

## Modelos híbridos y configuraciones tecnológicas para pronóstico de variables suelo-meteorológicas: revisión exhaustiva

### Hybrid Models and Technological Configurations for Forecasting Soil-Meteorological Variables: An Exhaustive Review

Giovanni Alexander Cuaran Páez<sup>1</sup> Luis Gabriel Lafaurie Ponce<sup>1-2</sup> Jenny Lucía Huertas Delgado<sup>1-2</sup> Daniel Alejandro Molina Cuaichar<sup>1</sup>

<sup>1</sup> Programa de Ingeniería Ambiental, Universidad Mariana, Pasto, Nariño, Colombia

<sup>2</sup> Grupo de investigación Ambiental (GIA)

#### ¿Cómo citar?

Cuaran GA, Lafaurie LG, Huertas JL, Molina DA. Modelos híbridos y configuraciones tecnológicas para pronóstico de variables suelo-me-teorológicas: revisión exhaustiva. Ingeniería y Competitividad, 2025, 27(2)e-30514876.

[https://doi.org/10.25100/  
iyc.v27i2.14786](https://doi.org/10.25100/iyc.v27i2.14786)

Recibido: 05/06/25  
Revisado: 10/06/25  
Aceptado: 15/08/25  
Online: 26/09/25

#### Correspondencia

jlhuertas@umariana.edu.co

## Resumen

**Introducción:** Los diseños de estaciones caseras de monitoreo del clima y del suelo han mostrado avances significativos en aplicaciones de registro, procesamiento, calibración y pronóstico, especialmente en agricultura sustentable. El desarrollo tecnológico ha impulsado el uso de sensores de aire y suelo de bajo costo, lo que ha permitido conformar bases de datos útiles para mejorar las mediciones y predicciones espacio-temporales.

**Objetivo:** Analizar de manera exhaustiva las configuraciones tecnológicas, aplicaciones, tendencias, calidad y necesidades de investigación en el monitoreo y pronóstico de variables suelo-meteorológicas.

**Materiales y Métodos:** Se revisaron artículos científicos publicados y se aplicaron herramientas de análisis estadístico y minería de datos, particularmente clustering jerárquico, para identificar patrones y enfoques relevantes en el campo.

**Resultados:** Los estudios muestran que la calibración de sensores de aire y suelo mediante métodos matemáticos, estadísticos y de inteligencia artificial ha permitido obtener registros confiables. Estos datos se emplean en la predicción de condiciones meteorológicas, del suelo y de niveles futuros de nutrientes y contaminantes. Asimismo, se observa un crecimiento en la utilización de modelos híbridos que combinan dos o más métodos de pronóstico, junto con estaciones meteorológicas y edáficas equipadas con diferentes sensores.

**Conclusiones:** La integración de tecnologías de bajo costo y modelos híbridos fortalece la precisión de los registros y pronósticos suelo-meteorológicos. Sin embargo, se identifican desafíos en la mejora de la calidad de los datos y en la consolidación de tendencias que orienten la investigación futura.

**Palabras clave:** Análisis ambiental, Agricultura de precisión, Sensores, Macrodatos, Inteligencia Artificial.

## Abstract

**Introduction:** Homemade designs of climate and soil monitoring stations have shown significant advances in recording, processing, calibration, and forecasting applications, particularly in sustainable agriculture. Technological development has promoted the use of low-cost air and soil sensors, enabling the creation of useful databases to improve measurements and spatio-temporal predictions.

**Objective:** To provide an exhaustive analysis of technological configurations, applications, trends, quality, and research needs in soil-meteorological monitoring and forecasting.

**Materials and Methods:** A review of published scientific articles was conducted, complemented with statistical analyses and data mining techniques, particularly hierarchical clustering, to identify patterns and relevant approaches in the field.

**Results:** Studies indicate that the calibration of air and soil sensors through mathematical, statistical, and artificial intelligence methods has enabled the generation of reliable records. These data have been used to predict weather and soil conditions, as well as future levels of nutrients and contaminants. Moreover, there is a growing trend toward the use of hybrid models that combine two or more forecasting methods, together with meteorological and edaphic stations equipped with diverse sensors.

**Conclusions:** The integration of low-cost technologies and hybrid models strengthens the accuracy of soil-meteorological records and forecasts. However, challenges remain in improving data quality and consolidating research trends to guide future advancements in the field.

