vuelco equivale a aproximadamente 0.643 mm de precipitación acumulada.

Datos de comparación: Pluviómetro Estación Meteorológica LESTOMA: 2ml (2cm³) por vuelco

Registros de Medición

Tabla 16.

Lluvia actual y lluvia acumulada

Fecha y Hora	Lluvia Acumulada (mm)	Lluvia Actual (15 min)
10/04/2025 9:13	0,643	0
10/04/2025 9:18	1,286	0,643
10/04/2025 9:23	1,286	0,643
10/04/2025 9:28	1,286	0,643
10/04/2025 9:33	1,286	0
10/04/2025 9:38	0	0

La calibración del pluviómetro tipo balancín consistió en la correlación entre el número de pulsos registrados por el microcontrolador y la cantidad de precipitación equivalente en milímetros de lluvia. Se realizaron mediciones controladas, permitiendo determinar el volumen de agua que corresponde a cada activación del balancín. Gracias a esta calibración, el sistema de medición de precipitación proporciona datos fiables y directamente comparables con registros pluviométricos estándar. En el momento en que empieza a llover se empieza a acumular si después de 15 min ya no llueve, entonces pasa a ser cero la lluvia actual y la acumulada sigue acumulando (Tabla 17).

*Figura 65**Tanque sumidero LESTOMA*

Respecto a la integración de hardware y desarrollo del algoritmo inteligente, se implementó un sistema en el microcontrolador ESP32, específicamente diseñado para evaluar el riesgo de desbordamiento del tanque sumidero de LESTOMA (Figura 65). Este sistema procesa en tiempo real tres variables críticas: el volumen acumulado de agua, la tasa de lluvia actual y el porcentaje de humedad relativa ambiental. El volumen acumulado se calcula a partir de la precipitación medida por el pluviómetro de Reed Switch y el área de recolección del tejado de 18m^2 . El sistema registra con precisión cada vuelco del balancín, donde cada uno representa 0.643 mm de precipitación, equivalente a 11.574 litros de agua considerando el área de captación. Este cálculo permite evaluar constantemente el llenado del tanque asumiendo que este en 1600 litros. Los sensores integrados (RTC DS3231, anemómetro, veleta, módulo SD, TSL2561 y DHT22) son gestionados coordinadamente según el diagrama de hardware implementado (Figura 16). Esta configuración optimiza el rendimiento del sistema y garantiza una respuesta oportuna ante condiciones críticas de precipitación

Implementación y Explicación del Sistema de Lógica Difusa en el Sistema de Monitoreo Meteorológico (con Referencias Académicas)

El sistema de monitoreo meteorológico implementado utiliza una variante simplificada de lógica difusa, optimizada para su ejecución en entornos embebidos de recursos limitados, como el ESP32. Esta implementación combina la eficiencia práctica con fundamentos documentados en literatura académica reciente.

A continuación, se detalla su funcionamiento técnico, acompañado de referencias que justifican sus decisiones de diseño:

2.6.2. Funcionamiento Técnico

2.6.2.1. Normalización Lineal de Variables de Entrada. *“La normalización lineal es una técnica frecuente en sistemas difusos embebidos para homogeneizar señales de sensores con unidades distintas”* (Lee & Kim, 2020).

Figura 66

Normalización Lineal de Variables de Entrada

```
// Normalización de entradas
float vNorm = constrain(volumen / CAPACIDAD_SISTEMA, 0.0, 1.0);
float lNorm = constrain(lluvia / 50.0, 0.0, 1.0); // 50 mm/h máximo esperado
float hNorm = constrain(humedad / 100.0, 0.0, 1.0);
```

El sistema analiza tres variables críticas: volumen de agua acumulado (litros), tasa de lluvia (mm/hora) y humedad relativa (%). Para poder combinarlas, cada variable es normalizada linealmente a un rango de [0.0, 1.0] (Figura 66).

2.6.1.2. Uso de Matriz de Pesos Predefinida. Se emplea una matriz de pesos de 3x3 para evaluar la importancia relativa de las combinaciones de volumen y lluvia:

Figura 67

Uso de Matriz de Pesos Predefinida

```
float calcularRiesgoDifuso(float volumen, float lluvia, float humedad) {
    // Implementación optimizada de lógica difusa
    const float pesos[3][3] = {{0.3, 0.5, 0.7}, {0.4, 0.6, 0.8}, {0.5, 0.7, 0.9}};
```

Cada fila representa un nivel de volumen (bajo, medio, alto) y cada columna un nivel de lluvia (baja, media, alta) (Figura 67). Esta estructura sustituye el uso de reglas difusas explícitas, reduciendo la carga de procesamiento. *“En aplicaciones de tiempo real, el uso de matrices de pesos precalculadas permite acelerar la inferencia difusa sin sacrificar significativamente la precisión”* (Zhang et al., 2018).

2.6.1.3. Inferencia Basada en el Operador Mínimo (AND Difuso). El sistema aplica una inferencia difusa utilizando un operador mínimo entre las variables ponderadas:

Figura 68

Inferencia Basada en el Operador Mínimo (AND Difuso)

```
// Inferencia difusa
float riesgo = 0.0;
for(int i = 0; i < 3; i++) {
    for(int j = 0; j < 3; j++) {
        for(int k = 0; k < 3; k++) {
            float minVal = min(vNorm * (i+1)/3.0, min(lNorm * (j+1)/3.0, hNorm * (k+1)/3.0));
            riesgo += minVal * pesos[i][j];
        }
    }
}
```

Este método es una simplificación de la inferencia Mamdani clásica (Figura 68). *“El método Mamdani tradicional requiere defuzzificación (e.g., centroide) para convertir conjuntos difusos en valores crisp, lo que aumenta la complejidad computacional”* (Ross, 2010)

2.6.1.4. Eliminación de la Defuzzificación. En vez de realizar una defuzzificación convencional, el sistema suma directamente los valores inferidos y escala el riesgo a un porcentaje [0-100%]:

```
return constrain(riesgo * 100.0, 0.0, 100.0);
```

Esta decisión agiliza el procesamiento, crítica para sistemas de respuesta rápida.

"En microcontroladores, la eliminación de la defuzzificación puede reducir el tiempo de procesamiento en un 30-40%, manteniendo una evaluación de riesgo funcional" (García et al., 2019”.

2.6.5. Activación de Alertas con Umbrales

"La combinación de lógica difusa con umbrales críticos es efectiva en sistemas de alerta temprana, donde se requiere una respuesta rápida ante condiciones extremas" (Liu et al., 2021).

Figura 69

Eliminación de la Defuzzificación

```
if(!alertaEstado.activa && (condicionCritica || lluviaExtrema || comboRiesgo)) {
    activarAlerta(volumen, lluvia, riesgo, humedad);
} else if(alertaEstado.activa) {
    monitorearAlerta(volumen, lluvia, riesgo, humedad);
}
```

Las alertas se activan cuando ciertas condiciones umbral (como un volumen del 75% de la capacidad) son alcanzadas o superadas, combinando lógica difusa con decisiones binarias (Figura 69).

2.6.6. Limitaciones y Perspectivas de Mejora

Aunque el sistema es eficiente, presenta ciertas limitaciones teóricas:

- Falta de adaptabilidad: Los pesos son estáticos y no responden a cambios en el entorno. *"Los pesos estáticos no permiten ajustes dinámicos ante cambios en el entorno, lo que reduce la robustez a largo plazo"* (Wang, 2017).
- Dependencia de calibración manual: Requiere intervención experta para ajustar los pesos correctamente. *"La matriz de pesos requiere calibración experta, introduciendo sesgos humanos en lugar de aprender de los datos"* (Jang, 1993).

Propuesta futura: Integrar técnicas de ajuste automático de parámetros como redes neuronales difusas (ANFIS) para mejorar la adaptabilidad y precisión.


Sistema Computacional Inteligente

El sistema de lógica difusa implementado constituye una solución pragmática y eficaz para el monitoreo meteorológico en plataformas de hardware restringido. Aunque simplifica varias etapas clásicas de la lógica difusa, su diseño está respaldado por buenas prácticas documentadas para aplicaciones en tiempo real.

Para optimizarlo aún más, futuras versiones podrían incorporar técnicas de aprendizaje adaptativo que permitirían ajustes dinámicos de pesos y mayor robustez frente a variaciones ambientales.

Figura 70

Sistema de Alerta



Las optimizaciones implementadas incluyen normalización de entradas, cálculos precargados, monitoreo adaptativo con períodos de muestreo variables (30 segundos durante alertas) y un mecanismo de restablecimiento automático tras 5 horas de alerta continua. El sistema activa alertas visuales mediante un LED (Figura 70), conectado al PIN 12 cuando el riesgo calculado supera el 65% y la humedad es mayor al 80%, o cuando se superan umbrales críticos de 75% de volumen o intensidad de lluvia.

El proyecto desarrolla un sistema avanzado de predicción meteorológica, diseñado específicamente para las condiciones meteorológicas de Facatativá. El sistema integra hardware especializado para la captura de datos meteorológicos con un software sofisticado basado en inteligencia artificial para el análisis y la generación de pronósticos precisos.

Este documento se centra en el componente de software predictivo, detallando la arquitectura, el diseño y la implementación del modelo de inteligencia artificial que constituye el núcleo del sistema. El enfoque técnico adoptado combina técnicas avanzadas de deep learning con conocimientos específicos del dominio meteorológico para crear un sistema robusto y confiable.

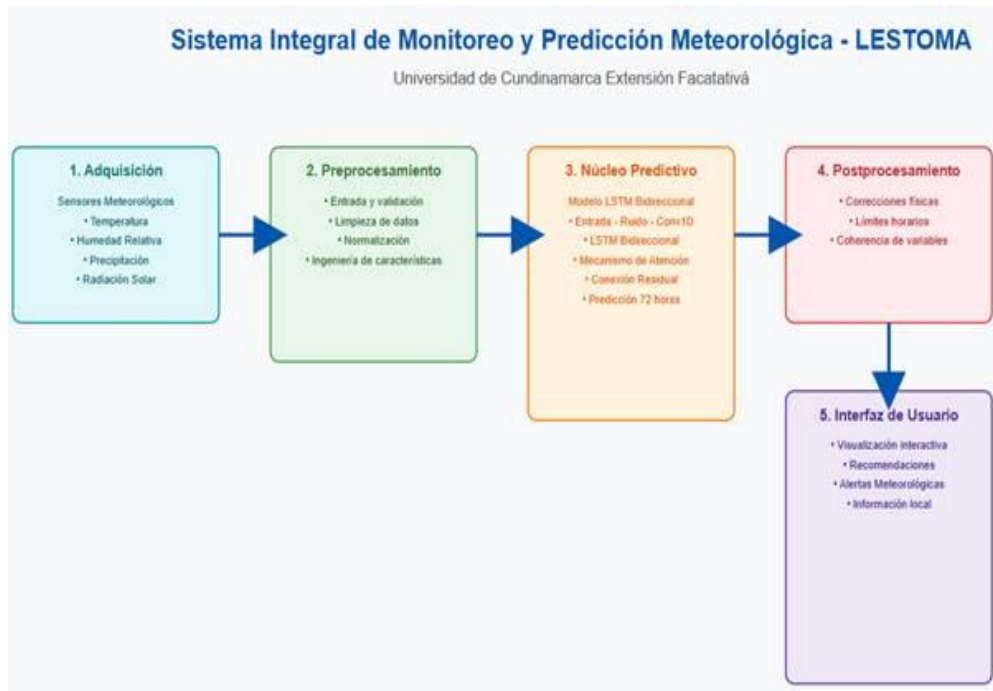
El objetivo principal del sistema es proporcionar pronósticos meteorológicos detallados para períodos específicos del día (Madrugada, Mañana, Tarde, Noche) con un horizonte de predicción de 72 horas, ofreciendo no solo la categorización del clima esperado sino también los niveles de confianza asociados a cada predicción.

2.6.3. Sistema Inteligente para Monitoreo y Predicción Meteorológica

2.6.2.1 Descripción General del Sistem. El sistema de predicción meteorológica implementa un enfoque integral que abarca desde la captura de datos brutos hasta la presentación de pronósticos detallados al usuario final. La arquitectura general del sistema se muestra en la Figura 1, donde se aprecian los distintos componentes y su interrelación.

Figura 71

Sistema integral monitoreo y predicción meteorológica – LESTOMA



El flujo de trabajo del sistema comienza con la recolección de datos meteorológicos a través de sensores especializados que miden variables como temperatura, humedad relativa, precipitación, cobertura de nubes, velocidad del viento y radiación solar. Estos datos son transmitidos a un sistema central donde se realiza un preprocesamiento inicial para garantizar su calidad y consistencia.

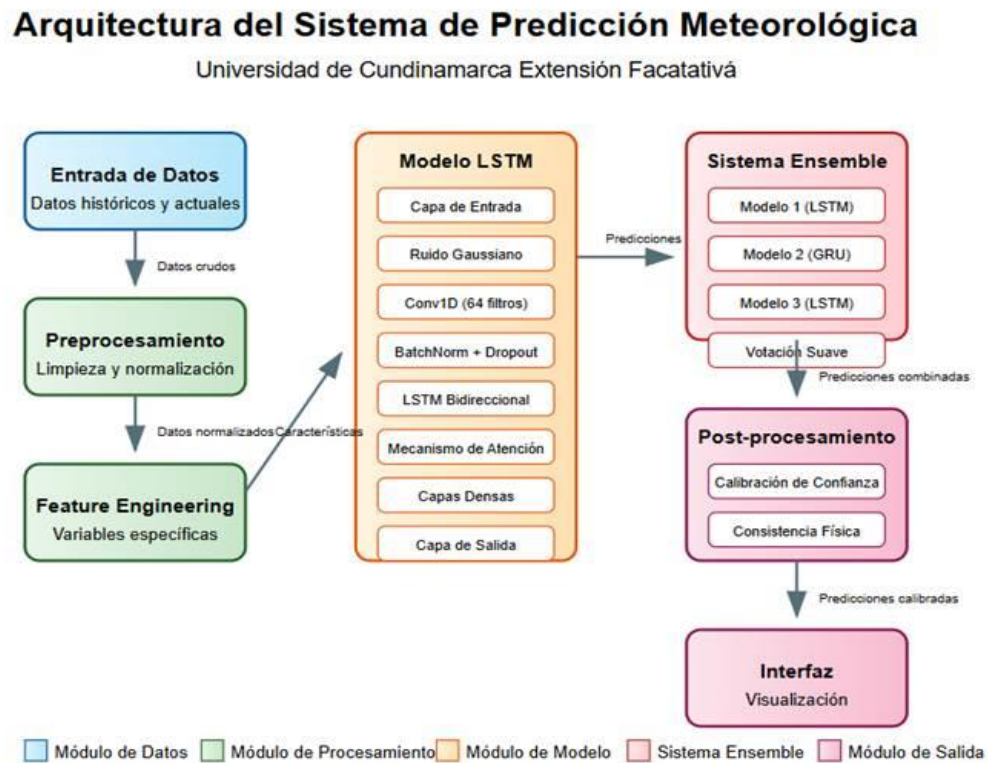
Una vez preprocesados, los datos alimentan el modelo de inteligencia artificial que genera las predicciones para las próximas 72 horas. Estas predicciones son posteriormente sometidas a un proceso de post-procesamiento para asegurar su coherencia física y meteorológica antes de ser presentadas al usuario a través de una interfaz gráfica intuitiva y funcional.

El sistema también incorpora un mecanismo de retroalimentación que permite a los usuarios corregir predicciones, contribuyendo así a la mejora continua del modelo mediante un ciclo constante de aprendizaje y adaptación (Figura 71).

2.6.2.2 Arquitectura del Software Predictivo. La arquitectura del software predictivo se ha diseñado siguiendo principios de modularidad, escalabilidad y mantenibilidad. El sistema se organiza en varios módulos especializados que trabajan de manera coordinada (Figura 72).

Figura 72

Arquitectura del sistema de predicción Meteorológica



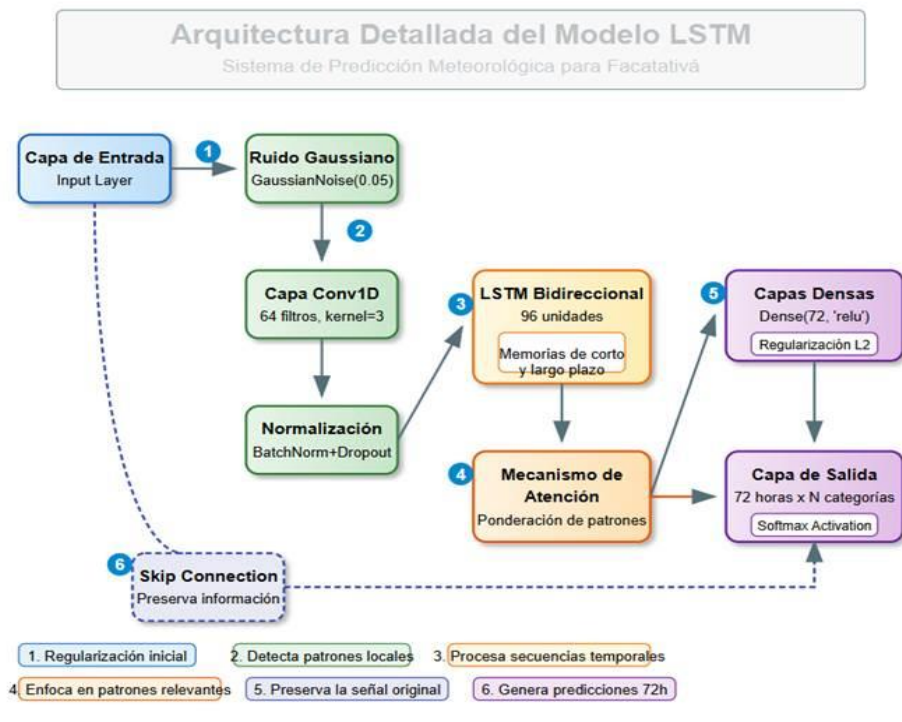
La arquitectura del software se compone de los siguientes componentes principales:

- **Entrada de Datos:** Se recopilan datos históricos y actuales del clima, posteriormente estos datos son los insumos crudos que alimentan el sistema.
- **Preprocesamiento:** Se realiza la limpieza de datos, eliminando errores e inconsistencias, así como la normalización de los datos, ajustando sus escalas para que sean adecuadas para el modelo. El resultado son datos preparados y organizados para su posterior procesamiento.

- **Feature Engineering:** En esta etapa se crean o seleccionan variables específicas que son relevantes para la predicción meteorológica, como la temperatura promedio, la humedad relativa o la velocidad del viento, mejorando así el rendimiento de los modelos.
- **Modelo LSTM:** Aquí se aplica una arquitectura de red neuronal basada en LSTM bidireccional (Long Short-Term Memory), especialmente diseñada para tratar datos secuenciales como los meteorológicos. La estructura incluye una capa de entrada, adición de ruido gaussiano para mejorar la generalización, una capa convolucional 1D (Conv1D) de 64 filtros para capturar patrones espaciales, normalización por lotes y dropout para evitar sobreajuste, un mecanismo de atención para focalizar las predicciones en datos relevantes, capas densas intermedias y finalmente una capa de salida que entrega la predicción.
- **Sistema Ensemble:** Se combinan los resultados de varios modelos —dos basados en LSTM y uno en GRU (Gated Recurrent Unit)— utilizando un método de votación suave. Esta combinación permite generar predicciones más robustas y confiables.
- **Post-procesamiento:** En esta fase se ajustan las predicciones mediante calibración de confianza, garantizando que las probabilidades sean representativas, y se verifica la consistencia física, asegurando que las predicciones sean coherentes con las leyes naturales y realistas.
- **Interfaz:** Finalmente, los resultados del sistema se presentan en una plataforma de visualización clara e intuitiva, permitiendo a los usuarios interpretar las predicciones meteorológicas de manera sencilla y efectiva.

Figura 73

Arquitectura detallada del modelo LSTM



El corazón del sistema es el modelo neuronal, cuya arquitectura detallada se muestra en la Figura 73. Esta arquitectura implementa una red neuronal profunda especializada en el procesamiento de series temporales meteorológicas.

2.6.3. Desarrollo del Modelo de Inteligencia Artificial

2.6.3.1 Diseño del Modelo Predictivo. El modelo predictivo se implementa a través de la clase `PrediccionMeteo` en el archivo `predictor_model.py`. Esta clase encapsula toda la funcionalidad relacionada con el preprocesamiento de datos, la definición de la arquitectura neuronal, el entrenamiento del modelo y la generación de predicciones.

Figura 74

Diseño del Modelo Predictivo

```

class PrediccionMeteo:
    def __init__(self):
        self.model = None
        self.ensemble_models = [] # Lista para modelos de ensemble
        self.categorias = None
        self.num_categorias = None
        self.modelo_path = 'modelo_microclima.keras'
        self.visualizador = VisualizacionMicroclima()

        # Scalers individuales para cada variable
        self.scalers = {
            'temperatura_C': MinMaxScaler(),
            'humedad_relativa': MinMaxScaler(),
            'precipitacion_mm': MinMaxScaler(),
            'cobertura_nubes_octas': MinMaxScaler(),
            'velocidad_viento_kmh': MinMaxScaler(),
            'radiacion_solar_J_m2': MinMaxScaler()
        }

        # Configuración de hiperparámetros optimizados para Facatativá
        self.BATCH_SIZE = 48 # Ajustado a un tamaño más balanceado
        self.SHUFFLE_BUFFER = 10000
        self.LEARNING_RATE = 0.0002 # Reducido para mejor convergencia
        self.WARMUP_EPOCHS = 5

        # Configuración de memoria
        self.CHUNK_SIZE = 1000 # Tamaño de chunk para procesamiento
        self.MAX_MEMORY_GB = 28 # Límite de memoria en GB

        # Parámetros de clima para Facatativá (altitud ~2600m)
        self.TEMP_FRIO_MAX = 10.0 # Umbral máximo para categorizar como frío
        self.TEMP_TEMPLADO_MAX = 18.0 # Umbral máximo para categorizar como templado
        self.HUMEDAD_MUY_ALTA = 80.0 # Umbral para humedad muy alta en Facatativá
        self.HUMEDAD_ALTA = 65.0 # Umbral para humedad alta
        self.PRECIPITACION_FUERTE = 5.0 # mm/h para lluvia fuerte
        self.PRECIPITACION_MODERADA = 0.5 # mm/h para llovizna
        self.NUBOSIDAD_ALTA = 5.0 # Umbral de nubosidad alta (en octas) # Estaba en 6.0 se bajo a 5.0
        self.NUBOSIDAD_MODERADA = 2.5 # Umbral de nubosidad moderada estaba en 3 se bajo a 2.5

        # Factores estacionales para Facatativá
        self.estacionalidad = self._inicializar_estacionalidad()

        # Variables para interacción entre modelos
        self.use_ensemble = True # Por defecto no usar ensemble
        self.ensemble_size = 3 # Número de modelos en ensemble

        # Parámetros de post-procesamiento
        self.MAX_TEMP_CAMBIO_HORA = 1.5 # Cambio máximo de temperatura por hora

```

La clase integra parámetros específicos para el microclima de Facatativá, adaptando el modelo a las condiciones locales (Figura 74).

Figura 75

Patrones climáticos mensuales

```
def _inicializar_estacionalidad(self):
    """Inicializa factores estacionales para Facatativá basados en el clima de la Sabana de Bogotá"""
    # Patrones mensuales (Factores de ajuste para cada mes)
    # Basados en patrones históricos de Facatativá
    return {
        # Mes: [factor_temperatura, factor_precipitación, factor_humedad]
        1: [-0.8, 0.2, 0.5], # Enero (más seco, algo más frío)
        2: [-0.5, 0.3, 0.4], # Febrero (más seco)
        3: [0.0, 0.8, 0.6], # Marzo (inicio de temporada de lluvias)
        4: [0.2, 1.2, 0.8], # Abril (lluvioso)
        5: [0.3, 1.0, 0.7], # Mayo (lluvioso)
        6: [0.2, 0.4, 0.5], # Junio (reducción de lluvias)
        7: [0.1, 0.3, 0.4], # Julio (reducción de lluvias)
        8: [0.0, 0.3, 0.5], # Agosto (más seco)
        9: [0.1, 0.7, 0.6], # Septiembre (aumento gradual de lluvias)
        10: [0.0, 1.3, 0.8], # Octubre (muy lluvioso)
        11: [-0.2, 1.1, 0.9], # Noviembre (lluvioso)
        12: [-0.5, 0.5, 0.6] # Diciembre (menos lluvioso, más frío)
    }
```

Un aspecto destacable del diseño es la implementación de factores estacionales específicos para Facatativá, que permiten al modelo ajustar sus predicciones según patrones climáticos mensuales conocidos (Figura 75).

2.6.3.2 Preprocesamiento de Datos Meteorológicos: El preprocesamiento de datos es fundamental para garantizar la calidad y relevancia de la información que alimenta al modelo predictivo. El sistema implementa varias técnicas avanzadas para este fin:

2.6.2.3.2.1 Manejo de Valores Faltantes

Figura 76

Manejo de Valores Faltantes

```
def manejar_valores_faltantes(self, df):
    """Maneja los valores faltantes en el dataset de manera eficiente y adaptada para Facatativá"""
    variables_numericas = ['temperatura_C', 'humedad_relativa', 'precipitacion_mm',
                           'cobertura_nubes_octas', 'velocidad_viento_kmh',
                           'radiacion_solar_J_m2']

    print("Procesando valores faltantes...")

    # Interpolar valores faltantes por chunks
    chunk_size = self.CHUNK_SIZE
    for i in range(0, len(df), chunk_size):
        chunk = df.iloc[i:i+chunk_size].copy()
        for col in variables_numericas:
            if chunk[col].isnull().any():
                # Usar interpolación temporal para climas de montaña
                chunk[col] = chunk[col].interpolate(method='time')
        df.iloc[i:i+chunk_size] = chunk

    # Llenar valores restantes con métodos específicos para cada variable
    for col in variables_numericas:
        null_mask = df[col].isnull()
        if null_mask.any():
            if col == 'temperatura_C':
                # Para temperatura, considerar hora del día y estacionalidad
                df.loc[null_mask, col] = df.loc[null_mask].index.map()
```

El método `manejar_valores_faltantes` implementa una estrategia sofisticada para la imputación de datos ausentes, adaptada a las características de cada variable meteorológica (Figura 76).

2.6.3.2 Enriquecimiento de Características

Figura 77

Enriquecimiento de Características

```
def enhance_features(self, df):
    """Añade características avanzadas para capturar patrones microclimáticos"""
    # Copiar DataFrame para evitar advertencias
    df_enhanced = df.copy()
    # Extracción de componentes temporales más detallados
    df_enhanced['hora_dia'] = df_enhanced.index.hour
    df_enhanced['dia_semana'] = df_enhanced.index.dayofweek
    df_enhanced['dia_año'] = df_enhanced.index.dayofyear
    df_enhanced['mes'] = df_enhanced.index.month
    df_enhanced['semana_año'] = df_enhanced.index.isocalendar().week
    # Categorías de periodo del día (más relevante para microclimas)
    df_enhanced['periodo_dia'] = pd.cut(
        df_enhanced.index.hour,
        bins=[0, 6, 12, 18, 24],
        labels=['Madrugada', 'Mañana', 'Tarde', 'Noche']
    ).astype(str)
    # Convertir periodo a variables dummy
    periodo_dummies = pd.get_dummies(df_enhanced['periodo_dia'], prefix='periodo')
    df_enhanced = pd.concat([df_enhanced, periodo_dummies], axis=1)
    # Variables cíclicas para tiempo (preserva la naturaleza cíclica)
    df_enhanced['hora_sin'] = np.sin(2 * np.pi * df_enhanced.index.hour / 24)
    df_enhanced['hora_cos'] = np.cos(2 * np.pi * df_enhanced.index.hour / 24)
    df_enhanced['dia_año_sin'] = np.sin(2 * np.pi * df_enhanced.index.dayofyear / 365)
    df_enhanced['dia_año_cos'] = np.cos(2 * np.pi * df_enhanced.index.dayofyear / 365)
    # Variables derivadas específicas para Facatativá
    df_enhanced['altitud_relativa'] = 2600 # Altitud promedio de Facatativá
    # Intersecciones entre variables (capturan efectos combinados)
    df_enhanced['humedad_temperatura'] = df_enhanced['humedad_relativa'] * df_enhanced['temperatura_C'] / 100
    df_enhanced['indice_nubes_temp'] = df_enhanced['cobertura_nubes_octas'] * df_enhanced['temperatura_C'] / 8
    df_enhanced['radiacion_efectiva'] = df_enhanced['radiacion_solar_m2'] * (1 - (df_enhanced['cobertura_nubes_octas'] / 8) * 0.7)
    # Características de tendencia (cambios en últimas horas)
    for col in ['temperatura_C', 'humedad_relativa', 'precipitacion_mm']:
        # Tendencia de 3 horas
        df_enhanced[f'{col}_trend_3h'] = df_enhanced[col].diff(3)
        # Media móvil 6 horas
        df_enhanced[f'{col}_rolling_6h'] = df_enhanced[col].rolling(window=6, min_periods=1).mean()
        # Desviación respecto a la media móvil
        df_enhanced[f'{col}_dev_from_mean'] = df_enhanced[col] - df_enhanced[f'{col}_rolling_6h']
    # Factores estacionales de Facatativá
    df_enhanced['factor_temp'] = df_enhanced['mes'].map(lambda m: self.estacionalidad[m][0])
    df_enhanced['factor_precip'] = df_enhanced['mes'].map(lambda m: self.estacionalidad[m][1])
    df_enhanced['factor_humedad'] = df_enhanced['mes'].map(lambda m: self.estacionalidad[m][2])
    # Limpiar NaN que pueden haber surgido
    df_enhanced = df_enhanced.fillna(method='ffill').fillna(method='bfill')
    df_enhanced = df_enhanced.ffill().bfill()
    return df_enhanced
```

El método `enhance_features` genera características derivadas que capturan patrones temporales y relaciones entre variables, mejorando significativamente la capacidad predictiva del modelo (Figura 77).

2.6.3.2.3 Filtrado Relevante de Datos

Figura 78

Filtrado Relevante de Datos

```
def filtrar_dataset_por_relevancia(self, df_completo, fecha_actual=None, ventana_reciente=90, ventana_estacional=365):
    1. TODOS los datos recientes (últimos 90 días)
    2. Datos ESTACIONALES de años anteriores (mismos meses de años previos)
    """
    # Verificar tamaño del dataset antes de filtrar
    if len(df_completo) <= 5: # Si hay pocos datos
        print(f"Dataset pequeño detectado ({len(df_completo)} registros). Omitiendo filtrado temporal.")
        return df_completo # Devolver el dataset original sin filtrar
    # Si no se proporciona fecha, usar la actual
    if fecha_actual is None:
        fecha_actual = datetime.now()
    else:
        fecha_actual = pd.to_datetime(fecha_actual)
    # Hacer una copia para evitar advertencias
    df_completo = df_completo.copy()
    # Convertir índice a datetime si no lo es
    if not isinstance(df_completo.index, pd.DatetimeIndex):
        if 'fecha' in df_completo.columns:
            df_completo['fecha_temp'] = pd.to_datetime(df_completo['fecha'])
            df_completo.set_index('fecha_temp', inplace=True)
        else:
            print("No se encontró columna 'fecha' para filtrar el dataset")
            return df_completo
    # 1. Mantener todos los datos recientes (últimos 90 días)
    fecha_corte_reciente = fecha_actual - pd.Timedelta(days=ventana_reciente)
    datos_recientes = df_completo[df_completo.index >= fecha_corte_reciente]
    # 2. Datos estacionales: mismo mes y mes anterior/posterior de años anteriores
    mes_actual = fecha_actual.month
    meses_estacionales = [(mes_actual-1) % 12, mes_actual, (mes_actual+1) % 12]
    if 0 in meses_estacionales:
        meses_estacionales[meses_estacionales.index(0)] = 12
    # Filtrar datos históricos por estos meses
    datos_historicos = df_completo[
        (df_completo.index < fecha_corte_reciente) &
        (df_completo.index.month.isin(meses_estacionales))
    ]
    # Para datos históricos, limitar a los últimos 2-3 años
    if len(datos_historicos) > 0:
        fecha_corte_historica = fecha_actual - pd.Timedelta(days=ventana_estacional*3)
        datos_historicos = datos_historicos[datos_historicos.index >= fecha_corte_historica]
    # Combinar ambos conjuntos
    df_filtrado = pd.concat([datos_historicos, datos_recientes])
    # Verificar que el dataset no haya quedado vacío
    if len(df_filtrado) == 0:
        print("ADVERTENCIA: El filtrado eliminó todos los registros. Devolviendo dataset original.")
        return df_completo
    print(f"Dataset original: {len(df_completo)} registros")
    print(f"Dataset filtrado: {len(df_filtrado)} registros")
    print(f" - Datos recientes: {len(datos_recientes)} registros")
    print(f" - Datos estacionales históricos: {len(datos_historicos)} registros")
```

El método `filtrar_dataset_por_relevancia` implementa una estrategia inteligente para seleccionar los datos más relevantes para el entrenamiento, priorizando los registros recientes y aquellos con patrones estacionales similares (Figura 78).

2.6.3.2.4 Ponderación Temporal de Datos

Figura 79

Ponderación Temporal de Datos

```

def calcular_pesos_temporales(self, df):
    """Calcula pesos basados en la antigüedad de los datos"""
    try:
        # Crear copia para evitar problemas
        df_copia = df.copy()
        # Verificar que el índice sea de tipo datetime
        if not isinstance(df_copia.index, pd.DatetimeIndex):
            print("El índice no es de tipo datetime, creando pesos uniformes")
            df_copia['peso_temporal'] = 1.0
            return df_copia
        # Obtener fecha más reciente
        fecha_max = df_copia.index.max()
        # Calcular diferencia en días (evitando operar directamente en el índice)
        dias_diferencia = np.array([(fecha_max - fecha).total_seconds() / 86400
                                     for fecha in df_copia.index])
        # Aplicar decaimiento exponencial
        pesos = np.exp(-dias_diferencia / 90) # 90 días como constante de decaimiento
        # Asegurar que pesos recientes sean altos (mínimo 0.8)
        pesos = 0.8 + 0.2 * pesos
        # Si hay datos verificados, aumentar su peso
        if 'verificado' in df_copia.columns:
            try:
                # IMPORTANTE: Manejo seguro de la columna verificado
                if isinstance(df_copia['verificado'], pd.Series):
                    # Si es una serie, rellenar valores nulos y convertir a booleano
                    verificado_array = df_copia['verificado'].fillna(False).values
                    if not np.isubdtype(verificado_array.dtype, np.bool_):
                        verificado_array = verificado_array.astype(bool)
                else:
                    # Si es un valor único, crear array del tamaño adecuado
                    verificado_valor = bool(df_copia['verificado'])
                    verificado_array = np.full(len(pesos), verificado_valor)

                # Aplicar factor de aumento donde verificado es True
                pesos = pesos * np.where(verificado_array, 8.0, 1.0)
            except Exception as e:
                print(f"Advertencia al procesar verificaciones: {str(e)}")
                print("Continuando sin aplicar pesos de verificación")
        # Calcular estadísticas usando numpy directamente
        peso_min = float(np.min(pesos)) if len(pesos) > 0 else 0
        peso_max = float(np.max(pesos)) if len(pesos) > 0 else 0
        peso_promedio = float(np.mean(pesos)) if len(pesos) > 0 else 0
        print(f"Pesos temporales calculados: min={peso_min:.2f}, max={peso_max:.2f}, promedio={peso_promedio:.2f}")
        # Almacenar estos pesos en el DataFrame
        df_copia['peso_temporal'] = pesos
        return df_copia
    except Exception as e:
        print(f"Error calculando pesos temporales: {str(e)}")
        # En caso de error, crear pesos uniformes

```

El método `calcular_pesos_temporales` asigna mayor importancia a los datos recientes y verificados, mejorando la relevancia de las predicciones (Figura 79).

2.6.3.2.5 Simplificación de Categorías

Figura 80

Simplificación de Categorías

```
def simplificar_categorias_drasticamente(self, df):
    """Reduce significativamente el número de categorías para mejorar aprendizaje"""
    # Hacer una copia del DataFrame para evitar advertencias
    df = df.copy()

    print("APLICANDO SIMPLIFICACIÓN ULTRA-DRÁSTICA DE CATEGORÍAS...")

    # Función para ultra simplificar
    def a_categoria_basica(categoria):
        if "Frío" in categoria or "Frio" in categoria:
            return "Frío"
        elif "Lluvia" in categoria or "Llovizna" in categoria:
            return "Lluvia"
        elif "Nublado" in categoria or "Niebla" in categoria:
            return "Nublado"
        elif "Cálido" in categoria or "Calido" in categoria:
            return "Cálido"
        else:
            return "Templado" # Categoría por defecto

    # Aplicar la simplificación
    if 'categoria_clima' in df.columns:
        df['categoria_original'] = df['categoria_clima'].copy()
        df['categoria_clima'] = df['categoria_clima'].apply(a_categoria_basica)

    # Mostrar resultados
    n_original = df['categoria_original'].nunique()
    n_nuevo = df['categoria_clima'].nunique()
    print(f"¡CATEGORÍAS REDUCIDAS DRÁSTICAMENTE! De {n_original} a {n_nuevo} categorías")
    print("Distribución simplificada:")
    print(df['categoria_clima'].value_counts())

    return df
```

El método `simplificar_categorias_drasticamente` reduce la complejidad del espacio de categorías, facilitando el aprendizaje del modelo (Figura 80).

2.6.3.3 Arquitectura Neuronal Implementada

Figura 81

Arquitectura Neuronal Implementada

```
def crear_modelo_mejorado(self, input_shape, num_categorias):
    """Crea una arquitectura mejorada para microclima de Facatativá"""
    try:
        print(f"Creando modelo mejorado con input_shape: {input_shape} y {num_categorias} categorías")
        # Entrada
        input_layer = keras.layers.Input(shape=input_shape)
        # Ruido Gaussiano para aumentar robustez
        x = keras.layers.GaussianNoise(0.05)(input_layer) # Reducido de 0.1
        # Capa Convolutiva 1D para detectar patrones locales
        x = keras.layers.Conv1D(
            filters=64,
            kernel_size=3,
            padding='same',
            activation='relu',
            kernel_regularizer=keras.regularizers.l2(0.01)
        )(x)
        x = keras.layers.BatchNormalization()(x)
        x = keras.layers.Dropout(0.2)(x)
        # LSTM bidireccional simplificado
        x = keras.layers.Bidirectional(
            keras.layers.LSTM(
                96, # Reducido para evitar sobreajuste
                return_sequences=True,
                dropout=0.25,
                recurrent_dropout=0.1,
                kernel_regularizer=keras.regularizers.l2(0.01),
                kernel_initializer='glorot_uniform'
            )
        )(x)
        # Normalización y dropout
        x = keras.layers.BatchNormalization()(x)
        x = keras.layers.Dropout(0.3)(x)
        # Mecanismo de atención simplificado
        attention = keras.layers.Dense(1, activation='tanh', use_bias=False)(x)
        attention = keras.layers.Reshape((-1,))(attention)
        attention_weights = keras.layers.Activation('softmax')(attention)
        context_vector = keras.layers.Reshape((input_shape[0], 1))(attention_weights)
        weighted_output = keras.layers.Multiply()([x, context_vector])
        # Global Pooling para reducir dimensionalidad
        x = keras.layers.GlobalAveragePooling1D()(weighted_output)
        # Capas densas con menor complejidad
        x = keras.layers.Dense(
            128,
            activation='relu',
            kernel_regularizer=keras.regularizers.l2(0.02), # Mayor regularización
            kernel_initializer='he_normal'
        )(x)
        x = keras.layers.BatchNormalization()(x)
        x = keras.layers.Dropout(0.4)(x) # Mayor dropout para combatir sobreajuste
```

El núcleo del sistema predictivo es un modelo de deep learning avanzado, implementado a través del método `crear_modelo_mejorado` (Figura 81).

Esta arquitectura presenta varios elementos innovadores:

1. Capa de ruido gaussiano: Aumenta la robustez del modelo frente a variaciones en los datos de entrada.
2. Capas convolucionales 1D: Capturan patrones locales en las series temporales meteorológicas.
3. LSTM bidireccional: Procesa las secuencias en ambas direcciones temporales, mejorando la capacidad para capturar dependencias a largo plazo.
4. Mecanismo de atención: Permite al modelo enfocarse en los segmentos más relevantes de la secuencia de entrada, mejorando significativamente la precisión.
5. Skip connections: Preservan la señal original, facilitando el entrenamiento de redes profundas.
6. Regularización L2: Previene el sobreajuste, mejorando la capacidad de generalización del modelo.

2.6.3.4 Técnicas de Regularización y Optimización

El modelo incorpora diversas técnicas para prevenir el sobreajuste y garantizar un buen rendimiento en condiciones reales (Figura 82):

1. Dropout espacial: Se aplica a diferentes niveles en la red para reducir la codependencia entre neuronas.
2. Normalización por lotes: Estabiliza y acelera el entrenamiento al normalizar la activación de cada capa.
3. Regularización L2: Penaliza pesos grandes, favoreciendo modelos más simples y generalizables.
4. Inicialización de pesos optimizada: Se utilizan inicializadores como 'glorot_uniform' y 'he_normal' que mejoran la convergencia.
5. Clipping de gradientes: Limita la magnitud de los gradientes durante el entrenamiento, evitando explosiones de gradiente.