**Keywords:** Environmental analysis, precision agriculture, sensor, big data, artificial intelligence



## Contribución a la literatura

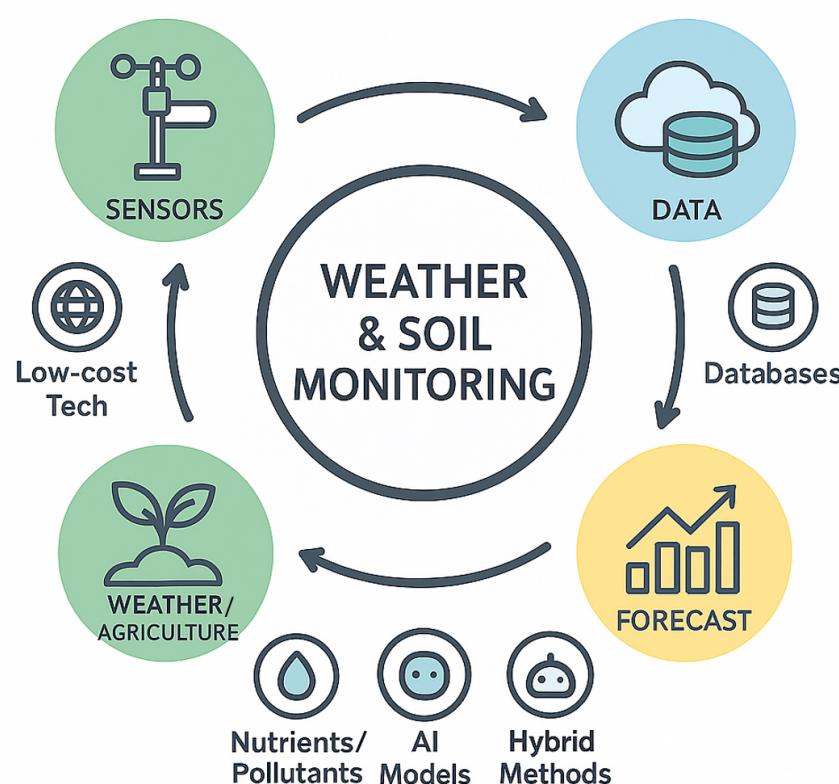
### ¿Por qué se llevó a cabo?

El registro de contaminantes como partículas en el aire o metales pesados en el suelo es esencial para estimar los niveles de contaminación o gestionar las políticas de mitigación. Muchas investigaciones actuales han propuesto dispositivos de monitoreo que utilizan uno o más tipos de sensores para correlacionar y predecir las concentraciones de contaminantes. Sin embargo, existe una falta de información sobre las estaciones de monitoreo con variables climáticas o de suelo estándar que apoyen eficientemente la evaluación de la dinámica de contaminación.

Por lo tanto, realizamos esta investigación para identificar las principales configuraciones tecnológicas de las estaciones de monitoreo de contaminantes del aire y del suelo agrupando protocolos y dispositivos de medición estadísticamente similares, utilizados por diferentes trabajos.

### ¿Cuáles fueron los resultados más significativos? ¿Qué aportan estos resultados?

Se identificaron las principales configuraciones tecnológicas de sensores de aire/suelo en las estaciones de monitoreo para aplicaciones de contaminación, registro meteorológico y de suelo, y pronóstico de clima/suelo. Se han identificado los principales modelos híbridos de predicción utilizados para predecir las condiciones meteorológicas/del suelo y los contaminantes. Las tendencias y brechas de investigación con respecto al año, la ubicación y los usos de las principales estaciones de monitoreo meteorológico / del suelo y los modelos de pronóstico han sido evaluados y propuestos para trabajos futuros. Los autores introducen el concepto de estaciones de monitoreo holístico, agrupando mediciones de condiciones climáticas y contaminantes, nutrientes y propiedades físico-químicas en el aire y el suelo, presentando un enfoque novedoso para conocimientos ambientales integrales. Al incorporar trabajos sobre pronóstico espacial y temporal de contaminantes y variables, esta investigación contribuye a la toma de decisiones informadas en agricultura sostenible y gestión ambiental, fomentando un futuro más saludable para nuestro planeta.



## Introducción

Las mediciones de variables del aire y el suelo se han utilizado en diversas aplicaciones, como la previsión meteorológica, la agricultura, la predicción de desastres, el diagnóstico del aire y el suelo y la previsión de la contaminación. Estos registros generalmente se obtienen mediante sensores de estado sólido independientes o sistemas robustos como estaciones meteorológicas y de suelo. El rápido desarrollo tecnológico y la información disponible en foros o sitios web han permitido el desarrollo de sistemas caseros de bajo costo capaces de medir diversas condiciones climáticas como la temperatura del aire, la humedad del aire, la presión atmosférica, la dirección del viento, la velocidad del viento, la precipitación o la irradiancia. Además, estos sistemas pueden medir variables del suelo como la temperatura, la humedad y el pH. Los investigadores han informado que el diseño mecánico-electrónico de estos sistemas de medición garantiza su precisión a través de un proceso de calibración y ajuste. Alternativamente, algunos sistemas procesan datos utilizando modelos matemáticos integrados, técnicas estadísticas, inteligencia artificial (IA) y métodos híbridos en microcontroladores. Por ejemplo, los invernaderos y los pequeños agricultores han integrado la medición automatizada local de sensores de pH, humedad, precipitaciones y temperatura, integrados con sistemas de control de retroalimentación acoplados, para gestionar el crecimiento de las plantas y el riego de manera efectiva. Además, algunas granjas incluyen anemómetros y pequeñas estaciones meteorológicas para registrar el clima local.

Aunque estas ventajas son asequibles, muchos investigadores aún confían en los datos del aire / suelo de las bases de datos y estaciones meteorológicas / del suelo sólidas. Esta elección se debe a que estas señales distribuidas espacialmente y a largo plazo proporcionan suficiente información sobre el clima local y las condiciones del suelo. Sin embargo, es importante tener en cuenta que su almacenamiento y gestión son costosos. Además, el procesamiento de datos utilizando software especializado a menudo requiere tiempo para permitir una comprensión profunda de la evolución temporal / espacial de las propiedades físicas y químicas del aire / suelo. Es notable que tanto las estaciones meteorológicas como las plataformas de datos suelen estar disponibles públicamente, lo que facilita el acceso y la utilización generalizados, a diferencia de las estaciones de monitoreo de suelos y sus datos, que se utilizan principalmente para fines de investigación específicos y no se encuentran con frecuencia en las plataformas de datos públicas. Esta accesibilidad limitada a los datos del suelo puede plantear desafíos para los investigadores que buscan conjuntos de datos completos e integrados para sus estudios ambientales.

El cambio climático es actualmente un problema apremiante porque conduce al aumento de la temperatura global, variaciones en los patrones de lluvia, disminución de la capa de nieve y reducción de los glaciares (1). Se ha realizado una amplia investigación para evaluar la correlación entre estos impactos, la contaminación del aire / suelo y las condiciones climáticas / del suelo. Los cambios de temperatura, por ejemplo, muestran una alta correlación positiva con concentraciones de partículas de tamaño de diámetro inferior a y (y respectivamente) y diversos contaminantes como las emisiones de dióxido de azufre () o dióxido de nitrógeno (). Por el contrario, las precipitaciones muestran una baja correlación negativa con estos contaminantes  $2.5 \mu\text{m}$ ,  $10 \mu\text{m}$ ,  $PM_{2.5}$ ,  $PM_{10}$ ,  $SO_2$ ,  $NO_2$  (2). Las estaciones meteorológicas y los sensores climáticos se utilizan para medir y registrar datos de temperatura, humedad, presión atmosférica, velocidad y

dirección del viento. Estos conjuntos de datos se utilizan en modelos de pronóstico para predecir el comportamiento dinámico de estas condiciones y evaluar el comportamiento de los contaminantes (3–6).

Por otro lado, la contaminación del aire y el suelo se ha convertido en un importante problema de salud pública mundial debido a los altos niveles de contaminantes liberados por las actividades antropogénicas, incluidas las industrias modernas, las emisiones vehiculares y la urbanización (7,8). Los contaminantes pueden tener impactos negativos en la salud incluso en bajas concentraciones, aumentando el riesgo de enfermedades cardiovasculares e infecciones respiratorias y pulmonares, y debilitando el sistema inmunológico (9–11). En cuanto a la contaminación del aire, en 2015, la Organización Mundial de la Salud (OMS) reconoció la contaminación del aire como un factor de riesgo para enfermedades no transmisibles como la cardiopatía isquémica, el accidente cerebrovascular, la enfermedad pulmonar obstructiva crónica, el asma y el cáncer (12). Además, se han encontrado correlaciones entre la contaminación del aire y las enfermedades, con series temporales superpuestas de partículas con un diámetro inferior a () y mortalidad por Covid-19 en Europa  $2.5\mu m PM_{2.5}$  (13). Por otro lado, la ingestión de verduras y suelos contaminados supone un factor de riesgo para trastornos gástricos y gastrointestinales debido a las altas concentraciones de metales como plomo (Pb), zinc (Zn), cobre (Cu), cadmio (Cd), arsénico (As), níquel (Ni) y cromo (Cr) en ciertos cultivos (14,15).