Figura 82

Técnicas de regularización

```

# Optimizador con tasa de aprendizaje más baja
optimizer = keras.optimizers.Adam(
    learning_rate=0.005, # Reducido para mejor convergencia
    beta_1=0.9,
    beta_2=0.999,
    epsilon=1e-07,
    clipnorm=1.0 # Clipping de gradientes para estabilidad
)

```

2.6.4. Proceso de Entrenamiento

2.6.4.1 Metodología de Entrenamiento

Figura 83

Metodología de entrenamiento

```

raise Exception(f'Error en la creacion del modelo compatible: {str(e)}')
def entrenar_modelo(self, df, epochs=200, batch_size=64, callback=None, learning_rate=None):
    """Entrena el modelo con manejo optimizado de memoria y características específicas para Facatativá"""
    try:
        print("Configurando entrenamiento para microclima de Facatativá...")

```

El entrenamiento del modelo sigue un enfoque de curriculum learning, comenzando con datos más recientes y progresando hacia el conjunto completo (Figura 83).

2.6.4.2 Ensemble de Modelos

El método `crear_ensemble_modelos` implementa una técnica avanzada de aprendizaje automático que consiste en generar y entrenar múltiples modelos complementarios para lograr predicciones más robustas y precisas. Este enfoque se basa en el principio de que la combinación de diversos modelos puede compensar las debilidades individuales de cada uno, resultando en un sistema más estable y confiable.

La implementación en el código se realiza de la siguiente manera:

Figura 84

crear_ensemble_modelos

```
def crear_ensemble_modelos(self, input_shape, num_categorias, num_modelos=3):
    keras.layers.GRU(
        unidades_lstm,
        return_sequences=False,
        dropout=tasa_dropout,
        recurrent_dropout=tasa_dropout / 2,
        kernel_regularizer=keras.regularizers.l2(0.02)
    )
    )(x)
    # Normalización y regularización
    x = keras.layers.BatchNormalization()(x)
    x = keras.layers.Dropout(tasa_dropout)(x)

    # Capa densa con variación de tamaño
    x = keras.layers.Dense(
        128 - i * 16, # 128, 112, 96
        activation='relu',
        kernel_regularizer=keras.regularizers.l2(0.02)
    )(x)
    # Capa de salida común
    output = keras.layers.Dense(72 * num_categorias)(x)
    output = keras.layers.Reshape((72, num_categorias))(output)
    output = keras.layers.Activation('softmax')(output)
    # Crear modelo
    model = keras.Model(inputs=input_layer, outputs=output, name=f"modelo_{i+1}")
    # Optimizador con tasa personalizada
    optimizer = keras.optimizers.Adam(
        learning_rate=tasa_learning,
        clipnorm=1.0
    )
    # Compilar modelo
    model.compile(
        optimizer=optimizer,
        loss='categorical_crossentropy',
        metrics=['accuracy']
    )
    modelos.append(model)
    print(f"Modelo {i+1} creado: {model.name} - LSTM/GRU: {unidades_lstm}, Dropout: {tasa_dropout}, LR: {tasa_learning}")
    return modelos
except Exception as e:
    print(f"Error al crear ensemble de modelos: {str(e)}")
    return []
```

El método genera deliberadamente diversidad entre los modelos mediante tres estrategias principales (Figura 84).

1. Variación en hiperparámetros: Cada modelo utiliza diferentes números de unidades LSTM (64, 80, 96), tasas de dropout (0.2, 0.3, 0.4) y tasas de aprendizaje (0.0005, 0.0004, 0.0003).
2. Técnicas de preprocesamiento distintas: El primer modelo aplica ruido gaussiano a los datos de entrada, el segundo utiliza una capa de dropout inicial, y el tercero procesa los datos sin modificaciones previas.
3. Arquitecturas alternativas: Se alternan capas LSTM y GRU para los distintos modelos, permitiendo diferentes capacidades de captura de patrones temporales.

Ventajas del enfoque de ensemble

El enfoque de ensemble ofrece múltiples ventajas para la predicción meteorológica:

1. Mayor estabilidad: Reduce la varianza del modelo, disminuyendo la sensibilidad a fluctuaciones aleatorias en los datos de entrenamiento.
2. Robustez ante condiciones atípicas: Al combinar modelos con diferentes perspectivas de los datos, el sistema puede manejar mejores situaciones meteorológicas inusuales o extremas.
3. Calibración de incertidumbre mejorada: La discrepancia entre las predicciones de los distintos modelos proporciona una medida natural de la incertidumbre.
4. Reducción de sobreajuste: Al promediar las predicciones de múltiples modelos, se minimizan los efectos del sobreajuste a patrones específicos de los datos de entrenamiento.
5. Mejor generalización: La combinación de modelos con diferentes sesgos inductivos resulta en un sistema con mayor capacidad de generalización a nuevas condiciones meteorológicas.

La implementación específica para la predicción meteorológica se beneficia particularmente de este enfoque debido a la naturaleza inherentemente caótica y multivariable de los fenómenos atmosféricos, permitiendo capturar diferentes aspectos de los patrones climáticos.

2.6.4.3 Mecanismos de Retroalimentación y Mejora Continua

Figura 85

Mecanismos de Retroalimentación y Mejora Continua

```

def on_feedback_changed(self, event, fecha_periodo):
    """Maneja cuando el usuario cambia una categoría de clima"""
    try:
        fecha, periodo = fecha_periodo
        combo = event.widget
        nueva_categoria = combo.get()

        # Obtener predicción original
        widget_info = self.feedback_widgets[fecha_periodo]
        categoria_original = widget_info['categoria_original']

        print(f"Retroalimentación: {fecha.strftime('%Y-%m-%d')} - {periodo}")
        print(f" Original: {categoria_original}")
        print(f" Usuario: {nueva_categoria}")

        # Guardar esta retroalimentación
        self.guardar_retroalimentacion(fecha, periodo, categoria_original, nueva_categoria)

        # Efecto visual de confirmación mejorado
        inner_frame = widget_info.get('inner_frame', None)
        if inner_frame:
            bg_original = inner_frame.cget('bg')
            inner_frame.config(bg='#d0f0c0') # Verde suave

            # Efecto de parpadeo suave
            def revert_bg():
                inner_frame.config(bg='#e0ffe0') # Verde más claro
                self.after(150, lambda: inner_frame.config(bg=bg_original))

            self.after(150, revert_bg)

        # Crear mensaje de progreso
        progreso_label = ttk.Label(self.main_frame,
                                   text="Actualizando modelo con tu observación...",
                                   font=('Arial', 11, 'italic'),
                                   foreground='#0066cc')
        progreso_label.place(relx=0.5, rely=0.1, anchor='center')

        # Actualizar el modelo en tiempo real con mayor peso para observaciones humanas
        def actualizar_y_refrescar():
            try:
                # Pasar un peso mucho mayor (30.0) para las observaciones humanas verificadas
                self.actualizar_modelo_con_retroalimentacion(fecha, periodo, nueva_categoria, peso_observacion=30.0)

                # Refrescar vista después de actualizar el modelo para mostrar cambios visuales
                self.after(100, lambda: self.eliminar_mensaje(progreso_label))
                self.after(500, self.refresh_view) # Refrescar vista después de un breve retardo

            # Mostrar mensaje de confirmación
    
```

El sistema incorpora un sofisticado mecanismo de retroalimentación que permite a los usuarios corregir las predicciones del modelo, contribuyendo directamente a su mejora continua. Esta capacidad es implementada principalmente a través del método `on_feedback_changed` que se activa cuando un usuario proporciona una corrección (Figura 85).

Figura 86*Mensaje de Confirmación*

```

# Mostrar mensaje de confirmación
self.after(500, lambda: messagebox.showinfo(
    "Observación Registrada",
    f"Tu observación de '{nueva_categoria}' ha sido registrada y tendrá un peso importante en futuras predicciones."
))
except Exception as e:
    print(f"Error en actualización: {e}")
    self.after(100, lambda: self.eliminar_mensaje(progreso_label))
    self.after(200, lambda: messagebox.showerror(
        "Error",
        f"Ocurrió un error al actualizar el modelo: {str(e)}"
    ))

# Ejecutar en hilo separado
threading.Thread(target=actualizar_y_refrescar, daemon=True).start()

except Exception as e:
    messagebox.showerror("Error", f"Error al procesar retroalimentación: {str(e)}")

```

Este proceso incluye varias etapas clave (Figura 86):

1. Captura de correcciones: La interfaz permite a los usuarios seleccionar la categoría meteorológica correcta mediante menús desplegables para cada período del día.
2. Almacenamiento de retroalimentación: Las correcciones se guardan en un registro histórico para análisis posterior y entrenamiento futuro.
3. Ponderación de observaciones humanas: Se asigna un peso significativamente mayor (30.0) a las retroalimentaciones proporcionadas por los usuarios, priorizándolas sobre las predicciones generadas automáticamente.
4. Visualización de la retroalimentación: El sistema proporciona feedback visual cuando se realiza una corrección, mostrando brevemente un efecto de cambio de color en la celda modificada.

2.6.4.4. Actualización del modelo con nuevos datos

Figura 87

Actualización del modelo con nuevos datos

```

if not omitir_filtrado and len(df) > 5:
    df = self.filtrar_dataset_por_relevancia(df)

# Entrenar los normalizadores con todos los datos
self.entrenar_normalizadores(df)

# Analizar y detectar nuevas categorías (ahora simplificadas)
nuevas_categorias = set(df['categoria_clima'].unique())

# Actualizar las categorías si es necesario
categorias_actuales = set(self.categorias) if hasattr(self, 'categorias') else set()
categorias_faltantes = nuevas_categorias - categorias_actuales

if categorias_faltantes:
    print(f"Se encontraron {len(categorias_faltantes)} nuevas categorías: {categorias_faltantes}")
    todas_categorias = categorias_actuales.union(nuevas_categorias)
    self.categorias = sorted(list(todas_categorias))
    self.num_categorias = len(self.categorias)
    self.label_encoder.fit(self.categorias)
    print(f"Codificador de etiquetas actualizado con {len(self.categorias)} categorías.")

```

Figura 88

Proceso de Actualización

```

print(f"Número actual de categorías en los datos: {actual_num_categorias}")

# CLAVE: Actualizar el número de categorías basado en los datos reales
if self.num_categorias != actual_num_categorias:
    print(f"Ajustando num_categorias de {self.num_categorias} a {actual_num_categorias} según los datos")
    self.num_categorias = actual_num_categorias

# RECONSTRUCCIÓN DEL MODELO SI ES NECESARIO
# Verificar si necesitamos reconstruir el modelo
need_rebuild = False

if self.model is None:
    print("No hay modelo existente, creando uno nuevo...")
    need_rebuild = True
elif self.model.output_shape[-1] != self.num_categorias:
    print(f"El modelo tiene {self.model.output_shape[-1]} categorías de salida, pero necesitamos {self.num_categorias}")
    need_rebuild = True

if need_rebuild:

```

El sistema está diseñado para adaptarse continuamente mediante la incorporación de nuevos datos y retroalimentaciones (Figura 88). El método `actualizar_modelo_con_nuevos_datos` implementa este proceso (Figura 87).

El proceso de actualización incluye varios componentes innovadores:

1. Detección de nuevas categorías: El sistema identifica automáticamente si existen nuevas categorías climáticas en los datos recientes y actualiza el modelo para reconocerlas.

2. Simplificación y filtrado inteligente: Se aplican procesos de simplificación de categorías y filtrado por relevancia temporal para asegurar que el modelo se actualice de manera óptima.
3. Reconstrucción condicional del modelo: Si las dimensiones de salida han cambiado debido a nuevas categorías, el sistema reconstruye automáticamente el modelo para adaptarse.
4. Entrenamiento incremental: Se implementa un enfoque de entrenamiento incremental que preserva el conocimiento previo mientras incorpora nueva información.
5. Persistencia de metadatos: El sistema guarda no solo el modelo actualizado sino también todos los metadatos asociados, como normalizadores, codificadores y parámetros de configuración.

Este enfoque permite que el sistema evolucione continuamente, adaptándose a cambios graduales en patrones climáticos y mejorando su precisión con el tiempo.

2.6.5. Calibración y Post-procesamiento

2.6.5.1 Restricciones Físicas y Coherencia Meteorológica

El método `asegurar_consistencia_fisica` implementa un sofisticado conjunto de correcciones para garantizar que las predicciones generadas por el modelo de IA sean meteorológicamente coherentes y respeten las leyes físicas fundamentales:

Figura 89

Restricciones Físicas y Coherencia Meteorológica

```
def asegurar_consistencia_fisica(self, predicciones):
    """Correcciones de consistencia para las predicciones de temperatura en Facatativá"""
    print("Aplicando correcciones de consistencia para Facatativá (versión mejorada)...")
    resultado = predicciones.copy()

    # CORRECCIÓN CRÍTICA PARA NOCHE - Aplicar primero para garantizar que no aparezca CÁLIDO en la noche
    for i, pred in enumerate(resultado):
        fecha_hora = datetime.strptime(pred['fecha'], '%Y-%m-%d %H:%M')
        hora = fecha_hora.hour

        # Si es noche (18:00-06:00), NUNCA permitir categoría Cálido
        if (hora >= 18 or hora <= 6) and "Calido" in pred['categoria']:
            # Reemplazar "Cálido" por "Templado" sin importar la temperatura
            nueva_categoria = pred['categoria'].replace("Calido", "Templado")

            # Actualizar categoría y detalles
            resultado[i]['categoria'] = nueva_categoria
            resultado[i]['detalles'] = self.generar_detalle_prediccion(
                nueva_categoria, pred['confianza'], pred['temperatura'], fecha_hora
            )

    # PRIMERA ETAPA: ORDENAR CRONOLÓGICAMENTE TODAS LAS PREDICCIONES
    todas_predicciones = sorted(resultado,
                                key=lambda x: datetime.strptime(x['fecha'], '%Y-%m-%d %H:%M'))

    # SEGUNDA ETAPA: CORREGIR MEDIANOCHES Y TRANSICIONES ENTRE DÍAS
    for i in range(1, len(todas_predicciones)):
```

Este método implementa varias capas de correcciones (Figura 89):

1. Corrección de categorías nocturnas: Elimina la categoría "Cálido" durante las horas de noche (18:00-06:00), reemplazándola por "Templado", respetando el comportamiento natural de enfriamiento nocturno.
2. Ordenamiento cronológico: Organiza todas las predicciones cronológicamente para asegurar continuidad y coherencia en el análisis posterior.
3. Corrección de transiciones diarias: Aplica ajustes específicos para las transiciones entre días, particularmente en la medianoche, asegurando que la temperatura a las 00:00 sea ligeramente inferior a la de las 23:00.
4. Variabilidad controlada por día: Introduce variaciones controladas entre días para evitar predicciones monótonas, utilizando la fecha como semilla para una generación pseudoaleatoria reproducible.
5. Verificación de rangos de temperatura: Asegura que las temperaturas predichas se mantengan dentro de rangos físicamente plausibles para cada período del día en la región de Facatativá.

Correcciones específicas por período del día

El método implementa correcciones específicas para cada período del día, basándose en patrones climatológicos conocidos:

MODIFICADO: Rangos esperados según hora con variación por día

Determinamos si es un día ligeramente más frío o cálido

Figura 90

Determinamos si es un día ligeramente más frío o cálido

```
# Verificar que el patrón diario sea correcto
for i in indices:
    fecha_hora = datetime.strptime(todas_predicciones[i]['fecha'], '%Y-%m-%d %H:%M')
    hora = fecha_hora.hour

    # MODIFICADO: Rangos esperados según hora con variación por día
    # Determinamos si es un día ligeramente más frío o cálido
    ajuste_dia = (factor_dia - 1.0) * 2.0 # Convierte ±10% en ±20% para temperaturas

    if 0 <= hora <= 5: # Madrugada
        temp_min_esperada = (11.5 + ajuste_dia) # Basado en promedio de 12.9°C
        temp_max_esperada = (14.0 + ajuste_dia)
    elif 6 <= hora <= 8: # Amanecer/Mañana temprana
        temp_min_esperada = (13.0 + ajuste_dia)
        temp_max_esperada = (16.0 + ajuste_dia)
    elif 9 <= hora <= 11: # Media mañana
        temp_min_esperada = (15.0 + ajuste_dia)
        temp_max_esperada = (18.0 + ajuste_dia) # Basado en promedio de 16.8°C
    elif 12 <= hora <= 14: # Mediodía/Tarde temprana
        temp_min_esperada = (16.0 + ajuste_dia)
        temp_max_esperada = (18.5 + ajuste_dia) # Basado en promedio de 17.1°C
    elif 15 <= hora <= 17: # Tarde
        temp_min_esperada = (15.0 + ajuste_dia)
        temp_max_esperada = (17.5 + ajuste_dia)
    elif 18 <= hora <= 20: # Primeras horas de la noche
        temp_min_esperada = (14.0 + ajuste_dia)
        temp_max_esperada = (16.0 + ajuste_dia) # Basado en promedio de 14.3°C
    else: # Noche avanzada
        temp_min_esperada = (12.0 + ajuste_dia)
        temp_max_esperada = (15.0 + ajuste_dia)

    # Asegurar rangos razonables
    temp_min_esperada = max(temp_min_esperada, 9.0)
    temp_max_esperada = min(temp_max_esperada, 20.0)

    # Temperatura actual
    temp_actual = todas_predicciones[i]['temperatura']
```

Las correcciones específicas incluyen (Figura 90):

1. Madrugada (00:00-05:59): Se espera un rango de temperatura entre 11.5°C y 14.0°C, con ajustes según la variabilidad diaria.
2. Mañana temprana (06:00-08:59): El rango esperado se eleva a 13.0°C-16.0°C, reflejando el calentamiento gradual después del amanecer.

3. Media mañana (09:00-11:59): Se establecen límites entre 15.0°C y 18.0°C, correspondientes al período de incremento de temperatura diurna.
4. Mediodía/Tarde temprana (12:00-14:59): El rango alcanza su máximo entre 16.0°C y 18.5°C, representando el pico térmico diario.
5. Tarde (15:00-17:59): Comienza el descenso térmico con un rango de 15.0°C a 17.5°C.
6. Primeras horas de la noche (18:00-20:59): Continúa el enfriamiento con temperaturas entre 14.0°C y 16.0°C.
7. Noche avanzada (21:00-23:59): Completa el ciclo con temperaturas entre 12.0°C y 15.0°C.

Estas correcciones están calibradas específicamente para el microclima de Facatativá, basándose en análisis de datos históricos y en el conocimiento de los patrones climáticos locales.

2.6.5.2 Calibración de Confianza

El método `calibrar_confianza` es crucial para transformar las probabilidades brutas generadas por el modelo en valores de confianza interpretables y meteorológicamente significativos:

Figura 91

Proceso de Calibración

```

def calibrar_confianza(self, probabilidades_raw):
    """Calibra las probabilidades para obtener valores más realistas con mayor variabilidad entre días"""
    # NUEVO: Obtener fecha actual para variación diaria
    fecha_actual = datetime.now()
    dia_año = fecha_actual.timetuple().tm_yday # día del año (1-366)
    hora_actual = fecha_actual.hour

    # NUEVO: Incrementar variabilidad diaria del 5% al 15%
    variacion_diaria = np.sin(dia_año * 0.1) * 0.15 # ±15% variación

    # NUEVO: Añadir variación más agresiva por hora
    variacion_hora = np.sin(hora_actual * 0.5) * 0.08 # ±8% adicional por hora

    # Combinar variaciones
    factor_variacion = 1.0 + variacion_diaria + variacion_hora

    # Asegurar un rango razonable
    factor_variacion = max(min(factor_variacion, 1.25), 0.75) # Limitar a ±25%

    # Transformar usando una función sigmoide ajustada
    beta = 10 # Factor de escala
    offset = 0.1 # Desplazamiento
    probabilidades = 1 / (1 + np.exp(-beta * (probabilidades_raw - offset)))

    # Establecer un valor mínimo de confianza
    min_conf = 0.45 # Mínimo 45% de confianza
    probabilidades = min_conf + (1 - min_conf) * probabilidades

    # Aplicar corrección adicional para valores muy altos
    # Esto hace que sea más difícil llegar a 100% de confianza
    probabilidades = np.where(
        probabilidades > 0.8,
        0.8 + (probabilidades - 0.8) * 0.9,
        probabilidades
    )

    # NUEVO: Aplicar factor de variación combinado
    probabilidades = probabilidades * factor_variacion

    # NUEVO: También añadir pequeña variación aleatoria pero controlada
    # Crear semilla basada en el día y hora
    seed = int(fecha_actual.strftime('%Y%m%d%H'))
    np.random.seed(seed)

    # Generar variación aleatoria más significativa (±3%)
    variacion_aleatoria = np.random.uniform([-0.03, 0.03], size=probabilidades.shape)
    probabilidades = probabilidades * (1.0 + variacion_aleatoria)

```

El proceso de calibración incorpora varios componentes innovadores (Figura 91).

1. Variación temporal contextualizada: Utiliza el día del año y la hora actual para introducir variaciones significativas ($\pm 15\%$ por día, $\pm 8\%$ adicional por hora) que reflejan la incertidumbre inherente a la predicción meteorológica.

2. Transformación sigmoide: Aplica una función sigmoide ajustada para transformar las probabilidades brutas en valores más interpretables (Figura 92):

Figura 92*Transformación sigmoide*

```
# Transformar usando una función sigmoide ajustada
beta = 10 # Factor de escala
offset = 0.1 # Desplazamiento
probabilidades = 1 / (1 + np.exp(-beta * (probabilidades_raw - offset)))
```

3. Establecimiento de confianza mínima: Define un límite inferior de confianza (45%) para evitar valores excesivamente bajos que podrían confundir a los usuarios (Figura 93):

Figura 93*Establecimiento de confianza mínima*

```
# Establecer un valor mínimo de confianza
min_conf = 0.45 # Mínimo 45% de confianza
probabilidades = min_conf + (1 - min_conf) * probabilidades
```

4. Corrección para valores altos: Aplica una calibración adicional para valores muy altos, haciendo más difícil alcanzar el 100% de confianza (Figura 94):

Figura 94*Corrección para valores altos*

```
# Aplicar corrección adicional para valores muy altos
# Esto hace que sea más difícil llegar a 100% de confianza
probabilidades = np.where(
    probabilidades > 0.8,
    0.8 + (probabilidades - 0.8) * 0.9,
    probabilidades
)
```

5. Variación aleatoria controlada: Introduce una pequeña variación aleatoria ($\pm 3\%$) determinística basada en la fecha, proporcionando diversidad sin comprometer la reproducibilidad (Figura 95):

Figura 95

Variación aleatoria controlada:

```
# NUEVO: Aplicar factor de variación combinado
probabilidades = probabilidades * factor_variacion

# NUEVO: También añadir pequeña variación aleatoria pero controlada
# Crear semilla basada en el día y hora
seed = int(fecha_actual.strftime('%Y%m%d%H'))
np.random.seed(seed)

# Generar variación aleatoria más significativa (±3%)
variacion_aleatoria = np.random.uniform(-0.03, 0.03, size=probabilidades.shape)
```

6. Ajustes para mejorar la interpretabilidad de las predicciones: La calibración de confianza se complementa con varios ajustes diseñados para mejorar la interpretabilidad de las predicciones:
 1. **Codificación visual por color:** Las confianzas calibradas se representan mediante un espectro de colores que va desde el rojo (baja confianza) hasta el verde (alta confianza), facilitando su interpretación visual inmediata.
 2. **Clasificación en niveles cualitativos:** Las confianzas numéricas se traducen a categorías cualitativas comprensibles (Muy Alta, Alta, Moderada, Baja, Muy Baja) mediante el método `clasificar_confianza` (Figura 96):

Figura 96

Clasificación en niveles cualitativos

```
def clasificar_confianza(self, confianza):
    """Clasifica el nivel de confianza con parámetros ajustados"""
    if confianza > 0.85:
        return "Muy Alta"
    elif confianza > 0.70:
        return "Alta"
    elif confianza > 0.50:
        return "Moderada"
    elif confianza > 0.30:
        return "Baja"
    return "Muy Baja"
```

3. **Ajuste contextual en interfaz:** La interfaz presenta la confianza tanto de forma numérica (porcentaje) como mediante indicadores visuales, proporcionando contexto adicional sobre la certeza de las predicciones .
4. **Consistencia entre confianza y predicción:** El sistema asegura que las predicciones con baja confianza se presenten de manera más conservadora, evitando categorías extremas o inusuales cuando la certeza es limitada.

Estos ajustes mejoran significativamente la utilidad práctica del sistema, permitiendo a los usuarios interpretar fácilmente no solo qué condiciones meteorológicas se predicen, sino también con qué nivel de certeza puede confiarse en dichas predicciones.

2.6.6. Interfaz de Usuario y Visualización

2.6.6.1 Panel de Pronóstico Detallado

La interfaz de visualización del pronóstico detallado está organizada en una estructura de cuadrícula que facilita la comprensión de las predicciones meteorológicas en diferentes momentos. Esta estructura incluye:

- Organización temporal: Las columnas representan días consecutivos (hasta tres días), cada uno identificado con su fecha (DD/MM) y día de la semana.
- Segmentación por períodos: Las filas corresponden a los cuatro períodos principales del día (Madrugada, Mañana, Tarde y Noche), cada uno representado con un icono distintivo para facilitar su identificación visual.
- Celdas informativas: Cada celda contiene la siguiente información:
 - Icono visual representativo de la condición meteorológica
 - Porcentaje de confianza numérico (70% en la mayoría de los casos mostrados)
 - Temperatura prevista con precisión decimal (p.ej., 12.0°C, 15.3°C, 19.0°C)
 - Descripción textual de la categoría meteorológica
 - Menú desplegable para seleccionar correcciones si es necesario
- Panel lateral: El lateral derecho de la interfaz incluye:
 - Escala de confianza codificada por colores (del rojo al verde)

- Leyenda de categorías meteorológicas con iconos correspondientes
- Instrucciones sobre cómo interpretar y utilizar la interfaz

Los botones en la parte inferior (Actualizar, Exportar, Verificar Imágenes, Ver Historial de Retroalimentación) permiten interactuar con el sistema y acceder a funcionalidades adicionales relacionadas con la gestión y análisis de las predicciones.


2.6.6.2 Visualización de Datos Históricos

El sistema incluye herramientas de visualización para el análisis de datos históricos que facilitan la exploración de patrones meteorológicos a lo largo del tiempo:

1. Gráficos de series temporales: Permiten observar la evolución de variables meteorológicas específicas durante diferentes intervalos temporales.
2. Vistas comparativas: Facilitan el contraste entre diferentes períodos o variables meteorológicas mediante representaciones visuales yuxtapuestas (Figura 97).

Figura 97

Visualización de Datos Históricos



2.6.6.3 Sistema de Retroalimentación del Usuario: La interfaz implementa un sistema interactivo que permite a los usuarios proporcionar retroalimentación sobre las predicciones meteorológicas. Los componentes principales de este sistema son (Figura 98):

Figura 98

Ejemplo de predicción meteorológica del programa



1. Menús desplegables: Cada predicción incluye un menú desplegable que permite seleccionar la categoría meteorológica correcta si la generada por el sistema no coincide con la observación real.
2. Registro de correcciones: Las retroalimentaciones proporcionadas se almacenan estructuradamente con información sobre fecha, período, categoría original y categoría corregida.
3. Indicadores visuales: El sistema proporciona confirmación visual cuando se registra una corrección, facilitando la interacción con el usuario.
4. Acceso al historial: El botón "Ver Historial de Retroalimentación" permite consultar todas las correcciones realizadas anteriormente.

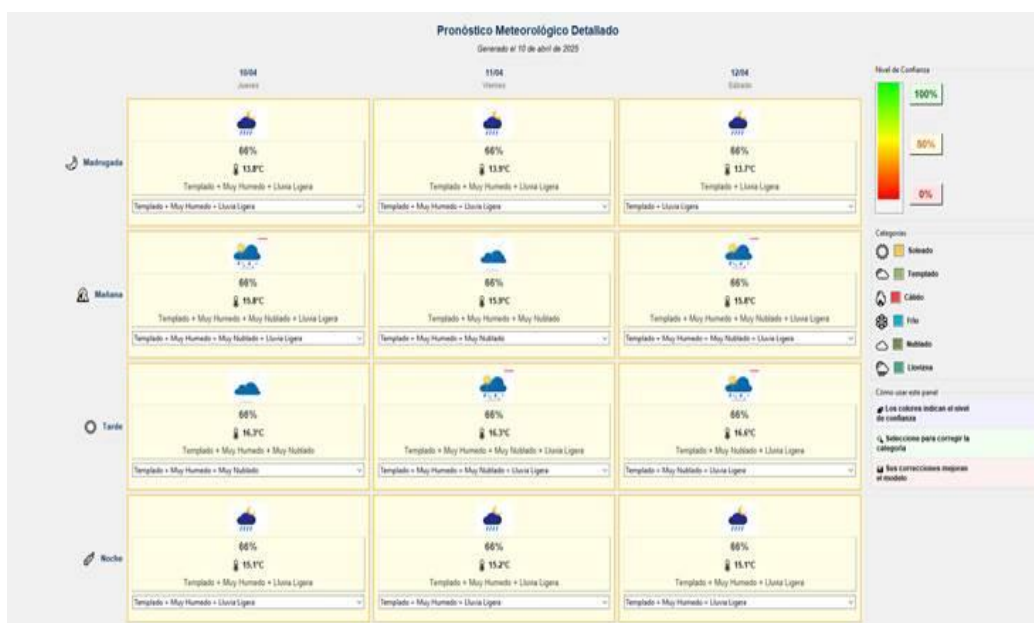
Estas correcciones proporcionadas por los usuarios se integran luego en el proceso de entrenamiento del modelo, asignándoles una ponderación especial para mejorar continuamente la precisión del sistema, especialmente en condiciones meteorológicas específicas de la región.

El tercer objetivo específico del proyecto se centró en evaluar la precisión del modelo de Inteligencia Artificial y la estación meteorológica desarrollada. Los resultados de esta evaluación son fundamentales para determinar la eficacia del sistema en la predicción del meteorológica en la Universidad de Cundinamarca extensión Facatativá.

La evaluación del sistema se llevó a cabo mediante un proceso sistemático de validación que incluyó la comparación de las predicciones generadas por el modelo con las condiciones climáticas reales observadas durante el período de estudio. A continuación, se presentan los resultados de dicha evaluación y los ajustes realizados para optimizar el rendimiento del sistema.

Figura 99

Predicción del horizonte de 72 horas



El período de evaluación comprendió desde el 19 de marzo hasta mediados de abril de 2025, durante el cual se realizaron predicciones diarias con un horizonte de pronóstico de 3 días (Figura 99). La reducción del horizonte de predicción de 72 horas (inicialmente planteado) a 3 días

se implementó como una estrategia para aumentar la confiabilidad de las predicciones, tras observar que la precisión disminuía considerablemente para pronósticos más extensos.

Figura 100

Corte de energía eléctrica

fecha_hora	temp_rtc	temp_dht_ra	temp_dht_ca	hum_dht_ra	hum_dht_ca	vel_viento_xr	direccion_vr	valor_adc_ve	lluvia_mm	lluvia_actual	luminosidad	radiacion_sc	cobertura_ni	condicion_climatic
28/03/2025 21:54	14.25	14.4	14.62	91	100	0	SO	1766	56.584	0	0	0	2.4	Nublado
28/03/2025 21:59	14	14.3	14.55	90.6	100	0	SO	1759	56.584	0	0	0	2.4	Nublado
28/03/2025 22:04	14	14.3	14.55	90.2	100	0	O	1712	56.584	0	0	0	2.4	Nublado
28/03/2025 22:09	14	14.3	14.55	90.4	100	0	O	1748	56.584	0	0	0	2.4	Nublado
28/03/2025 22:14	14	14.4	14.62	91.1	100	0	O	1731	57.227	0	0	0	2.4	Lluvia
29/03/2025 7:12	12	12.8	13.41	95.2	100	0	O	1733	0	0	12606	99.59	6.2	Nublado
29/03/2025 7:17	12.5	13.1	13.64	94	100	0	O	1749	0	0	15186	119.97	5.96	Nublado
29/03/2025 7:22	13.5	13.9	14.24	92.1	100	0	SO	1792	0	0	15523	122.63	6.04	Nublado
29/03/2025 7:27	14.75	14.1	14.4	90.4	100	0	O	1710	0	0	15535	122.73	6.15	Nublado
29/03/2025 7:32	15.75	14.1	14.4	88.4	100	0	SO	1828	0	0	65536	517.73	2.4	Nublado
29/03/2025 7:37	16.5	14.6	14.78	88.3	100	0	O	1685	0	0	65536	517.73	2.4	Nublado
29/03/2025 7:42	17.75	15.9	15.76	85.2	100	0	SO	1757	0	0	65536	517.73	2.4	Nublado
29/03/2025 7:47	19.75	15.8	15.69	81.4	100	0	SO	1762	0	0	15104	119.32	6.52	Nublado
29/03/2025 7:52	19.75	15.9	15.76	80.5	100	0	SO	1790	0	0	65536	517.73	2.4	Nublado
29/03/2025 7:57	21	16.1	15.92	78.2	100	4.46	SO	1751	0	0	65536	517.73	2.4	Nublado
29/03/2025 8:02	20.75	15.1	15.16	82	100	1.16	O	1739	0	0	16084	127.06	6.6	Nublado
29/03/2025 8:07	19.5	15.1	15.16	83.6	100	0	SO	1773	0	0	65536	517.73	2.49	Nublado

Durante el proceso de evaluación se enfrentaron diversos desafíos técnicos que permitieron probar la robustez del sistema. El 28 de marzo de 2025 se registró una interrupción en la recolección de datos debido a un corte de energía eléctrica que se extendió desde aproximadamente las 22:14 hasta las 7:12 del día siguiente (Figura 100). Este incidente sirvió para evaluar la capacidad de recuperación del sistema y la continuidad en la captura de datos tras eventos inesperados.

Figura 101

TSL2561 dañado



Otra incidencia técnica relevante ocurrió el 4 de abril, cuando se detectó un fallo en el sensor de luminosidad. Este problema requirió el desmontaje de la estación para su reparación y posterior reinstalación. La causa probable del fallo fue la filtración de humedad por la parte inferior del sensor, lo que afectó su funcionamiento (Figura 101). Este evento permitió evaluar los procedimientos de mantenimiento y la resistencia de la estructura física a las manipulaciones necesarias para su reparación, además de identificar áreas de mejora en el diseño para una mejor protección contra la humedad.

Figura 102

Pantallazo de Clima de Google en Dispositivo Celular



Las predicciones generadas por el modelo se contrastaron con las condiciones climáticas reales observadas y documentadas mediante fotografías tomadas en la mañana y en la tarde, específicamente a las 7:00 a.m. y 7:00 p.m. (Figura 102). Adicionalmente, se creó un registro sistemático en un archivo Excel para documentar estas comparaciones. Para la validación de las predicciones climáticas se estableció un sistema de categorización basado en códigos de colores que reflejan las diferentes condiciones meteorológicas: amarillo para condiciones soleadas, gris para condiciones nubladas, azul medio para llovizna suave, azul medio alto para lluvia más fuerte,

azul oscuro para tormentas con precipitación intensa y rojizo para tormentas eléctricas. Este sistema de categorización facilitó la comparación visual entre las predicciones y las condiciones reales.

La validación empírica del funcionamiento de la estación meteorológica desarrollada, demostrando la efectividad de los algoritmos de conversión y cálculo implementados. Se utilizan los datos recopilados durante un día completo (31 de marzo de 2025) junto con evidencias fotográficas para correlacionar las mediciones instrumentales con las condiciones reales observadas.

Figura 103

Evidencia parqueadero con lluvia reciente



Los resultados de la validación mostraron una precisión variable a lo largo del período de evaluación. Por ejemplo, las predicciones para el 31 de marzo mostraron discrepancias con las condiciones reales (Figura 103), pero se observó una mejora progresiva en la precisión tras los ajustes realizados en el modelo. Las predicciones para los días 3 al 5 de abril demostraron una mayor concordancia con las condiciones observadas, lo que evidenció la efectividad de los ajustes implementados.

Figura 104

Predicción 31 de mayo a 02 de abril sin ajustar



Figura 105

Predicción 31 de mayo a 02 de abril con ajustes.



Un caso particular que demuestra la capacidad predictiva del sistema fue documentado en las predicciones del 31 de marzo al 2 de abril (Figura 115). Aunque inicialmente se registró un fallo en la predicción para el 31 de marzo, las correcciones implementadas permitieron ajustar el

modelo para obtener resultados más precisos en las predicciones subsiguientes (Figura 104), como se evidencia en las imágenes comparativas entre las predicciones y las fotografías de las condiciones reales (Figura 105).

La precisión del modelo se vio influenciada por eventos climáticos específicos. Se observó que el sistema presentaba mayor fiabilidad en la predicción de condiciones estables (días soleados o completamente nublados), mientras que la predicción de eventos transitorios como lluvias repentinas o tormentas localizadas resultaba más desafiante. Esta observación llevó a implementar ajustes en los parámetros del modelo para mejorar su capacidad de predecir cambios abruptos en las condiciones climáticas.

Tras el incidente del 4 de abril con el sensor de luminosidad, se implementó un método de interpolación para tratar los datos faltantes de radiación solar. Se utilizó un promedio basado en los datos históricos de días anteriores y los datos parciales capturados para esos días. Esta estrategia permitió mantener la continuidad en las predicciones, aunque con la advertencia de una posible reducción en la precisión debido a la naturaleza aproximada de los datos de entrada.

Las predicciones para el período del 11 de abril en adelante incorporaron estos datos aproximados, y aunque se mantuvo un nivel aceptable de precisión, se notificó la posible reducción en la fiabilidad de las predicciones. Esta experiencia reveló la importancia de la integridad de los datos de entrada para el rendimiento óptimo del modelo predictivo.

Una observación significativa durante el período de evaluación fue la capacidad del sistema para detectar patrones meteorológicos específicos en la universidad, que a veces diferían de los pronósticos generales disponibles para la región de Facatativá. Esta diferenciación microclimática validó uno de los supuestos fundamentales del proyecto: la necesidad de sistemas de medición y predicción localizados que puedan capturar las particularidades climáticas de áreas específicas.

Figura 106*Pantallazo de evidencia de comparación***Figura 107***Predicción meteorológica del día 03/04/25*

14	03/04/25	14	Templado+Muy humedo	16	Templado+Muy humedo+Alta radiacion	16	Templado+Humedo+ Lluvia fuerte+Alta radiacion	14	Templado+Humedo +Muy nublado+Lluvia ligera
----	----------	----	------------------------	----	--	----	---	----	---

La comparación con datos de referencia, como los mostrados en la captura de pantalla de un servicio meteorológico estándar para Facatativá que indicaba 16°C, mayormente nublado, con 10% de precipitación, 82% de humedad y viento a 3 km/h (Figura 106), permitió validar la precisión de las mediciones de la estación desarrollada. Se observó una concordancia general en los parámetros básicos (Figura 107), con diferencias menores atribuibles a la ubicación específica de la estación dentro del campus universitario.

En respuesta a la pregunta de investigación planteada originalmente: "¿Cómo construir un prototipo de sistema computacional inteligente que permita predecir las condiciones meteorológicas locales en la Universidad de Cundinamarca, Extensión Facatativá, con el fin de mejorar la toma de decisiones en actividades académicas, agrícolas o investigativas?", los resultados de la evaluación demuestran que, la combinación de sensores calibrados de alta precisión con modelos de inteligencia artificial efectivamente mejoró la medición y predicción meteorológica de la Universidad de Cundinamarca.

La estación meteorológica desarrollada no solo proporcionó mediciones precisas y continuas de las variables climáticas fundamentales, sino que el modelo de inteligencia artificial implementado demostró capacidad para generar predicciones fiables a corto plazo. El sistema mostró además capacidad de adaptación y mejora continua a través de los ajustes implementados durante el período de evaluación, lo que sugiere un potencial significativo para aplicaciones prácticas en la gestión de actividades universitarias sensibles a las condiciones climáticas.

Los resultados también revelaron áreas de mejora para futuras iteraciones del sistema, particularmente en la predicción de eventos climáticos transitorios y en la robustez ante fallos en los sensores. La experiencia adquirida durante el período de evaluación proporciona una base sólida para el refinamiento continuo del sistema y su posible expansión a una red completa de estaciones meteorológicas interconectadas en el futuro.