Además, los contaminantes del aire y del suelo tienen efectos perjudiciales para el medio ambiente, en relación con el cambio climático. Estos efectos incluyen fenómenos como la lluvia ácida, la neblina, el efecto invernadero, el agujero de ozono, el smog fotoquímico y la disminución de la microbiota del suelo (biomasa y actividad microbiana) (16–20).

Debido a esto, la implementación de un sistema de gestión de control de emisiones contaminantes se vuelve imperativa. Los rápidos avances tecnológicos en la Cuarta Revolución Industrial han llevado a los investigadores a considerar las tecnologías digitales. Estas tecnologías han liderado el desarrollo y la evaluación de modelos de pronóstico que emplean registros de series temporales y espaciales de variables climáticas y del suelo para predecir el comportamiento dinámico del aire y el suelo, incluidos los niveles de contaminación. Para lograr esto, estos modelos incorporan métodos matemáticos, estadísticos y de IA para procesar bases de datos meteorológicas y de suelos, que describen el pasado, presente y futuro (predicción) del comportamiento de la dinámica del aire / suelo. Los hallazgos de estos modelos tienen un potencial significativo para apoyar la aplicación de políticas ambientales, reducir los niveles de contaminación de acuerdo con las leyes ambientales locales y mitigar los impactos negativos socioambientales. Por lo tanto, comprender las correlaciones entre las tecnologías de registro del aire y el suelo, las variables del clima y el suelo, la dinámica del aire y el suelo, la contaminación del aire y el suelo, así como los modelos de evaluación y pronóstico es crucial para evaluar el impacto de los enfoques tradicionales y novedosos en la mejora de la calidad del clima y el suelo, la reducción de la contaminación ambiental y la prevención de desastres.

Los investigadores pueden beneficiarse enormemente de los resultados de este estudio para avanzar en futuras metodologías de investigación relacionadas con el desarrollo de sistemas de medición de variables aire/suelo y las técnicas de información de procesamiento integradas para modelos de pronóstico meteorológico o de contaminación.

## Motivación de la revisión

Durante las dos primeras décadas del siglo XXI la importancia de predecir las condiciones climáticas y del suelo ha aumentado significativamente, debido a las fuertes correlaciones observadas entre las mediciones de las propiedades fisicoquímicas del aire / suelo y los niveles de contaminantes, este conocimiento tiene una amplia gama de aplicaciones, incluidas las aplicaciones agrícolas, la prevención de desastres y la gestión ecológica (6,18,21). Los investigadores han dedicado sus esfuerzos a desarrollar métodos de pronóstico que les permitan obtener registros precisos del clima, el suelo y los contaminantes. Con esta valiosa información, se pueden desarrollar políticas de gestión ambiental para reducir eficazmente los niveles de contaminantes de conformidad con los umbrales superiores de las leyes ambientales locales (20,22–25).

Además, estos avances han permitido a las granjas mejorar la calidad de los cultivos mediante la optimización de los períodos de siembra y cosecha, la determinación de los programas de riego de plantas apropiados y la gestión de las concentraciones de pesticidas, estas mejoras se logran mediante la aplicación de sistemas de control y pronóstico que utilizan registros meteorológicos / del suelo como predictores (21,26).

Por otro lado, se han realizado numerosas revisiones para enumerar y evaluar las ventajas y limitaciones de los diferentes métodos de pronóstico (3,27–30). En un estudio reciente, Alexander Baklanov y Zhang (31) reconoció la brecha de información existente con respecto a los modelos matemáticos de pronóstico de la calidad del aire (AQF) en revisiones anteriores. Su estudio evalúa las ventajas y la precisión de utilizar sistemas de pronóstico multiescala, modelos de procesos meteorológicos y modelos de emisión atmosférica como los sistemas de predicción ambiental sin fisuras (SEPS), el modelado combinado de química y meteorología (CCMM) y el pronóstico de análisis por conjuntos (EFA). Este enfoque implica la integración de varias fuentes de datos y modelos matemáticos de diferentes tipos con supuestos alternativos, utilizando distintos métodos de reconocimiento de patrones (32). Su contribución mejora el AQF al incorporar el acoplamiento en línea de la dinámica atmosférica y la química, la mejora de la asimilación y fusión de datos, el aprendizaje automático, los enfoques de predicción multiescala y el pronóstico subestacional a estacional.