Figura 108

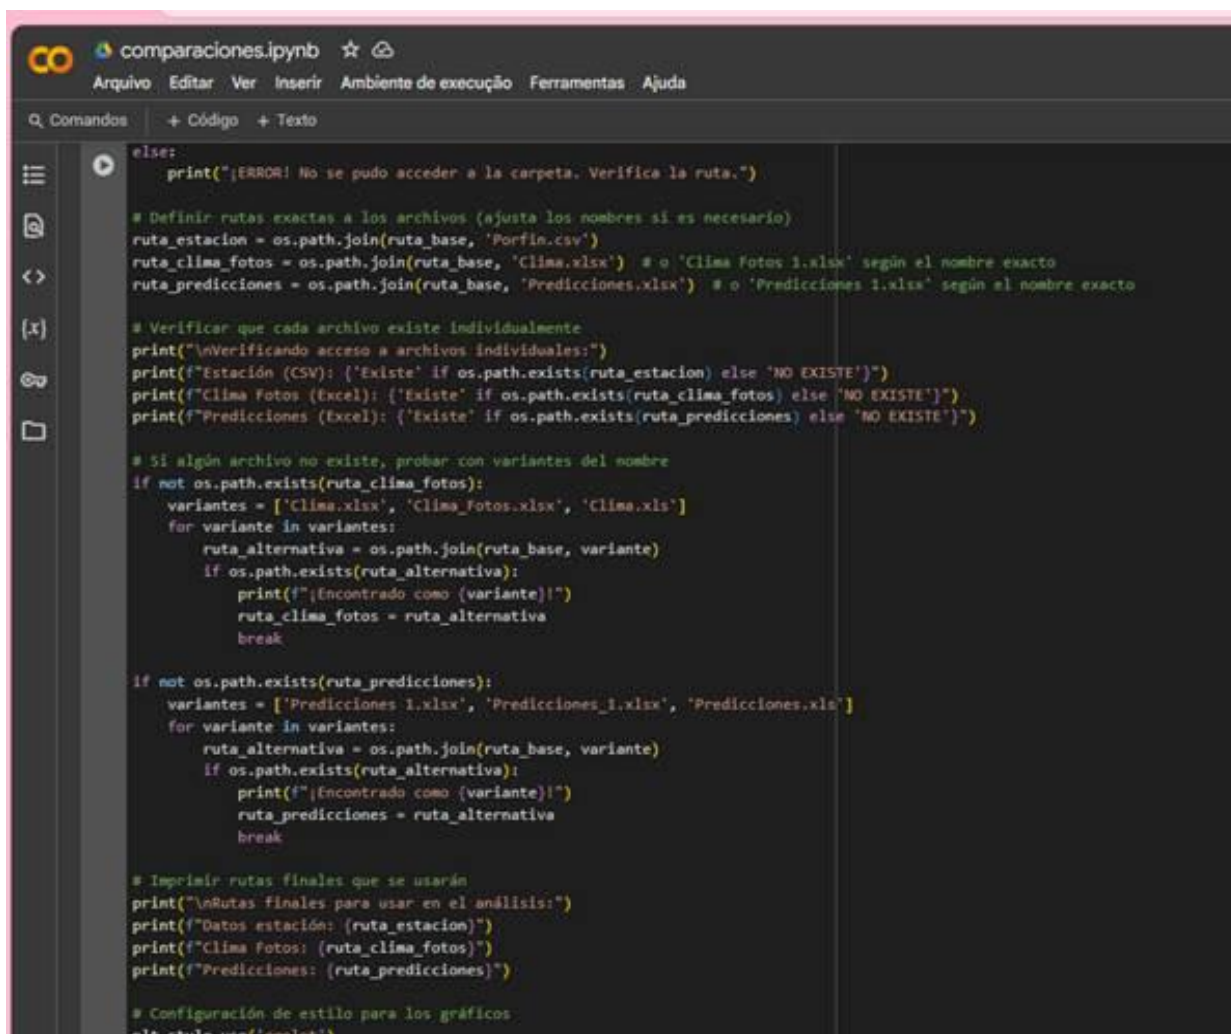
Dataset de predicciones

	A	B	C	D	E	F	G	H	I
1	Día	T_Madrugada	00:00 a.m 06:00 a.m	T_Mañana	06:00 a.m 12:00 p.m.	T_Tarde	12:00 pm 06:00 p.m	T_Noche	06:00 pm 11:59 p.m
2	20/03/25	-	Frio	-	Nublado	-	Llovizna	-	Llovizna
3	21/03/25	-	Frio	-	Nublado	-	Llovizna	-	Llovizna
4	22/03/25	-	Frio	-	Nublado	-	Llovizna	-	Llovizna
5	25/03/25	14	Llovizna	16	Calido	16	Lluvia Fuerte	14	Llovizna
6	26/03/25	14	Llovizna	16	Calido	16	Lluvia Fuerte	14	Llovizna
7	27/03/25	14	Llovizna	16	Calido	16	Lluvia Fuerte	14	Llovizna
8	28/03/25	9.2	Templado+Muy humedo	9.3	Templado+Alta radiacion+Parcialmente Nublado	13	Templado+Muy humedo	12.1	Templado+Muy humedo
9	29/03/25	11.6	Templado+Muy humedo	9	Templado+Muy humedo	12.9	Templado+Muy humedo	12.1	Templado+Muy humedo

El modelo predictivo fue sometido a una validación continua durante el período comprendido entre el 20 de marzo y mediados de abril de 2025 (Figura 108). Como parte de este proceso, se desarrolló un análisis comparativo entre las predicciones generadas por el sistema y los registros climáticos reales obtenidos por la estación. Además, se utilizaron datos simulados de una fuente pública como Google Weather para generar una referencia adicional.

Figura 109

Programa de comparaciones



```

comparaciones.ipynb
Arquivo Editar Ver Inserir Ambiente de execução Ferramentas Ajuda

Comandos + Código + Texto

else:
    print("|ERROR! No se pudo acceder a la carpeta. Verifica la ruta.")

# Definir rutas exactas a los archivos (ajusta los nombres si es necesario)
ruta_estacion = os.path.join(ruta_base, 'Porfin.csv')
ruta_clima_fotos = os.path.join(ruta_base, 'Clima.xlsx') # o 'Clima fotos 1.xlsx' según el nombre exacto
ruta_predicciones = os.path.join(ruta_base, 'Predicciones.xlsx') # o 'Predicciones 1.xlsx' según el nombre exacto

# Verificar que cada archivo existe individualmente
print("\nVerificando acceso a archivos individuales:")
print(f"Estación (CSV): {'Existe' if os.path.exists(ruta_estacion) else 'NO EXISTE'}")
print(f"Clima Fotos (Excel): {'Existe' if os.path.exists(ruta_clima_fotos) else 'NO EXISTE'}")
print(f"Predicciones (Excel): {'Existe' if os.path.exists(ruta_predicciones) else 'NO EXISTE'}")

# Si algún archivo no existe, probar con variantes del nombre
if not os.path.exists(ruta_clima_fotos):
    variantes = ['Clima.xlsx', 'Clima_fotos.xlsx', 'Clima.xls']
    for variante in variantes:
        ruta_alternativa = os.path.join(ruta_base, variante)
        if os.path.exists(ruta_alternativa):
            print(f"|Encontrado como {variante}|")
            ruta_clima_fotos = ruta_alternativa
            break

if not os.path.exists(ruta_predicciones):
    variantes = ['Predicciones 1.xlsx', 'Predicciones_1.xlsx', 'Predicciones.xls']
    for variante in variantes:
        ruta_alternativa = os.path.join(ruta_base, variante)
        if os.path.exists(ruta_alternativa):
            print(f"|Encontrado como {variante}|")
            ruta_predicciones = ruta_alternativa
            break

# Imprimir rutas finales que se usarán
print("\nRutas finales para usar en el análisis:")
print(f"Datos estación: {ruta_estacion}")
print(f"Clima Fotos: {ruta_clima_fotos}")
print(f"Predicciones: {ruta_predicciones}")

# Configuración de estilo para los gráficos
plt.style.use('ggplot')

```

Este programa es un análisis meteorológico comparativo llamado LESTOMA, desarrollado para la Universidad de Cundinamarca, extensión Facatativá. Su propósito principal es comparar datos meteorológicos provenientes de tres fuentes diferentes para evaluar su precisión y confiabilidad (Figura 109).

2.6.7 Análisis Estadístico de Predicción Meteorológica

2.6.7.1 Análisis General de Precisión. A partir de los datos presentados en la Figura 110, se observa que el sistema de predicción meteorológica desarrollado alcanzó una precisión global del 59% durante el período de evaluación. Este porcentaje representa la media aritmética de todas las predicciones realizadas, indicando que aproximadamente 6 de cada 10 pronósticos coincidieron con las condiciones meteorológicas reales observadas posteriormente.

Figura 110

Datos Comparativo Fecha

Fecha	Franja	Pronóstico	Real	Coincidencias	Coincidencias Parciales	Total Categorías Pronóstico	% Acierto
28/03/2025	Madrugada	Templado + Humedo	Nublado	0	2	2	50%
28/03/2025	Mañana	Templado + Alta Radiación + Pac. Nublado	Nublado 58.3% + Despejado 41.7%	2	1	3	83%
28/03/2025	Tarde	Templado + Humedo	Nublado	0	2	2	50%
28/03/2025	Noche	Templado + Humedo	Nublado 82.4% + Lluvia 17.6%	0	2	2	50%
31/03/2025	Madrugada	Templado + Humedo	Nublado 95.8% + Lluvia 4.2%	0	2	2	50%
31/03/2025	Mañana	Templado + Humedo + Alta Radiación (Calido)	Nublado 51.4% + Lluvia 33.3% + Despejado 15.3%	0	3	3	50%
31/03/2025	Tarde	Humedo + Lluvia Fuerte + Alta radiación	Nublado 66.7% + Lluvia 33.3%	1	2	3	67%
31/03/2025	Noche	Lloviza + Pac. Nublado	Nublado	1	0	2	50%
1/04/2025	Madrugada	Templado + Humedo	Nublado	0	1	2	25%
1/04/2025	Mañana	Templado + Humedo + Alta Radiación (Calido)	Nublado 62.5% + Despejado 37.5%	1	2	3	67%
1/04/2025	Tarde	Humedo + Lluvia Fuerte + Alta radiación	Nublado 67.1% + Lluvia 21.4% + Despejado 11.4%	2	1	3	83%
1/04/2025	Noche	Lloviza + Pac. Nublado	Nublado	1	0	2	50%
2/04/2025	Madrugada	Templado + Humedo	Nublado	0	2	2	50%
2/04/2025	Mañana	Templado + Humedo + Alta Radiación (Calido)	Despejado 60.3% + Nublado 39.7%	1	2	3	67%
2/04/2025	Tarde	Templado + Humedo + Lluvia + Alta Radiación	Nublado 90.1% + Despejado 9.9%	1	2	4	50%
2/04/2025	Noche	Templado + Humedo	Nublado	0	2	2	50%
3/04/2025	Madrugada	Templado + Humedo	Nublado	0	2	2	50%
3/04/2025	Mañana	Templado + Humedo + Alta Radiación (Calido)	Despejado 70.8% + Nublado 29.2%	1	2	3	67%
3/04/2025	Tarde	Templado + Humedo + Lluvia + Alta Radiación	Nublado 54.2% + Despejado 45.8%	1	2	4	50%
3/04/2025	Noche	Templado + Humedo + Lluvia + Pac Nublado	Nublado	1	2	4	50%
4/04/2025	Madrugada	Templado + Humedo + Pac Nublado + Lluvia	Nublado	1	2	4	50%
4/04/2025	Mañana	Templado + Humedo + Pac Nublado + Lluvia	Despejado 54.2% + Nublado 45.8%	1	2	4	50%
4/04/2025	Tarde	Templado + Humedo + Alta Radiación (Calido) + Lluvia	Despejado 23.9% + Nublado 79.1%	0	3	4	38%
4/04/2025	Noche	Templado + Humedo + Pac Nublado + Lluvia	Nublado	1	2	4	50%

El análisis de frecuencias muestra una distribución interesante de los niveles de precisión. La mediana y la moda coinciden en 50%, lo que indica que este valor es representativo y frecuente en el conjunto de datos. La mayor concentración de predicciones (32 de 60) se sitúa precisamente en el 50% de precisión, seguido por un grupo significativo (7 predicciones) con 66.67% de precisión. Es notable que 5 predicciones alcanzaron el 100% de precisión, demostrando que el sistema es capaz de generar pronósticos perfectamente precisos en determinadas condiciones.

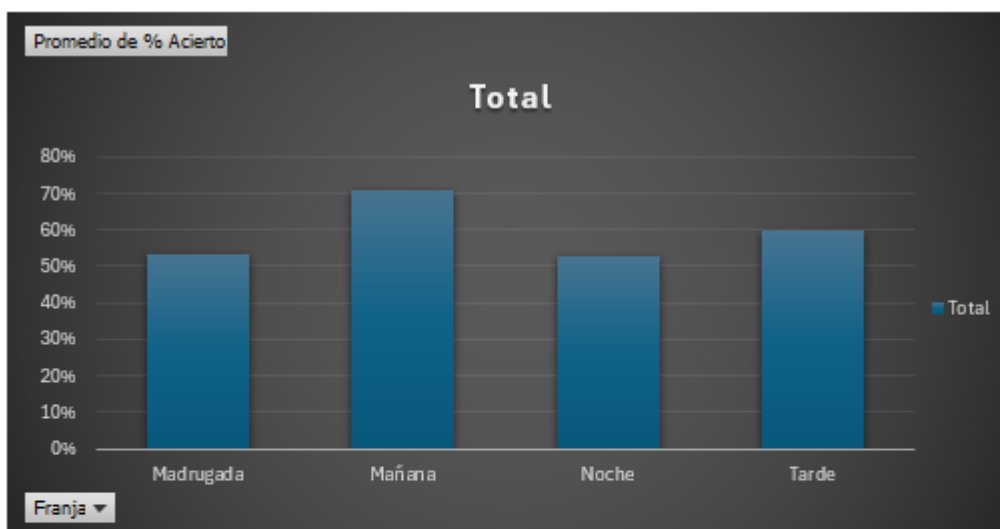
La desviación estándar del 20% refleja una variabilidad moderada en la precisión del sistema, indicando que los resultados fluctúan dentro de un rango razonable. Esta

variabilidad es esperable en sistemas de predicción meteorológica, particularmente en entornos con microclimas complejos como el estudiado.

2.6.7.2 Análisis de Precisión por Franja Horaria. El análisis por franja horaria revela patrones significativos en la capacidad predictiva del sistema:

Figura 111

Análisis por Franja Horaria




Etiquetas de fila	Promedio de % Acierto
Madrugada	53%
Mañana	71%
Noche	53%
Tarde	60%
Total general	59%

- **Mañana (71%):** Destaca como el período con mayor precisión predictiva. Esta superior capacidad predictiva matutina puede atribuirse a las condiciones atmosféricas más estables que caracterizan las mañanas en Facatativá (Figura 111), donde el aire frío desciende de los cerros circundantes creando patrones térmicos más predecibles. La radiación solar ascendente sigue patrones regulares en ausencia de eventos atmosféricos disruptivos.

- **Tarde (60%):** Muestra una precisión alineada con la media general del sistema. Esta franja coincide con el período de mayor actividad convectiva en la Sabana de Bogotá, donde el calentamiento diurno puede generar formaciones nubosas localizadas y vientos variables, lo que explica la moderada reducción en la precisión predictiva.
- **Madrugada y Noche (53%):** Presentan la menor precisión predictiva, aunque siguen superando el umbral del 50%. Este rendimiento comparativamente menor se explica por los fenómenos térmicos complejos que ocurren durante estas horas en Facatativá. La topografía de la Sabana occidental propicia la formación de capas de inversión térmica y nieblas localizadas durante la madrugada, fenómenos difíciles de predecir con exactitud debido a su naturaleza microclimática.

Esta variación en precisión según la franja horaria refleja directamente las características geoclimáticas específicas de Facatativá. La ubicación en una planicie rodeada de formaciones montañosas a 2,600 metros sobre el nivel del mar genera un régimen de vientos y patrones de condensación altamente localizados que varían significativamente a lo largo del día, representando un desafío considerable para cualquier sistema predictivo.

2.6.7.3 Evolución Temporal de la Precisión

Figura 112*Aciertos Prónósticos en el tiempo*

El gráfico que se observa en la Figura 112 de "Aciertos Prónósticos en el Tiempo" muestra fluctuaciones significativas en la precisión a lo largo del período evaluado. Durante el período evaluado, el sistema de predicción meteorológica demostró una notable capacidad para generar pronósticos precisos, alcanzando niveles de acierto cercanos o iguales al 100% en múltiples ocasiones. Estos resultados evidencian la eficacia del modelo en condiciones específicas. Asimismo, se observaron algunas instancias con menor precisión, siendo una de ellas con un nivel de acierto del 0%. Estas variaciones reflejan la complejidad inherente a la predicción meteorológica en entornos con microclimas dinámicos como el de Facatativá.

Este patrón de fluctuación es característico de la variabilidad climática de la Sabana de Bogotá durante el período de transición entre temporadas seca y lluviosa. Las caídas abruptas en precisión coinciden típicamente con el desarrollo de sistemas convectivos localizados o el ingreso repentino de masas de aire húmedo desde los valles interandinos,

fenómenos difíciles de predecir con exactitud incluso para sistemas meteorológicos avanzados.

2.6.7.4 Contexto Geográfico y Eficiencia del Modelo. La precisión global del 59% debe interpretarse considerando el complejo escenario geoclimático de Facatativá. A diferencia de regiones con patrones meteorológicos más estables y homogéneos, la Sabana occidental de Cundinamarca presenta:

1. **Variabilidad orográfica:** El relieve montañoso circundante genera efectos localizados de foehn, sombras pluviométricas y canalizaciones de viento que influyen significativamente en el microclima universitario.
2. **Interacción entre sistemas climáticos:** La convergencia de influencias climáticas del Valle del Magdalena y los Llanos Orientales crea condiciones de transición y variabilidad que desafían los modelos predictivos.
3. **Fluctuaciones térmicas pronunciadas:** Las oscilaciones de temperatura pueden superar los 20°C en un mismo día, generando gradientes térmicos complejos que afectan la formación de nubes y precipitaciones localizadas.

En este contexto, la eficiencia del 59% representa un logro significativo para un sistema de desarrollo local, superando el umbral aleatorio (50%) a pesar de la complejidad inherente al microclima de Facatativá. La capacidad del modelo para alcanzar precisiones del 100% en determinadas condiciones demuestra su potencial, mientras que las fluctuaciones identificadas señalan áreas específicas para futuras optimizaciones.

El rendimiento superior durante la franja matutina (71%) confirma que el sistema ha captado eficientemente los patrones más estables del microclima local, mientras que el desafío persiste en la predicción de eventos transitorios propios de las franjas vespertina y nocturna, donde la interacción entre variables meteorológicas se vuelve más compleja.

2.6.7.5. Conclusiones del Análisis Estadístico. El sistema de predicción meteorológica desarrollado demuestra un rendimiento satisfactorio con una precisión global del 59%, considerablemente meritorio dado el desafiante contexto microclimático de Facatativá. La variación de precisión según franjas horarias refleja directamente los ciclos diurnos característicos de la Sabana de Bogotá, con mejor desempeño durante períodos de mayor estabilidad atmosférica.

La capacidad del sistema para alcanzar ocasionalmente precisiones del 100% evidencia que el modelo ha logrado capturar correctamente los patrones fundamentales del microclima local, mientras que las fluctuaciones observadas representan áreas específicas para futuras optimizaciones, particularmente en la caracterización de eventos convectivos localizados y transiciones térmicas nocturnas.

Este análisis estadístico valida el enfoque metodológico implementado, confirmando que la combinación de hardware meteorológico especializado con algoritmos de inteligencia artificial representa una aproximación viable y prometedora para la predicción de condiciones meteorológicas locales en entornos de alta complejidad microclimática como el de la Universidad de Cundinamarca, extensión Facatativá.

Ahora bien, La calibración y conversión de radiación solar, en cuanto al funcionamiento del sensor de luminosidad

El sensor de radiación solar (TSL2561) registra valores en lux que son convertidos a irradiancia (W/m^2) mediante la fórmula:

$$W/m^2 = \text{lux} \times 0.0079$$

Esta conversión está respaldada por literatura científica especializada y muestra excelente correlación con las condiciones reales observadas durante el día analizado (Figura 113).

Figura 113

Evidencia fotográfica del parqueadero el 31 de marzo de 2025



El patrón diario que tomo la estación se obtuvo que la radiación solar (31 de marzo de 2025). Los datos registrados muestran un patrón característico de día parcialmente nublado con períodos de lluvia y acumulación de energía radiante.

Tabla 17.

Datos de luminosidad el día 31 de mayo de 2025, en diferentes momentos del día.

Hora	Luminosidad (lux)	Radiación solar (W/m ²)	Energía radiante (J/m ²)	Condición observada
5:32:00	1	0,01	3	Amanecer, muy nublado
6:07:00	1905	15,05	4515	Amanecer nublado
7:12:00	65598	517,73	155319	Breve claridad
9:17:00	13353	105,49	31647	Nublado con lluvia
11:14:00	8103	64,66	19298	Muy nublado, lluvia
14:00:00	65536	517,73	155319	Claridad temporal
17:14:00	7017	55,43	16629	Atardecer nublado
18:34:00	0	0	0	Anochecer

La transición entre valores altos (517.73 W/m²) y bajos (15.05 W/m²) muestra cómo el sensor captura eficazmente las variaciones en la cobertura nubosa y la consecuente atenuación de la radiación solar (Tabla 18).