Los modelos de pronóstico también se utilizan en la agricultura. Por ejemplo, Thorat et.al (21) identificó insecticidas y fertilizantes adecuados para ser aplicados a los cultivos mediante el procesamiento de imágenes de plagas utilizando los métodos de la función de probabilidad de transición (TPF) y la red neuronal convolucional (CNN). Este enfoque les permitió identificar insecticidas y fertilizantes adecuados para los cultivos. El sistema integró medidas de concentración de nitrógeno, potasio y fósforo (estas son medidas individuales y sincrónicas, generalmente nombradas por sus símbolos químicos NKP), imágenes de plagas e información sobre los principales insecticidas utilizados, lo que le permitió predecir y recomendar el mejor insecticida para el control de plagas. Khaydukova et.al (33) emplearon una metodología similar, pero también consideraron el pH, la conductividad eléctrica (CE) y el carbono orgánico como factores adicionales a evaluar. Estos valores se correlacionaron mediante técnicas de regresión multivariable.

Por otro lado, Lu Bai et.al (34,35) Revisó la teoría y las aplicaciones de los modelos de pronóstico híbridos, que abarcan métodos estadísticos, de IA y numéricos, junto con su teoría y aplicaciones.

Además, compararon y evaluaron las ventajas y desventajas de diferentes combinaciones de estos métodos. Los modelos estadísticos tienen una amplia gama de aplicaciones ambientales y requieren menos tiempo de procesamiento; sin embargo, se necesita una gran cantidad de datos de series temporales. Los modelos de IA, por otro lado, mejoran el pronóstico con una cantidad relativamente menor de datos; pero, su algoritmo puede ser inestable. Los modelos híbridos, que combinan enfoques estadísticos y de IA, ofrecen robustez, alta adaptabilidad y un bajo riesgo de fracaso; sin embargo, su diseño es relativamente complejo.

Otros investigadores se han centrado en describir métodos específicos para abordar las brechas de información en los modelos de pronóstico ambiental (17–19). Hui Liu et.al (19) evaluó la precisión, las ventajas y las limitaciones de los métodos de descomposición espectral de datos que involucran componentes de frecuencia. Exploraron técnicas como la transformación de ondículas y la descomposición variacional y empírica, junto con modelos de pronóstico como redes neuronales artificiales (ANN), máquinas de vectores de soporte (SVM) y máquinas de aprendizaje extremo (ELM).

A pesar de que algunas revisiones recopilan y evalúan diferentes variables meteorológicas / del suelo y sus métodos de pronóstico, sigue existiendo una brecha de información sobre las correlaciones y la agrupación entre predictores, métodos, modelos de pronóstico, calidad y otras características. Esta revisión tiene como objetivo abordar esta brecha resumiendo y correlacionando los métodos de medición del clima / suelo, las aplicaciones y los métodos de pronóstico del clima / suelo utilizados en diferentes investigaciones, con el objetivo de responder a la pregunta:

¿Cuáles son las principales configuraciones tecnológicas de las estaciones meteorológicas/del suelo y sus principales modelos de pronóstico híbridos utilizados en diferentes aplicaciones del aire/suelo?

### Organización de la revisión

En esta revisión, primero recopilamos y organizamos la información esencial de cincuenta documentos de investigación. A continuación, discutimos las aplicaciones de los registros meteorológicos / del suelo, incluidos dispositivos, métodos de comunicación, técnicas de almacenamiento y métodos de pronóstico. Además, proporcionamos descripciones detalladas, ubicaciones geográficas, años de estudio y enfoques de comunicación comúnmente empleados.

Posteriormente, presentamos una descripción crítica de las principales configuraciones y dispositivos electrónicos, aplicaciones, sistemas integrados y modelos de pronóstico híbridos utilizados en diferentes investigaciones. Esta información está respaldada por los resultados del análisis multivariado que incluye la evaluación de la normalidad, el análisis de componentes principales, la correlación y la agrupación jerárquica. Finalmente, se proporcionan conclusiones y recomendaciones.