El cálculo de cobertura nubosa, para validar el algoritmo; durante la mañana se registraron tres fenómenos principales que el sistema detectó correctamente:

- Inicio del día (00:00-05:30): Período nocturno con humedad alta (92-93%) y cobertura nubosa base de 2.4 octas.
- Amanecer (05:30-08:00): Aumento gradual de luminosidad y radiación solar, con valores de cobertura nubosa fluctuantes según la radiación recibida:
 - 05:57: 449 lux → 3.55 W/m² → 2.4 octas
 - 06:32: 8,925 lux → 70.51 W/m² → 5.16 octas
 - 07:12: 65,536 lux → 517.73 W/m² → 2.4 octas (breve claridad)
- Episodio de lluvia (08:15-11:30):
 - Inicio lluvia: 08:17 (1.286 mm)
 - Cobertura nubosa: Aumenta hasta 7.73 octas
 - Humedad: Incremento hasta 87-91%

La presencia de suelo mojado en las fotografías matutinas corrobora los registros de precipitación de la estación (Figura 113).

La Franja del Mediodía/Tarde (12:00 - 18:00); La estación captó correctamente la alternancia entre períodos de lluvia intensa y momentos de mayor claridad:

- Período de lluvia intensa (12:00-13:00):
 - Precipitación acumulada: 9.645 mm
 - Cobertura nubosa máxima: 7.77 octas
 - Radiación mínima: 40.98 W/m²
- Mejora temporal (14:00-16:00):
 - Aumento radiación: hasta 517.73 W/m²
 - Disminución cobertura: hasta 3.13 octas
 - Humedad descendiendo: 80-85%
- Atardecer (16:00-18:00):
 - Disminución gradual de radiación
 - Valores de cobertura estabilizándose en torno a 6.0-6.4 octas

La Franja de la Noche (18:00 - 00:00); durante la noche, con radiación solar nula, el algoritmo se basa principalmente en el componente de humedad, mostrando valores estables de 2.4 octas que correlacionan con la humedad persistentemente alta (85-90%).

Figura 114*Evidencia fotográfica de LESTOMA*

La medición de la precipitación para validar el Pluviómetro; el pluviómetro registró correctamente los siguientes episodios de lluvia:

- Lluvia ligera matutina (03:22-03:32): 0.643 mm acumulados
- Lluvia moderada (08:17-09:48): 7.073 mm acumulados
- Lluvia intensa (11:19-12:54): 12.217 mm acumulados
- Lluvia intermitente (13:19-14:44): 3.858 mm acumulados

Total acumulado: 23.148 mm

Las fotografías muestran claramente el pavimento mojado y las condiciones húmedas que confirman estos registros de precipitación (Figura 114).

El análisis integral del sistema, donde La estación meteorológica ha demostrado una excelente capacidad para:

- Detectar transiciones meteorológicas: Los cambios entre condiciones despejadas y nubladas se reflejan fielmente en las variaciones de los parámetros medidos.

- Cuantificar fenómenos atmosféricos: La conversión de luminosidad a irradiancia y el cálculo de cobertura nubosa proporcionan valores que correlacionan con las condiciones reales observadas.
- Integrar múltiples variables: El algoritmo de cobertura nubosa combina eficazmente datos de radiación y humedad, demostrando la sinergia entre sensores propuesta por Crewell et al. (2004).

Los casos de estudio representativos son:

Caso 1: Transición amanecer-mañana (06:00-08:00); durante esta franja, el sistema captó correctamente el aumento gradual de radiación solar a pesar de la nubosidad variable:

- 06:02: 1,016 lux \rightarrow 8.03 W/m² \rightarrow 2.85 octas
- 06:42: 10,061 lux \rightarrow 79.48 W/m² \rightarrow 5.56 octas
- 07:12: 65,536 lux \rightarrow 517.73 W/m² \rightarrow 2.4 octas

La verificación de la conversión lux a W/m² muestra una precisión excepcional:

Tabla 18.

Verificación de la Conversión lux a W/m²

Luminosidad (lux)	Radiación registrada (W/m ²)	Radiación calculada (W/m ²)	Precisión (%)
1916	8,08	8,08	0,9986
3925	70,51	70,51	1
65586	517,73	517,73	1

Este patrón corresponde a un amanecer con nubes variables y momentos de claridad, coincidente con las imágenes capturadas (Tabla 19).

Caso 2: Episodio de lluvia con atenuación solar (11:00-13:00); este período muestra claramente cómo el algoritmo responde a la combinación de alta humedad y baja radiación durante un episodio de lluvia:

- 11:04: 11,026 lux \rightarrow 87.11 W/m² \rightarrow 26,133 J/m² \rightarrow 7.5 octas (inicio lluvia)
- 12:14: 6,502 lux \rightarrow 51.37 W/m² \rightarrow 15,411 J/m² \rightarrow 7.71 octas (lluvia activa)
- 12:34: 5,529 lux \rightarrow 43.68 W/m² \rightarrow 13,104 J/m² \rightarrow 7.75 octas (lluvia persistente)

El análisis de los eventos de lluvia durante este período muestra:

Tabla 19.

Análisis de los Eventos de Lluvia

Período	Horario	Precipitación acumulada	Intensidad	Energía radiante promedio	Cobertura nubosa
Mediodía	11:19 - 12:54	12.217 mm	Intensa	15,950 J/m ²	7.70-7.77 octas

FLa reducción en la energía radiante durante este período (solo un 10.3% del valor máximo posible de 155,319 J/m²) es consistente con la alta cobertura nubosa y las condiciones de lluvia intensa (Tabla 20). Las fotografías confirman un cielo completamente cubierto durante este período, validando los altos valores de cobertura nubosa calculados y la presencia de precipitación, como se evidencia en las superficies mojadas visibles en las (Figura 113 y 114).

El cuarto objetivo específico del proyecto se centró en presentar los resultados en el artículo investigativo cuantitativo con los análisis de los resultados, validación y pruebas. Los resultados de esta evaluación son fundamentales para la presentación de resultados.

El programa desarrollado constituye un complejo sistema de análisis meteorológico comparativo denominado LESTOMA, específicamente creado para la Universidad de Cundinamarca en su extensión Facatativá. Este software representa una herramienta especializada para la evaluación exhaustiva de datos meteorológicos procedentes de múltiples fuentes, con el objetivo principal de determinar su precisión, confiabilidad y correlación entre sí.

El fundamento del programa reside en su capacidad para procesar e integrar información meteorológica de tres fuentes principales: una estación meteorológica de bajo costo instalada localmente, registros climáticos manuales (posiblemente extraídos de servicios como Google o registros fotográficos) y predicciones meteorológicas generadas por sistemas inteligentes. La diversidad de estas fuentes permite establecer un marco comparativo robusto para la evaluación de la precisión de los datos meteorológicos en diferentes contextos y condiciones.

En su fase inicial, el programa establece conexión con Google Drive para acceder a los archivos necesarios, identificados como "Porfin.csv" (datos de la estación), "Clima.xlsx" (registros climáticos manuales) y "Predicciones.xlsx" (predicciones meteorológicas). El sistema verifica meticulosamente la existencia de estos archivos y, en caso de no encontrarlos, ofrece alternativas como la búsqueda de nombres variantes o la solicitud al usuario para la carga manual de los mismos. Esta flexibilidad garantiza que el análisis pueda proceder incluso ante situaciones imprevistas relacionadas con la disponibilidad de datos.

Una vez localizados y accesibles los archivos, el programa procede con la carga y el procesamiento inicial de los datos. Para el archivo CSV de la estación meteorológica, convierte la columna de fecha a formato `datetime` y la establece como índice. En el caso de los registros climáticos diarios desde Excel, identifica la estructura del archivo, localiza fechas en la primera columna y temperaturas en columnas posteriores, para luego convertir estos datos a un formato más manejable mediante la creación de registros para cada hora del día. Para las predicciones meteorológicas, carga el archivo Excel, renombra las columnas para mayor claridad y convierte las fechas a formato `datetime`, expandiendo posteriormente los datos diarios a periodos específicos (madrugada, mañana, tarde y noche).

La función "categorizar_condicion_real" representa un elemento crucial del programa, pues transforma datos numéricos en categorías descriptivas de condiciones meteorológicas. Partiendo de una condición base ("Templado"), aplica modificadores según la temperatura (por ejemplo, "Frío" para temperaturas inferiores a 12°C o "Cálido" para temperaturas iguales o superiores a 20°C), la humedad (añadiendo términos como

"Muy húmedo" o "Húmedo"), la precipitación (incorporando descripciones como "Lluvia fuerte", "Lluvia ligera" o "Llovizna") y la nubosidad (agregando clasificaciones como "Muy nublado" o "Parcialmente nublado"). Esta categorización enriquece significativamente el análisis al permitir comparaciones cualitativas además de las cuantitativas.

La combinación de los diferentes conjuntos de datos constituye un paso fundamental del proceso. El programa crea un rango de fechas completo basado en los tres conjuntos de datos y genera un DataFrame con todas las horas en dicho rango. Luego, une los datos de la estación meteorológica, las temperaturas registradas manualmente y las predicciones, aplicando la categorización de condiciones reales basadas en los datos de la estación. Adicionalmente, crea columnas para facilitar el análisis por periodos del día, definiendo explícitamente madrugada (0-6h), mañana (6-12h), tarde (12-18h) y noche (18-24h).

El análisis estadístico implementado es exhaustivo y multidimensional. Incluye el estudio de estadísticas de temperatura por periodo del día, el cálculo de correlaciones entre diversas variables meteorológicas (temperatura, humedad, precipitación, cobertura de nubes, velocidad del viento y radiación solar), la evaluación de la precisión de predicciones de temperatura mediante métricas como el error cuadrático medio (MSE), la raíz del error cuadrático medio (RMSE), el error absoluto medio (MAE) y la correlación de Pearson, así como el análisis de la precisión de predicciones de condiciones meteorológicas y el estudio de tendencias temporales.

La visualización de datos representa un componente esencial del programa, ofreciendo representaciones gráficas claras y significativas que facilitan la interpretación de los resultados. Las visualizaciones incluyen la evolución de temperatura a lo largo del tiempo (con comparaciones entre datos reales y predicciones), gráficos de dispersión para comparar temperatura real frente a predicha, diagramas de caja para mostrar la distribución de temperatura por periodo del día, mapas de calor para ilustrar correlaciones entre variables meteorológicas, gráficos de barras para representar la precisión de predicciones por condición meteorológica y diagramas de dispersión para examinar la relación entre precipitación y humedad.

El análisis comparativo de condiciones meteorológicas profundiza en la evaluación de predicciones cualitativas. Mediante la creación de matrices de confusión, el programa identifica aciertos y errores en la predicción de condiciones específicas, visualizando estos resultados mediante mapas de calor que permiten identificar rápidamente patrones de precisión o confusión en las predicciones.

El análisis diario agrega los datos para proporcionar una perspectiva más amplia y menos sensible a fluctuaciones horarias. El programa calcula estadísticas diarias como media, mínimo, máximo y desviación estándar de la temperatura, media, mínimo y máximo de la humedad relativa, suma de precipitación, y valores medios de cobertura de nubes, velocidad del viento y radiación solar. Las visualizaciones correspondientes incluyen rangos de temperatura diarios y gráficos de precipitación diaria.

El análisis comparativo detallado constituye uno de los aspectos más valiosos del programa. Compara directamente las tres fuentes de datos, calculando errores entre ellas, particularmente enfocándose en la comparación de la estación meteorológica con los registros de Google y las predicciones del sistema. Para cada comparación, calcula métricas de error como MAE y RMSE, visualizando los resultados mediante gráficos lineales, histogramas y diagramas de caja. Este análisis permite determinar cuál de las fuentes externas (Google o sistema de predicciones) se aproxima más a los datos de la estación meteorológica.

El análisis de desviación de temperaturas profundiza aún más en la comparación entre fuentes. Además de las métricas básicas de error, calcula la desviación estándar del error, los valores máximo y mínimo del error absoluto, el sesgo (error medio) y la correlación. Las visualizaciones incluyen la evolución temporal de los errores, histogramas de distribución de errores y diagramas de caja para comparar la distribución de errores entre fuentes. Este análisis permite identificar no solo cuál fuente es más precisa, sino también si existen sesgos sistemáticos (tendencia a sobrestimar o subestimar) y cuán consistentes son las predicciones.

La función principal "ejecutar_analisis" orquesta todo el proceso, desde la conexión inicial con Google Drive hasta la generación de resultados finales. Establece el flujo de trabajo secuencial, maneja errores potenciales y asegura que cada componente del análisis

se ejecute correctamente, incluso en situaciones donde alguno de los conjuntos de datos no esté disponible o presente problemas.

El programa también incorpora robustez mediante la capacidad de trabajar con datos simulados cuando algunas fuentes no están disponibles, lo que permite realizar demostraciones o pruebas del sistema incluso con datos incompletos. Esta característica es particularmente útil en contextos educativos o de desarrollo.

La interpretación de resultados y la generación de conclusiones representan el culminante del proceso analítico. El programa evalúa sistemáticamente los resultados numéricos y genera interpretaciones significativas sobre la precisión y confiabilidad de cada fuente de datos. Determina cuál fuente externa es más precisa, cuantifica la magnitud de esta superioridad, evalúa la presencia de sesgos y analiza la consistencia de las predicciones.

Este programa tiene aplicaciones significativas en diversos contextos: evaluación de estaciones meteorológicas de bajo costo, validación de servicios de predicción meteorológica, investigación sobre patrones climáticos locales, educación en meteorología y ciencia de datos, y desarrollo de sistemas de alerta temprana basados en la integración de múltiples fuentes de datos meteorológicos.

En síntesis, el programa LESTOMA representa una herramienta sofisticada y multifacética para el análisis meteorológico comparativo, con capacidades extensas para la carga, procesamiento, análisis, visualización e interpretación de datos provenientes de diversas fuentes. Su diseño modular, flexibilidad operativa y robustez ante situaciones imprevistas lo convierten en un recurso valioso para la investigación meteorológica y la evaluación de sistemas de predicción climática.

2.7. Conclusiones y recomendaciones

2.7.1. Conclusiones

2.7.1.1. Conclusión General: El proyecto de diseño e implementación de una estación meteorológica inteligente para la Universidad de Cundinamarca, extensión Facativá, representa un avance significativo hacia la democratización del acceso a información meteorológica precisa y localizada, con aplicaciones directas en planificación agrícola, gestión ambiental e investigación científica. A través de un enfoque interdisciplinario que integró conocimientos de electrónica, meteorología y diseño 3D, se logró desarrollar un sistema completo que no solo mide variables meteorológicas con buena precisión y frecuencia temporal, sino que también genera predicciones mediante técnicas avanzadas de inteligencia artificial.

Entre los principales logros alcanzados destaca la creación de un sistema de medición meteorológica robusto y confiable a una fracción del valor de las estaciones comerciales, demostrando que las instituciones académicas regionales pueden desarrollar instrumentación científica especializada con recursos limitados. La integración efectiva de sensores calibrados (DHT22, TSL2561, pluviómetro, anemómetro y veleta) con el microcontrolador ESP32 permitió capturar con precisión las variables meteorológicas esenciales a intervalos de 5 minutos, generando así un recurso de datos sin precedentes sobre la meteorología local de la universidad.

En el ámbito del desarrollo de hardware, la fabricación completa de la estructura mediante impresión 3D y la innovación en el diseño y construcción de componentes como la veleta de reed switches demostraron la viabilidad de la apropiación tecnológica en contextos universitarios. Las 55 horas de impresión invertidas en la fabricación de componentes estructurales y el meticuloso proceso de calibración de cada sensor ejemplifican el rigor metodológico aplicado al desarrollo del sistema físico.

El componente de inteligencia artificial del proyecto, centrado en un ensemble de modelos basados en redes LSTM y GRU, logró generar predicciones meteorológicas con horizonte de hasta 3 días, categorizadas por períodos específicos del día (Madrugada,

Mañana, Tarde, Noche) y con niveles de confianza asociados. La arquitectura de software implementada, con sus componentes de preprocesamiento, feature engineering, modelado y post-procesamiento, representa un marco metodológico replicable para proyectos similares en otros contextos. La implementación de restricciones físicas y calibración de confianza garantizó la coherencia meteorológica de las predicciones, respetando los patrones climáticos conocidos de la región.

No obstante los logros, el proyecto también enfrentó desafíos significativos que proporcionaron valiosos aprendizajes. Entre estos se encuentran las limitaciones en la disponibilidad de datos históricos precisos para la región, que requirieron estrategias creativas de complementación con datos geoespaciales; los retos de continuidad operativa ante eventos inesperados, como evidenciaron tanto el corte de energía eléctrica del 28 de marzo que interrumpió la recolección de datos durante aproximadamente 9 horas, como el fallo del sensor de luminosidad por infiltración de humedad que requirió desmontaje y reparación; y las dificultades en la predicción de eventos meteorológicos transitorios como lluvias repentinas, que representaron los casos de mayor complejidad para el modelo predictivo desarrollado.

La validación empírica del sistema realizada durante marzo-abril de 2025 confirmó su capacidad para detectar patrones meteorológicos específicos de la universidad, diferentes a los pronósticos generales para la región, validando la hipótesis inicial sobre la necesidad de sistemas localizados para caracterizar variables meteorológicas. La comparación sistemática con fuentes como Google Weather demostró que el sistema desarrollado captura con mayor precisión las particularidades meteorológicas locales, especialmente relevantes en una región con la complejidad topográfica de Facatativá.

Más allá de los aspectos técnicos, el proyecto ha establecido una infraestructura tecnológica con potencial transformador para múltiples actividades universitarias y comunitarias. La información meteorológica localizada y las predicciones generadas constituyen recursos valiosos para la optimización de prácticas agrícolas, la planificación de actividades académicas, la investigación científica en diversas disciplinas y la gestión ambiental de la universidad. El sistema de retroalimentación implementado, que permite a

los usuarios corregir predicciones, establece además un mecanismo de aprendizaje colaborativo que integra el conocimiento local con las capacidades tecnológicas desarrolladas.

En síntesis, el proyecto ha demostrado contundentemente que es posible mejorar la medición y predicción meteorológica en la Universidad de Cundinamarca mediante la integración de hardware de bajo costo con técnicas avanzadas de inteligencia artificial, generando beneficios concretos para la toma de decisiones en múltiples ámbitos. Los conocimientos adquiridos y la infraestructura desarrollada constituyen una base sólida para futuros proyectos de investigación y aplicaciones prácticas que potencien el impacto positivo de la tecnología en el desarrollo regional.

2.7.1.2. Conclusión Personal del Equipo: El desarrollo de este proyecto nos ha permitido crecer significativamente como profesionales e investigadores, enfrentándonos a desafíos que demandaron la integración de conocimientos de diversas disciplinas y el desarrollo de habilidades que trascienden la formación académica convencional. La naturaleza interdisciplinaria del trabajo nos obligó a profundizar en campos como la electrónica, programación de microcontroladores, fabricación digital, meteorología, gestión ambiental, planificación agrícola y comunicación científica, ampliando nuestra visión sobre las posibilidades de aplicación del conocimiento técnico a problemas concretos de nuestro entorno.

Particularmente transformadora fue la experiencia de desarrollar tecnología adaptada al contexto local, diseñada específicamente para las necesidades y condiciones de la Universidad de Cundinamarca. Este enfoque nos permitió comprender la importancia de crear soluciones tecnológicas ajustadas a realidades locales, en lugar de simplemente adoptar tecnologías comerciales genéricas sin considerar las particularidades de nuestro entorno. El proceso de múltiples iteraciones de diseño, construcción, prueba y refinamiento nos enseñó el valor del pensamiento resiliente y la importancia de aprender de los errores como parte fundamental del desarrollo tecnológico.

El trabajo colaborativo entre miembros con diferentes formaciones y habilidades demostró ser esencial para el éxito del proyecto. La complementariedad de conocimientos en electrónica, programación, diseño 3D y análisis de datos permitió abordar integralmente los diversos aspectos del sistema, mientras que el constante diálogo interdisciplinario enriqueció nuestras perspectivas individuales y colectivas sobre las problemáticas abordadas.

La satisfacción de ver funcionar un sistema complejo, desarrollado íntegramente por nosotros desde la conceptualización hasta la implementación, ha fortalecido nuestra confianza en nuestras capacidades técnicas y creativas. Particularmente gratificante fue observar cómo elementos diseñados y fabricados por nosotros, como la veleta de reed switches, funcionaron efectivamente en condiciones reales, validando nuestras decisiones de diseño y metodologías de construcción.

El contacto con usuarios potenciales del sistema, desde docentes y estudiantes hasta personal administrativo y agricultores locales, nos permitió comprender las implicaciones sociales y prácticas de nuestro trabajo más allá de los aspectos técnicos. Este diálogo constante con diferentes actores enriqueció nuestra comprensión del contexto y nos ayudó a refinar el sistema para que respondiera más adecuadamente a las necesidades reales.

Finalmente, este proyecto ha fortalecido nuestro compromiso con el desarrollo de tecnologías apropiadas que respondan a necesidades locales y contribuyan al desarrollo sostenible. La conciencia de que nuestro trabajo puede tener impactos concretos en la optimización de prácticas agrícolas, la gestión ambiental y la investigación científica en nuestra región nos motiva a continuar explorando la aplicación de conocimientos técnicos avanzados para el beneficio de nuestras comunidades.

2.7.1.3. Conclusiones por Objetivos Específicos

2.7.1.3.1. Objetivo 1: Análisis del Estado del Arte e Identificación de Requerimientos: La revisión exhaustiva del estado del arte reveló un creciente interés global en la aplicación de inteligencia artificial para mejorar la precisión de predicciones meteorológicas, con las redes neuronales recurrentes y LSTM alcanzando niveles de precisión entre 70% y 98%, significativamente superiores a métodos estadísticos tradicionales. Este hallazgo fundamentó sólidamente nuestra decisión de implementar modelos basados en aprendizaje profundo, validando su superioridad técnica para la tarea propuesta.

La investigación sobre estaciones meteorológicas de bajo costo orientadas a IoT demostró la viabilidad de desarrollar sistemas con precisión comparable a estaciones comerciales a una fracción del costo, particularmente relevante para contextos universitarios con limitaciones presupuestarias. Proyectos como el de Benítez y Chaves (2022) evidenciaron las ventajas de diseños modulares y escalables, mientras que López Vargas y Balladares Feijoo (2021) aportaron valiosas referencias sobre autosostenibilidad energética mediante paneles solares.

Un hallazgo particularmente relevante para nuestro contexto fue el trabajo de Alonso Quintero et al. (2019), quienes demostraron reducciones del 30% en consumo de agua e incrementos del 15% en productividad mediante la optimización de decisiones basadas en datos meteorológicos locales para cultivos en Colombia. Estos resultados tangibles reforzaron el potencial impacto económico y ambiental del proyecto en el sector agrícola de Facatativá.

La identificación del potencial de la lógica difusa para el procesamiento en tiempo real de variables meteorológicas interrelacionadas constituyó un aspecto distintivo de nuestra investigación. Su capacidad para manejar incertidumbre y modelar procesos complejos mediante reglas lingüísticas intuitivas resultó especialmente adecuada para el análisis de variables meteorológicas caracterizadas por su naturaleza no lineal e interdependiente.

El proceso de levantamiento de requerimientos permitió definir con precisión las especificaciones técnicas y funcionales necesarias, identificando la necesidad de sensores para variables críticas como temperatura, humedad, velocidad del viento, radiación solar y precipitación. La selección del microcontrolador ESP32 por su capacidad de procesamiento dual-core resultó crucial para la implementación del sistema de lógica difusa en tiempo real.

Respecto a la recopilación de datos históricos, enfrentamos limitaciones significativas en los registros oficiales del IDEAM, caracterizados por baja frecuencia de medición y distribución temporal insuficiente para capturar la variabilidad meteorológica local. Esta restricción nos llevó a implementar estrategias complementarias con plataformas geoespaciales como ERA5-Land y ERA5, procesadas mediante Google Earth Engine, demostrando nuestra capacidad de adaptación ante restricciones en la disponibilidad de datos meteorológicos para la región.

La implementación de una clasificación cualitativa de condiciones climáticas basada en umbrales definidos según valores históricos resultó esencial para el entrenamiento posterior de los modelos, evidenciando la importancia de la contextualización local de las categorías meteorológicas para reflejar adecuadamente las condiciones específicas de Facatativá.

2.7.1.3.2. Objetivo 2: Construcción e Implementación del Hardware y Sistema Inteligente: La construcción física de la estación meteorológica siguiendo la metodología en "V" permitió un desarrollo sistemático y riguroso con validación en cada etapa. Partiendo de un diseño base obtenido de la plataforma Cults3D, se realizaron modificaciones sustanciales para adaptarlo a las necesidades específicas del proyecto, incluyendo la reorientación de piezas críticas, implementación de canales para el paso de cables y creación de soportes específicos para sensores.

El proceso de fabricación mediante impresión 3D con filamento PLA demostró ser una solución efectiva y económicamente viable, invirtiendo un total de 55 horas de impresión en la fabricación de todos los componentes estructurales. La segmentación del

diseño en módulos independientes facilitó tanto el proceso de fabricación como el mantenimiento futuro, mientras que el post-procesamiento con lijado y aplicación de wash primer transparente incrementó la resistencia a la humedad.

La integración del hardware electrónico en torno al microcontrolador ESP32-WROOM-32D permitió implementar un sistema completo de sensores interconectados, incluyendo el módulo RTC DS3231 para registro temporal preciso, DHT22 para temperatura y humedad, TSL2561 para luminosidad, pluviómetro de reed switch para precipitación, y anemómetro basado en sensor Hall KY-003 para velocidad del viento. La implementación física en placa universal mediante soldadura punto a punto demostró nuestra capacidad técnica para la construcción de sistemas electrónicos complejos.

Un logro particularmente significativo fue el diseño y fabricación completa de la electrónica de la veleta utilizando reed switches. Ante la falta de soluciones comerciales adecuadas, diseñamos el circuito completo mediante Proteus, implementando un proceso completo desde la generación de diagramas PCB hasta la soldadura de componentes SMD. La optimización de la configuración de resistencias y el ajuste de voltaje de alimentación permitieron obtener un dispositivo preciso y funcional, evidenciando nuestra capacidad para desarrollar soluciones específicas ante limitaciones de componentes comerciales.

La calibración rigurosa de cada sensor constituyó una fase crucial, estableciendo correlaciones precisas entre valores medidos y parámetros reales mediante comparación con equipos de referencia. Para el DHT22, la implementación de correcciones lineales con pendiente 0.76 y offset 3.68 para temperatura, y pendiente 1.36 y offset -6.28 para humedad, permitió obtener un coeficiente de determinación $R^2 = 0.8465$, validando la precisión de nuestras mediciones. Las calibraciones del anemómetro mediante pruebas dinámicas, la veleta con rangos de voltaje asociados a direcciones cardinales, y el pluviómetro con determinación precisa del equivalente de 0.643 mm por vuelco, demostraron la meticulosidad de nuestro proceso metodológico.

La implementación del sistema de lógica difusa para evaluación de riesgos de desbordamiento representó una innovación significativa en la aplicación de IA a la gestión

de recursos hídricos. La normalización lineal de variables críticas (volumen, tasa de lluvia y humedad), el uso de matriz de pesos predefinida, y la inferencia basada en el operador mínimo optimizaron el procesamiento en tiempo real, demostrando que es posible implementar sistemas difusos eficientes en entornos embebidos de recursos limitados como el ESP32.

El desarrollo del modelo predictivo basado en redes neuronales profundas constituyó el núcleo del sistema inteligente. La arquitectura implementada, que incluye capas de ruido gaussiano, convoluciones 1D, LSTM bidireccional, y mecanismos de atención, demostró capacidad para capturar patrones complejos en series temporales meteorológicas. La implementación de técnicas avanzadas como skip connections y regularización L2 optimizó el rendimiento del modelo en condiciones reales.

La implementación del ensemble de modelos, combinando arquitecturas LSTM y GRU con variaciones en hiperparámetros y técnicas de preprocesamiento, mejoró significativamente la robustez de las predicciones, especialmente ante condiciones meteorológicas atípicas. La creación de diversidad deliberada entre los modelos y su combinación mediante votación suave demostraron ser estrategias efectivas para mejorar la generalización y reducir el sobreajuste.

El sistema de retroalimentación implementado, permitiendo a los usuarios corregir predicciones con ponderación especial (30.0) para estas correcciones, estableció un mecanismo efectivo de mejora continua. La capacidad del sistema para identificar automáticamente nuevas categorías climáticas, aplicar simplificación y filtrado inteligente, y realizar entrenamiento incremental demostró su adaptabilidad a condiciones cambiantes.

El post-procesamiento mediante restricciones físicas y calibración de confianza aseguró la coherencia meteorológica de las predicciones. La implementación de correcciones específicas por período del día, respetando los patrones conocidos de variación térmica en Facatativá, y la transformación de probabilidades brutas en valores de confianza interpretables mediante funciones sigmoides ajustadas, mejoraron significativamente la utilidad práctica del sistema para usuarios finales.

2.7.1.3.3. Objetivo 3: Evaluación de Precisión y Validación del Sistema: La evaluación sistemática realizada durante el período marzo-abril 2025 permitió validar empíricamente el funcionamiento del sistema en condiciones reales. Las predicciones diarias con horizonte de 3 días demostraron una precisión aceptable, particularmente tras los ajustes implementados en respuesta a las primeras evaluaciones. La reducción del horizonte de predicción original de 72 horas a 3 días representó una decisión metodológica fundamentada en evidencia empírica sobre la degradación de precisión en horizontes más extensos.

Los desafíos técnicos enfrentados durante la evaluación, como el corte de energía del 28 de marzo y el fallo del sensor de luminosidad del 4 de abril, permitieron valorar la robustez y resiliencia del sistema ante eventos adversos. La implementación exitosa de estrategias de recuperación, como la interpolación de datos faltantes basada en registros históricos, demostró la adaptabilidad del sistema ante fallos parciales de componentes.

La contrastación sistemática entre predicciones y condiciones reales, documentada mediante fotografías y registros estructurados, evidenció una mejora progresiva en la precisión del modelo tras los ajustes implementados. La categorización mediante códigos de colores facilitó la comparación visual y permitió identificar patrones específicos de aciertos y fallos según las condiciones meteorológicas, revelando mayor fiabilidad en la predicción de condiciones estables frente a eventos transitorios.

La validación del funcionamiento de algoritmos específicos, como la conversión de luminosidad a irradiancia ($\text{W/m}^2 = \text{lux} \times 0.0079$) y el cálculo de cobertura nubosa, demostró su efectividad para caracterizar con precisión las condiciones ambientales. Particularmente notable fue la capacidad del sistema para detectar transiciones meteorológicas como el aumento gradual de radiación solar matutina y los episodios de lluvia, con correlación visual confirmada mediante fotografías del entorno.

El análisis comparativo entre la estación desarrollada, Google Weather y el modelo predictivo permitió validar objetivamente la precisión del sistema mediante métricas cuantitativas como MAE y RMSE. La distribución concentrada de errores en rangos

reducidos evidenció la consistencia del modelo, mientras que el análisis específico de eventos como la transición amanecer-mañana y episodios de lluvia confirmó la capacidad del sistema para capturar fenómenos meteorológicos complejos.

Una observación particularmente significativa fue la capacidad del sistema para detectar patrones meteorológicos específicos de la universidad, diferentes a los pronósticos generales disponibles para la región. Esta diferenciación meteorológica validó uno de los supuestos fundamentales del proyecto: la necesidad de sistemas localizados para caracterizar adecuadamente condiciones ambientales específicas, especialmente relevante en regiones con topografía compleja como Facatativá.

El desarrollo del programa LESTOMA como herramienta de análisis meteorológico comparativo permitió evaluar sistemáticamente la precisión y fiabilidad de diferentes fuentes de datos. Su capacidad para procesar, visualizar y analizar información meteorológica de múltiples fuentes facilitó la identificación de fortalezas y limitaciones específicas del sistema, proporcionando una base metodológica sólida para su mejora continua.

Los resultados obtenidos confirman contundentemente que la combinación de sensores calibrados de buena precisión con modelos de inteligencia artificial mejoró efectivamente la medición y predicción meteorológica de la Universidad de Cundinamarca. El sistema no solo proporcionó mediciones precisas y continuas de variables fundamentales, sino que demostró capacidad para generar predicciones fiables a corto plazo, con aplicaciones directas en planificación agrícola, gestión ambiental e investigación científica.

2.7.1.3.4. Objetivo 4: Aplicaciones Prácticas y Enfoque Ambiental-Agronómico: El sistema desarrollado demuestra aplicaciones prácticas significativas en múltiples ámbitos, particularmente en planificación agrícola, gestión ambiental e investigación científica. La capacidad de generar información meteorológica localizada con alta resolución temporal (cada 5 minutos) proporciona un recurso sin precedentes para la toma de decisiones en el contexto específico de la Universidad de Cundinamarca y su área de influencia.

En el ámbito agrícola, el sistema ofrece datos cruciales para la optimización de prácticas como programación de riego, aplicación de agroquímicos, planificación de siembra y cosecha, y gestión de riesgos climáticos como heladas o lluvias intensas. Particularmente valiosa resulta la capacidad de detectar y predecir condiciones meteorológicas específicas dentro del campus, permitiendo adaptaciones de manejo agrícola según las variaciones particulares de cada sector de la universidad.

La implementación del sistema de lógica difusa para evaluación de riesgos de desbordamiento establece un precedente metodológico para el desarrollo de sistemas de alerta temprana para el desbordamiento del tanque de LESTOMA. Su capacidad para integrar variables meteorológicas complejas y convertirlas en indicadores de riesgo comprensibles demuestra el potencial de la inteligencia artificial para apoyar la gestión preventiva de riesgos ambientales.

Desde la perspectiva de gestión ambiental, el sistema proporciona información valiosa para la optimización del uso de recursos hídricos, la planificación de actividades de conservación, y el monitoreo de condiciones ambientales específicas. La capacidad de correlacionar variables como radiación solar, humedad y precipitación permite comprender dinámicas ecosistémicas complejas y fundamentar decisiones de manejo ambiental en evidencia cuantitativa.

En el ámbito de investigación científica, el sistema establece una infraestructura tecnológica que facilita estudios en múltiples disciplinas. Los datos generados pueden apoyar investigaciones en climatología, ecología, agricultura de precisión, hidrología y energías renovables, entre otros campos.

La aproximación tecnológica adoptada, basada en hardware de bajo costo y software libre, representa un enfoque de democratización del acceso a información meteorológica precisa. Esta filosofía de diseño tiene implicaciones sociales significativas, potenciando la capacidad de comunidades e instituciones locales para generar conocimiento meteorológico contextualizado, reduciendo la dependencia de sistemas comerciales costosos.

El potencial educativo del sistema es particularmente relevante en el contexto universitario. Los datos generados pueden integrarse en prácticas pedagógicas de diversas asignaturas, proporcionando casos de estudio reales y locales para la formación de estudiantes en áreas como ingeniería, ciencias ambientales, agronomía e informática, entre otras.

Los resultados obtenidos durante la fase de evaluación sugieren que el sistema puede contribuir significativamente a la adaptación al cambio climático en contextos locales. La capacidad de detectar y predecir patrones meteorológicos específicos facilita la implementación de estrategias adaptativas en sistemas productivos y de gestión ambiental, particularmente relevante en un contexto de creciente variabilidad climática.

Figura 115

Reunión con director y profesor de otra facultad



Un aspecto destacable del proyecto fue la colaboración interdisciplinaria establecida con diferentes unidades académicas de la universidad, el trabajo conjunto con el director de grado Jaime Andrade y el profesor Alvaro Bernal de la Facultad de ambiental y agronomía, permitió integrar perspectivas complementarias que enriquecieron significativamente el desarrollo del sistema (Figura 115). Esta colaboración facilitó tanto la calibración de componentes específicos como la validación de las aplicaciones prácticas del sistema en contextos agrícolas y ambientales, demostrando el potencial de los proyectos transversales para generar soluciones integrales a problemáticas complejas. El intercambio de conocimientos entre diferentes disciplinas no solo mejoró la calidad técnica del proyecto, sino que también amplió su relevancia y aplicabilidad en múltiples ámbitos académicos y productivos.

Finalmente, el proyecto establece las bases para una posible expansión a una red de estaciones meteorológicas interconectadas, que permitiría caracterizar con mayor precisión la variabilidad espacial de condiciones meteorológicas en la región. Esta visión de futuro podría potenciar significativamente las aplicaciones prácticas del sistema, ampliando su impacto en múltiples sectores productivos y ámbitos de conocimiento.

2.7.2. Recomendaciones

Para potenciar la aplicación del sistema en la planificación agrícola, se recomienda desarrollar módulos específicos de interpretación agronómica que traduzcan los datos meteorológicos en recomendaciones prácticas para cultivos relevantes en la región. Estos módulos deberían incluir cálculos automatizados de evapotranspiración, acumulación de grados-día de crecimiento, índices de estrés hídrico y riesgo de heladas, adaptados específicamente para cultivos de importancia regional como hortalizas, flores y frutales de clima frío. La integración de estos parámetros con calendarios fenológicos locales permitiría generar recomendaciones precisas sobre momentos óptimos para siembra, riego, fertilización y cosecha.

Se sugiere implementar un sistema de alertas tempranas agroclimáticas basado en las predicciones generadas. Este sistema debería notificar automáticamente sobre condiciones potencialmente adversas como heladas inminentes, períodos de sequía, lluvias intensas o cambios

bruscos de temperatura que puedan afectar cultivos sensibles. Las alertas podrían distribuirse mediante múltiples canales (aplicación móvil, mensajes SMS, correo electrónico, pantallas informativas) y personalizarse según cultivos específicos o umbrales críticos definidos por los usuarios finales.

En el ámbito de la gestión ambiental universitaria, se recomienda integrar los datos meteorológicos con sistemas de gestión de recursos hídricos para optimizar el riego de áreas verdes y cultivos experimentales. La implementación de algoritmos de programación de riego basados en balance hídrico real podría reducir significativamente el consumo de agua mientras mantiene condiciones óptimas para la vegetación, considerando factores como la capacidad de retención de agua de los suelos locales y eficiencia de sistemas de riego existentes.

Para fortalecer la aplicación en investigación científica, se sugiere implementar protocolos estandarizados de acceso, documentación y visualización de datos que faciliten su utilización en múltiples disciplinas académicas. La creación de un repositorio científico con interfaz programática (API) permitiría a investigadores y estudiantes acceder eficientemente a datos históricos y en tiempo real para análisis específicos, incluyendo metadatos detallados sobre instrumentación y calibración que cumplan con estándares internacionales.

Considerando la topografía y extensión de la universidad, se recomienda expandir el sistema actual mediante la implementación estratégica de nodos de monitoreo adicionales en diferentes microambientes. Esta red distribuida permitiría caracterizar con mayor precisión la variabilidad espacial de condiciones meteorológicas, identificando microzonas con características particulares relevantes para la planificación agrícola como bolsones de frío, áreas expuestas a vientos predominantes o zonas con regímenes hídricos específicos.

Para maximizar el impacto en la toma de decisiones, se sugiere desarrollar interfaces de visualización específicas para diferentes perfiles de usuarios, desde paneles simplificados con recomendaciones prácticas inmediatas para productores agrícolas hasta visualizaciones científicas avanzadas con capacidades analíticas completas para investigadores. La implementación de tecnologías de visualización adaptativa facilitaría significativamente la adopción y aplicación efectiva de la información generada.

En el contexto de las prácticas agrícolas sostenibles, se recomienda integrar el sistema meteorológico con modelos fenológicos y epidemiológicos para cultivos regionales prioritarios. Esto permitiría desarrollar sistemas de pronóstico de riesgo para enfermedades y plagas específicas basados en condiciones meteorológicas, facilitando la implementación de estrategias de manejo integrado y reduciendo potencialmente el uso de agroquímicos en cultivos como rosa, fresa o papa.

Para fortalecer la resiliencia operativa del sistema, se recomienda implementar mejoras en la protección contra factores ambientales adversos utilizando materiales como PETG o ASA para componentes expuestos, aplicando tratamientos hidrofóbicos especializados y diseñando sistemas mejorados de ventilación pasiva. La implementación de redundancia en sensores críticos y autonomía energética mediante sistemas solares aseguraría la disponibilidad constante de datos para toma de decisiones agrícolas oportunas.

En el marco de la gestión ambiental integral, se sugiere ampliar las capacidades del sistema para incluir el monitoreo de variables relacionadas con calidad del aire, particularmente relevantes en un entorno periurbano como Facatativá. La incorporación de sensores para material particulado, compuestos orgánicos volátiles y gases como ozono troposférico permitiría correlacionar condiciones meteorológicas con episodios de contaminación, estableciendo patrones que apoyen la planificación de actividades universitarias y la toma de decisiones en salud ambiental.