## Materiales y métodos

### Estrategia de búsqueda y selección de literatura

Para nuestro estudio, hemos construido una ecuación de búsqueda utilizando la siguiente estructura: "Tipo de estación" Y "Condición climática o del suelo" Y "Método de programación" Y "Sistema de comunicación" Y "Método de pronóstico". Cada clasificador contiene la siguiente combinación de palabras clave:

"Tipo de estación": estación meteorológica O estación de suelo

"Condición meteorológica o del suelo": temperatura O humedad O precipitación O presión O humedad O pH O NPK O sensores O registro

"Método de programación": Microcontrolador O Python O SQL O MySQL

"Sistema de comunicación": WiFi O IoT O MicroSD O Bluetooth O Xbee O zigbee

"Método de pronóstico": Aprendizaje autónomo O pronóstico O calidad del aire O calidad del suelo

Como fuentes de datos se utilizaron bases de datos como Google Scholar, Scopus, Scielo, Science Direct, IEEE Xplore y repositorios de institutos de investigación digital, donde se aplicó la ecuación de búsqueda para obtener un conjunto de documentos de investigación relacionados con la medición de las condiciones meteorológicas y del suelo, que incluye tecnologías como estaciones suelo-meteorológicas o sistemas embebidos. Además, hemos incluido artículos con aplicaciones de modelos tradicionales (calibración) y de pronóstico para evaluar o predecir la calidad del aire y el suelo, utilizando registros ambientales temporales y espaciales como predictores. Se consideró una muestra estadística de 50 documentos de investigación aleatorios del conjunto más grande obtenido. Tabla 1.

Tabla 1. Clasificación de diferentes investigaciones

Tipo de estación	Condiciones climáticas o del suelo	Método de programación		Sistema de comunicación		Método de pronóstico	Ref.
		Uno	Dos o más	Uno	Dos o más	Uno	
Clima y suelo	Temperatura del aire, humedad		✓		✓		(36)
		✓		✓		✓	(37)
		✓		✓			(26,38)
				✓			(39,40)
				✓		✓	(41,42)
				✓			(43)
		✓		✓		✓	(44,45)
	Temperatura del aire,			✓			(46)
				✓		✓	(47)
	Temperatura del aire, humedad, gases	✓		✓		✓	(48)
		✓			✓		(49,50)
		✓		✓			(51)
		✓				✓	(30,52,53)
				✓		✓	(5)
Tiempo	Temperatura del aire, Humedad, Precipitación		✓	✓		✓	(54)
				✓		✓	(55)
		✓		✓		✓	(56–58)
				✓			(59)
				✓		✓	(60)
		✓				✓	(61)
				✓		✓	(62)
	Gases					✓	(23,63,64)
		✓				✓	(65)
	Temperatura del aire, Humedad, Presión	✓		✓			(66–68)
Suelo	Humedad	✓					(69)
						✓	(70)
				✓			(71)
	NKP			✓			(72)
		✓		✓		✓	(21)
	pH del suelo, NKP			✓		✓	(73)
		✓				✓	(33)
				✓			(74)
Suelo	✓			✓			(75)
	Humedad, pH del suelo	✓				✓	(76)
				✓			(77)
		✓		✓			(78)
Suelo	Temperatura del suelo	✓		✓		✓	(79)

Los documentos de investigación se clasificaron en los siguientes clasificadores: tipo de estación (clima o suelo), condiciones climáticas y del suelo, tipo de software, tipo de comunicación,

método de pronóstico, año y lugar (Mesa 1). Organizamos la información en una matriz con cada clasificación como columnas y el número de documentos como filas.

#### Tratamiento estadístico

Se calculó la frecuencia para cada característica para identificar características similares entre las investigaciones. Se realizó una prueba de Shapiro-Wilk y una correlación de Kendall para determinar y evaluar el nivel de distribución normal y las correlaciones, respectivamente, para las condiciones climáticas / del suelo, el método de programación, el sistema de comunicación y el método de pronóstico. Posteriormente, se aplicó un Análisis de Componentes Principales (PCA) a los datos del modelo meteorológico/de suelo y de pronóstico para agrupar diferentes sensores de aire/suelo en cinco estaciones meteorológicas/de suelo principales basadas en los componentes principales obtenidos. Además, diferentes métodos de pronóstico se agruparon en once modelos de pronóstico híbridos, considerando la tendencia hacia el logro de precisión con menores requisitos de procesamiento y almacenamiento a través de métodos complementarios.

Finalmente, se calculó la correlación de Kendall y la agrupación de distritos de tipo jerárquico entre estaciones meteorológicas / de suelo, modelos de pronóstico híbridos, datos de año de publicación y continente para evaluar los principales usos de configuración.