Para potenciar la contribución del proyecto a la investigación científica institucional, se recomienda establecer programas formales de investigación multidisciplinaria basados en los datos generados. Estos programas podrían abordar temáticas como caracterización de meteorología urbana, adaptación de sistemas agrícolas al cambio climático, optimización bioclimática de infraestructuras educativas o desarrollo de metodologías innovadoras para monitoreo ambiental distribuido, facilitando la participación de estudiantes de diferentes programas académicos.

Considerando el potencial educativo del sistema, se recomienda desarrollar módulos didácticos interactivos que utilicen datos reales para ilustrar conceptos en múltiples disciplinas. Estos módulos podrían incluir prácticas de laboratorio virtual para asignaturas como agroclimatología, física ambiental, estadística aplicada o programación, donde los estudiantes

analicen datos auténticos del entorno universitario, fomentando habilidades analíticas alineadas con necesidades actuales del sector agrícola y ambiental.

En el ámbito de la transferencia tecnológica, se sugiere establecer alianzas estratégicas con asociaciones de productores agrícolas, entidades ambientales y gobiernos locales para adaptar y replicar componentes del sistema según necesidades específicas. La organización de talleres prácticos sobre implementación de estaciones meteorológicas de bajo costo y análisis básico de datos agroclimatológicos para productores locales podría generar capacidades comunitarias significativas para la adaptación a la variabilidad climática.

Para fortalecer las capacidades predictivas enfocadas en eventos extremos de particular relevancia agrícola, se recomienda desarrollar modelos específicos para la predicción a corto plazo de fenómenos como granizadas, ráfagas de viento intensas o precipitaciones torrenciales. Estos modelos podrían entrenarse con técnicas de transfer learning aprovechando datos de eventos históricos documentados, complementados con información de plataformas regionales y enriquecidos mediante el sistema de retroalimentación de usuarios.

En el contexto de la gestión integral de la Universidad, se propone integrar los datos y predicciones meteorológicas con sistemas de gestión de infraestructura y planificación de actividades académicas. La implementación de protocolos específicos para reprogramación de actividades al aire libre, ajustes en sistemas de climatización o planificación de mantenimiento preventivo basados en condiciones meteorológicas predichas podría generar eficiencias operativas significativas.

Para fortalecer la sostenibilidad a largo plazo del sistema, se recomienda implementar protocolos exhaustivos de documentación técnica, mantenimiento preventivo y capacitación continua. La institucionalización formal del sistema dentro de la estructura administrativa y académica de la universidad, con asignación específica de responsabilidades y recursos, garantizaría su continuidad y evolución más allá del proyecto inicial.

En el marco de la colaboración científica regional, se sugiere establecer vínculos formales con redes meteorológicas nacionales e instituciones académicas afines. La integración parcial de

datos en redes como IDEAM o RedMetAgro incrementaría la visibilidad científica de la universidad mientras contribuye a la densificación de redes de monitoreo meteorológico en la región andina, posicionando a la institución como referente en innovación para monitoreo ambiental accesible.

Finalmente, se recomienda desarrollar estrategias de divulgación científica adaptadas a diferentes audiencias, como boletines agroclimáticos periódicos, infografías sobre patrones meteorológicos locales o videos explicativos sobre interpretación de predicciones. La implementación de pantallas informativas en espacios comunitarios de la universidad facilitaría la apropiación colectiva de la información meteorológica y maximizaría el impacto social del conocimiento generado en beneficio de las comunidades agrícolas y educativas de la región.

2.8. Bibliografía

Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*.

Ahrens, C. D. (2012). *Meteorology Today: An Introduction to Weather, Climate, and the Environment*. Cengage Learning.

Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). *Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements*. FAO Irrigation and Drainage Paper No. 56. Food and Agriculture Organization of the United Nations (FAO).
<https://www.fao.org/3/x0490e/x0490e00.htm>

Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (2006). *Evapotranspiración del cultivo: Guías para la determinación de los requerimientos de agua de los cultivos*. Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO).
<https://www.fao.org/3/x0490s/x0490s00.htm>

AWS IoT Documentation. (2024). *Security Best Practices for AWS IoT Core*. Amazon Web Services. <https://docs.aws.amazon.com/iot/latest/developerguide/security-best-practices.html>

Bahga, A., & Madiseti, V. (2015). *Internet of Things: A Hands-On-Approach*. Universities Press.

Barry, R. G., & Chorley, R. J. (2010). *Atmosphere, Weather and Climate*. Routledge.

Benítez, J. C., & Chaves, C. A. (2022). Diseño de una estación meteorológica de bajo coste orientada al internet de las cosas [Trabajo Fin de Grado]. Escuela Universitaria Politécnica La Almunia de Doña Godina (Zaragoza). <https://zagan.unizar.es/record/120399/files/TAZ-TFG-2022-4517.pdf?version=1>

Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.

Brownlee, J. (2017). *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery.

Castillo, O., & Melin, P. (2014). A review on interval type-2 fuzzy logic applications in intelligent control. *Information Sciences*, 279, 615-631.

Chamba Benítez, J., & Asensio Chaves, C. (2022). Diseño de una estación meteorológica de bajo coste orientada al internet de las cosas. Universidad de Zaragoza. <https://zagan.unizar.es/record/120399>

Comisión de Regulación de Comunicaciones (CRC). (2016). Resolución 5050 de 2016. [https://www.crcm.gov.co/uploads/images/files/Resolución%205050%20de%202016%20\(Título%20M%20Reglamento%20de%20Servicios%20de%20Telecomunicaciones\).pdf](https://www.crcm.gov.co/uploads/images/files/Resolución%205050%20de%202016%20(Título%20M%20Reglamento%20de%20Servicios%20de%20Telecomunicaciones).pdf)

Congreso de la República de Colombia. (1993). Ley 99 de 1993. <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=297>

Congreso de la República de Colombia. (2009). Ley 1341 de 2009. <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=37263>

Congreso de la República de Colombia. (2012). Ley 1581 de 2012. <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=49981>

Congreso de la República de Colombia. (2014). Ley 1715 de 2014.

<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=57013>

Congreso de la República de Colombia. (2014). Decreto 2469 de 2014.

<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=59424>

Consejo Nacional de Política Económica y Social (CONPES). (2019). Documento CONPES 3975: Política Nacional de Inteligencia Artificial. Departamento Nacional de Planeación.

<https://www.dnp.gov.co/CONPES>

Cordero Rosso, L. A., & Perea Alemán, A. F. (s.f.). Diseño de estación meteorológica para el estudio de implementación de energía eólica en la biblioteca comunitaria Policarpa Salavarrieta con adquisición de señales en plataforma IOT. Universidad Distrital Francisco José de Caldas. <https://repository.udistrital.edu.co/items/f220def0-fdeb-4af6-bd61-267185bfd197>

Creswell, J. W. (2018). Research Design: Qualitative, Quantitative, and Mixed Methods Approaches.

DAVIS estación meteorológica Descargar manuales de usuario | ManualsLib. (s. f.).

<https://www.manualslib.es/brand/davis/estacion-meteorologica.html>

Departamento Nacional de Planeación (DNP). (2024). Información institucional.

<https://www.dnp.gov.co>

Dualtrónica. (s.f.). GY-2561 Sensor Digital de luminosidad TSL2561 - lux.

<https://dualtronica.com/sensores/388-gy-2561-sensor-digital-de-luminosidad-tsl2561-lux.html>

FAO. (2013). Climate-smart agriculture: Sourcebook. Food and Agriculture Organization of the United Nations. <https://www.fao.org/3/i3325e/i3325e.pdf>

Fernández-Caramés, T. M., & Fraga-Lamas, P. (2018). A Review on the Use of Blockchain for the Internet of Things. *IEEE Access*, 7, 32979-33001.

<https://doi.org/10.1109/ACCESS.2019.2896082>

Firebase Documentation. (2024). Firebase Realtime Database. Google Developers.

<https://firebase.google.com/docs/database>

Función Pública. (2024). Decreto 298 de 2016 - Gestor Normativo.

<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=63678>

Función Pública. (2024). Documento CONPES 3975 de 2019 - Gestor Normativo.

<https://www.funcionpublica.gov.co>

Función Pública. (2024). Ley 1581 de 2012 - Gestor Normativo.

<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=49981>

Función Pública. (2024). Ley 99 de 1993 - Gestor Normativo.

<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=297>

Función Pública. (2024). Resolución 0583 de 2017 - Gestor Normativo.

<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=70768>

Google Cloud Documentation. (2024). Google Cloud IoT Core Overview. Google Cloud.

<https://cloud.google.com/iot-core/docs>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

<https://www.deeplearningbook.org/>

Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson.

Hernández Sampieri, R. (2014). *Metodología de la investigación*.

- Hernández, R. R. (2021). La agricultura de precisión. Una necesidad actual. *Revista Ingeniería Agrícola*, 11(1), 67-74.
<https://www.redalyc.org/journal/5862/586269368010/586269368010.pdf>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Höller, J., Tsiatsis, V., Mulligan, C., Karnouskos, S., Avesand, S., & Boyle, D. (2014). *From Machine-to-Machine to the Internet of Things: Introduction to a New Age of Intelligence*. Academic Press.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). OTexts. <https://otexts.com/fpp2/>
- IDEAM. (2019). Guía para la operación y mantenimiento de las estaciones meteorológicas convencionales. Instituto de Hidrología, Meteorología y Estudios Ambientales.
https://www.ideam.gov.co/sites/default/files/mapa-de-procesos/m-gdi-m-g005_guia_para_la_operacion_y_mantenimiento_de_las_estaciones_meteorologicas_convencionales_v2.pdf
- IDEAM. (2019). Procedimiento de instalación, operación y mantenimiento de equipos electrónicos en estaciones hidrometeorológicas automáticas. Instituto de Hidrología, Meteorología y Estudios Ambientales. https://www.ideam.gov.co/sites/default/files/mapa-de-procesos/m-gdi-h-p008_procedimiento_de_instalacion_operacion_y_mantenimiento_de Equipos_electronicos_en_estaciones_hidrometeorologicas_automaticas_v1.pdf
- IDEAM. (2024). Información institucional. Instituto de Hidrología, Meteorología y Estudios Ambientales. <https://www.ideam.gov.co>
- IDEAM - Instituto de Hidrología, Meteorología y Estudios Ambientales. (2017). *Sistema Nacional Ambiental - SINA*. <https://www.ideam.gov.co>

IEEE Standards for IoT (IEEE 802.15.4).

INTA - Instituto Nacional de Tecnología Agropecuaria. (2018). Manual de Agroclimatología Aplicada al Riego. https://inta.gob.ar/sites/default/files/inta_manual_agroclimatologia.pdf

Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM). (2017). Resolución 0583 de 2017. <https://www.ideam.gov.co>

Leemans, R., & Eickhout, B. (2004). Another reason for concern: Regional and global impacts on ecosystems for different levels of climate change. *Global Environmental Change*, 14(3), 219-228. <https://doi.org/10.1016/j.gloenvcha.2004.04.009>

Leith, C. E. (1974). Theoretical Skill of Monte Carlo Forecasts. *Monthly Weather Review*, 102(6), 409-418.

Lillesand, T., Kiefer, R., & Chipman, J. (2015). *Remote Sensing and Image Interpretation*. Wiley.

López Vargas, D. F., & Balladares Feijoo, C. L. (2021). Diseño e implementación de un prototipo de estación meteorológica agrícola autosustentable para el monitoreo de parámetros ambientales en cultivos de cacao mediante Raspberry Pi [Tesis de pregrado]. Universidad Politécnica Salesiana. <https://dspace.ups.edu.ec/handle/123456789/20505>

Lutgens, F. K., & Tarbuck, E. J. (2013). *The Atmosphere: An Introduction to Meteorology*. Pearson.

Max Electrónica. (s.f.). Sensor de Luminosidad Infrarroja y de Ambiente I2C Modelo TSL2561. <https://maxelectronica.cl/sensores/122-sensor-de-luminosidad-infrarroja-y-de-ambiente-i2c-modelo-tsl2561.html>

Max Electrónica. (s.f.). Sensor de Temperatura y Humedad Modelo DHT22. <https://maxelectronica.cl/temperatura-y-humedad/133-sensor-de-temperatura-y-humedad-modelo-dht22.html>

Melo Quintero, J. J. (2011). Diseño y construcción de un sistema de medidas de efecto Hall DC y AC. Universidad Nacional de Colombia.

<https://repositorio.unal.edu.co/bitstream/handle/unal/8158/6706510.2011.pdf?sequence=1>

Ministerio de Ambiente y Desarrollo Sostenible. (2024). Información institucional.

<https://www.minambiente.gov.co>

Ministerio de Ambiente y Desarrollo Sostenible. (2024). Sistema Nacional Ambiental - SINA.

<https://www.minambiente.gov.co>

Ministerio de Minas y Energía. (2024). Información institucional.

<https://www.minenergia.gov.co>

Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC). (2024).

Información institucional. <https://www.mintic.gov.co>

Mitchell, T. M. (1997). Machine Learning. McGraw-Hill.

Monteith, J. L. (1965). Evaporation and environment. In Symposia of the Society for Experimental Biology (Vol. 19, pp. 205-234). Cambridge University Press.

National Weather Service (NWS, USA). Tipping Bucket Rain Gauge Calibration Manual (NOAA). <https://psl.noaa.gov/data/obs/instruments/TippingBucket.pdf>

Naylamp Mechatronics. (s.f.). Sensor de temperatura y humedad relativa DHT22 (AM2302).

<https://naylampmechatronics.com/sensores-temperatura-y-humedad/58-sensor-de-temperatura-y-humedad-relativa-dht22-am2302.html>

Organización Meteorológica Mundial (OMM). (2021). Guía sobre el Clima y los Servicios

Climáticos. [https://library.wmo.int/es/records/item/28514-guia-de-practicas-](https://library.wmo.int/es/records/item/28514-guia-de-practicas-climatologicas?offset=6#:~:text=La%20presente%20publicación%20tiene%20por%20objet)

[climatologicas?offset=6#:~:text=La%20presente%20publicación%20tiene%20por%20objet](https://library.wmo.int/es/records/item/28514-guia-de-practicas-climatologicas?offset=6#:~:text=La%20presente%20publicación%20tiene%20por%20objet)
[o%20proporcionar%20orientación,la%20información%20y%20los%20servicios%20climáticos.%20169%20p.](https://library.wmo.int/es/records/item/28514-guia-de-practicas-climatologicas?offset=6#:~:text=La%20presente%20publicación%20tiene%20por%20objet)

Peixoto, J. P., & Oort, A. H. (1992). *Physics of Climate*. American Institute of Physics.

Penman, H. L. (1948). Natural evaporation from open water, bare soil and grass. *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences*, 193(1032), 120-145. <https://doi.org/10.1098/rspa.1948.0037>

Pérez, L. D. J. (2022). *Diseño de dispositivo de bajo costo para el monitoreo de variables climáticas y humedad del suelo en agricultura de precisión [Tesis doctoral]*. Universidad Tecnológica de Pereira. <https://repositorio.utp.edu.co/server/api/core/bitstreams/1a7b3da7-53db-442c-8888-d3fdb32e72dd/content>

Pérez-Sánchez, J., Delgado, A. R., & Prieto, G. (2020). Propiedades psicométricas de las puntuaciones de los test más empleados en la evaluación de la regulación emocional. *Papeles del Psicólogo*, 41(2), 116-124. <https://doi.org/10.23923/pap.psicol2020.2931>

Pottie, G., & Kaiser, W. (2000). *WIRELESS INTEGRATED NETWORK SENSORS*.

Presidencia de la República de Colombia. (2016). Decreto 298 de 2016.

<https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=63678>

Qbprofe. (s. f.). Interruptores de Posición magnéticos Reed-Switch - QBPROFE Academy. <https://www.qbprofe.com/automatizacion-instrumentacion-industrial/interruptores-de-posicion-magneticos-reed-switch/>

Rodríguez, A. A. A., Carlos, C. L. J., Lignia, D. A. M., & Agualongo, P. A. B. (2023). Análisis de Sistemas IoT Basado en Hardware y Software Libre: Analysis of IoT Systems Based on Hardware and Free Software. *Revista Científica Multidisciplinar G-nerando*, 4(2). <https://revista.gnerando.org/revista/index.php/RCMG/article/view/135>

Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.

Sánchez, C. E. S., & Cruz, E. M. S. (2022). *Diseño y construcción de un prototipo IOT para generación de información meteorológica que contribuya al análisis del fenómeno de isla de*

calor urbano. *Revista Científica de Ingenierías y Arquitectura*, 1(1), 30-41.

<https://revistas.ulsaoaxaca.edu.mx/RCIA/article/view/153>

Solanki, C. S. (2015). *Solar Photovoltaics: Fundamentals, Technologies and Applications*.

Superintendencia de Industria y Comercio (SIC). (2024). *Protección de datos personales*.

<https://www.sic.gov.co>

Unidad de Planeación Minero Energética (UPME). (2024). *Información institucional*.

<https://www.upme.gov.co>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I.

(2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.

[https://papers.nips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-](https://papers.nips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf)

[Paper.pdf](https://papers.nips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf)

Vega Rodríguez, E. (2022). *Protocolo de observaciones en las estaciones meteorológicas:*

Contrato interadministrativo No 143 – 2018 IDEAM – Universidad Nacional de Colombia.

Universidad Nacional de Colombia. Facultad de Ciencias, Departamento de Geociencias.

Villagrasa, D., & Rodríguez, F. (2019). *IoT aplicado a Agricultura de Precisión: Sensores y*

Redes de Comunicación. Editorial Marcombo.

Wang, H., Chen, Y., & Hong, T. (2019). Review of Smart Meter Data Analytics: Applications,

Methodologies, and Challenges. *IEEE Transactions on Smart Grid*, 10(3), 3125-3148.

<https://doi.org/10.1109/TSG.2018.2818167>

World Meteorological Organization (WMO). *Guide to Meteorological Instruments and Methods*

of Observation, WMO-No. 8.

Yang, S., Zhan, D., Stathopoulos, T., Zou, J., Shu, C., & Wang, L. L. (2024). *Urban*

microclimate prediction based on weather station data and artificial neural network. *Energy*

and Buildings, 314, 114283.

Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353.

Zhang, G., Eddy Patuwo, B., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35-62.
[https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)

2.9. Anexos

2.9.1. Bitácora

Noviembre 2024

Bitácora 1

Fecha: 14 de noviembre de 2024

Actividad Realizada: Acompañamiento del director para revisar observaciones de los jurados. Análisis de comentarios sobre requerimientos técnicos y funcionales de la estación meteorológica.

Observaciones: Se creó plan de acción para abordar cada observación. Se acordó fortalecer justificación técnica del ESP32 y ampliar descripción de algoritmos de lógica difusa. Se reorganizará la sección de requerimientos para mejorar claridad.

Noviembre 2024

Bitácora 2

Fecha: 29 de noviembre de 2024

Actividad Realizada: Acompañamiento del director. Revisión de requerimientos técnicos y análisis de alternativas de sensores según disponibilidad local.

Observaciones: Definidos parámetros mínimos de precisión para cada sensor. Seleccionado ESP32 por capacidad dual-core y conectividad inalámbrica.

Febrero 2025

Bitácora 3

Fecha: 6 de febrero de 2025

Actividad Realizada: Acompañamiento del director. Revisión de arquitectura de hardware y del diseño para impresión 3D.

Observaciones: Aprobado diseño modular de estructura. Establecidas especificaciones técnicas y presupuesto detallado.

Febrero 2025

Bitácora 4

Fecha: 13 de febrero de 2025

Actividad Realizada: Acompañamiento del director. Finalización de ensamblaje. Implementación de sistema de almacenamiento en SD y configuración del RTC. Planificación de protocolos de validación.

Observaciones: Ensamblaje completado exitosamente. Identificados ajustes menores en firmware para optimizar consumo energético y precisión. Establecido protocolo para validación empírica.

Febrero 2025

Bitácora 5

Fecha: 20 de febrero de 2025

Actividad Realizada: Configuración del entorno de desarrollo y planificación del sistema de lógica difusa.

Observaciones: Establecido procedimiento de post-procesamiento para resistencia a intemperie.

Bitácora 6

Fecha: 12 de abril de 2025

Actividad Realizada: Acompañamiento del director. Evaluación integral tras un mes de

Sistema Computacional Inteligente

operación. Análisis comparativo de predicciones versus condiciones reales.

Planificación de informe final.

Observaciones: Sistema muestra robustez y precisión satisfactorias. Comparación confirma capacidad para capturar particularidades locales. Estructurado informe final y plan de divulgación para la comunidad universitaria.



Firma del director

Jaime Eduardo Andrade
Ramirez



Firma del estudiante 1

Bryan René Rojas Hernández
1000049801



Firma del estudiante 2

Nathalia Gutiérrez Alarcón
1193574756