#### Principales estaciones de medición y monitoreo del clima / suelo

En Figura 1 a), se muestra la frecuencia de los registros meteorológicos utilizados en los documentos. Entre las variables climáticas, la temperatura presenta la mayor variabilidad, seguida de la humedad relativa, la irradiancia, la velocidad del viento y la presión. Estas variables se miden y registran fácilmente debido a que hay muchos sensores económicos, asequibles y precisos disponibles tanto en estaciones meteorológicas robustas como en diseños caseros. La temperatura y la humedad relativa se miden con frecuencia juntas y exhiben una fuerte correlación de Kendall (0.69 con ) (ver Apéndice). Los sensores comerciales a menudo integran dispositivos que generan potencial eléctrico en respuesta a cambios de temperatura y humedad. En consecuencia, estas dos variables a menudo se observan juntas ya que la humedad relativa depende directa y estrechamente de la temperatura ambiente y la cantidad de vapor de agua que se retiene en el aire circundante  $p < 0.05$  (80,81). Del mismo modo, la velocidad del viento muestra una fuerte correlación con la dirección del viento (). Además, la temperatura tiene una correlación considerable con la precipitación, la presión, la irradiancia y la velocidad del viento (y, respectivamente). Por lo tanto, la temperatura se mide comúnmente junto con otras condiciones climáticas. Sin embargo, si bien las condiciones climáticas están correlacionadas principalmente, la 0.740.34, 0.410.470.470.38 etá (UV) exhiben correlaciones semanales con otras condiciones climáticas.

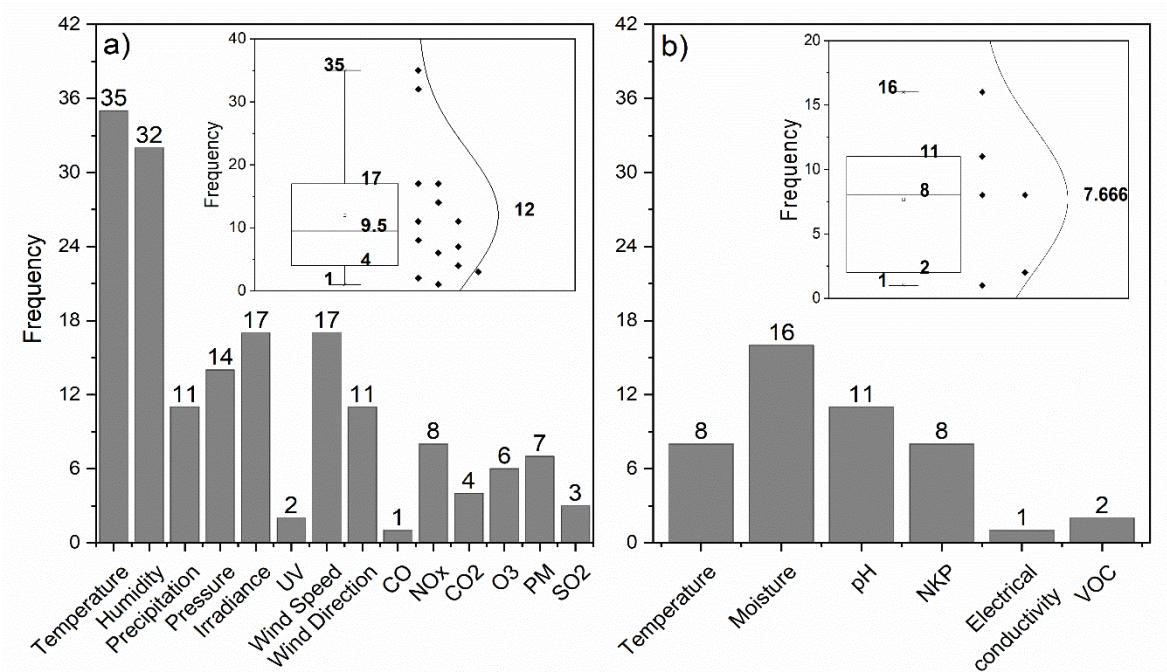


Figura 1. Histograma, diagrama de caja y curva normal de a) clima y b) variables de suelo.

El diagrama de caja y el análisis de la curva normal indican que los contaminantes gaseosos como (Óxidos de nitrógeno con ), (Óxidos de carbono con ), tienen una frecuencia más baja. Los contaminantes pueden variar según su ubicación; por lo tanto, los contaminantes que son objeto de diversas investigaciones son principalmente diferentes y se agrupan cerca de una frecuencia. Además, la distribución de los datos de estos contaminantes no es normal, como se desprende de la prueba de Shapiro-Wilk (). La media geométrica de los datos tiene un valor de desviación estándar , lo que indica que entre y documentos del total considerado, tienen en cuenta las variables climáticas. Curiosamente, aproximadamente el 24% de los artículos considerados en el análisis representan el 85,71% de las variables climáticas analizadas. Esto sugiere que una parte significativa de la investigación se centró en un número relativamente pequeño de variables climáticas, las medidas de temperatura y humedad se destacaron como las principales variables en aproximadamente el 80% de los artículos. Estas variables juegan un papel crucial en la evaluación de la calidad del aire y la predicción de las condiciones atmosféricas debido a su impacto directo en diversos procesos ambientales y la salud humana.

$$NO_x = \{1,2\} CO_x = \{1,2\} PM_{2.5} PM_{10} 1p < 0.058.010.9 - 2.9 \approx 018.9 \approx 1995\%$$

Las variables del suelo se miden con menos frecuencia, como se muestra en Figura 1 b); sin embargo, la humedad tiene un gran interés de investigación para determinar la calidad del suelo. Incluso, en los sistemas que incluyen sensores meteorológicos y de suelo, la calidad del aire superficial está influenciada por la humedad y la temperatura de la superficie (71,73–76,79). Los datos de distribución de las variables de suelo se encuentran normales, como lo indica la prueba de Shapiro-Wilk (), con un valor medio de 7.7 y un valor de desviación estándar de , lo que indica que entre y documentos del total considerado, representan el 95% de las variables de suelo analizadas. Este resultado contrasta con la prueba de correlación de Kendall (ver Apéndice), ya  $p > 0.055.62.1 \approx 213.3 \approx 130.70$  puestos orgánicos volátiles (COV) muestra una alta correlación () .

Por lo tanto, no son comunes las aplicaciones o dispositivos que registran conjuntamente diferentes variables del suelo. La temperatura y la humedad del suelo exhiben una correlación de (), lo que indica un bajo uso de sensores híbridos de temperatura-humedad del suelo por parte de los investigadores, en contraste con los sensores híbridos de temperatura-humedad del aire. Es importante destacar que la humedad del suelo, o el método por el cual se determina esta variable dentro del suelo, está directamente relacionada con la constante dieléctrica del agua y no está influenciada por la temperatura como en el caso de la humedad relativa ambiental. Al respecto, Topp et. al  $0.40 p < 0.05$  (82–84) indican que mediante el uso de curvas de calibración adecuadas, la medición de la constante dieléctrica puede estar directamente relacionada con la humedad del suelo.

En un caso específico, la CE se registra en un solo papel, principalmente debido al costo inasequible, el costo y la complejidad de diseñar sensores caseros. A pesar de esto, los dispositivos electrónicos comerciales que incluyen mediciones de pH, NKP y EC también son costosos. Por lo tanto, los esfuerzos actuales se centran en describir las condiciones del suelo mediante el procesamiento de registros de pH y NKP utilizando sensores de suelo de medición múltiple, como se muestra en la Tabla B.1, donde las medidas de NKP y pH del suelo en los artículos tienen una correlación de (), que es mayor que la correlación entre NKP y EC del suelo  $(0.56 p < 0.050.33)$ .

La CE sirve como un indicador indirecto que permite estimar la concentración de sales disueltas en el suelo, el valor de esta variable está significativamente influenciado por la humedad del suelo, donde los bajos contenidos de humedad indican valores de CE más altos debido a que la cantidad de sales permanece constante, pero con un menor contenido de agua en la solución, las sales a menudo resultan de la fertilización química, estando típicamente compuesto por macronutrientes como nitrógeno, fósforo y potasio. Además, los fertilizantes químicos pueden influir en el aumento o disminución de los valores de pH en los suelos, dependiendo de la naturaleza de los fertilizantes aplicados.

#### Protocolos de programación y comunicación en aplicaciones meteorológicas/de suelo

La adquisición de registros temporales o espaciales de las variables climáticas o del suelo depende de diferentes fuentes, ya sean diseños comerciales o caseros. Además, estos registros se basan en el software de programación integrado utilizado para almacenar y procesar datos meteorológicos y de suelo. Debido a la disponibilidad de estaciones meteorológicas privadas y públicas, como el proyecto del Índice Mundial de Calidad del Aire (85), obtener registros sin agregar dispositivos electrónicos se ha vuelto sencillo. Como resultado, los datos a menudo se procesan utilizando software especializado como Python, Java, QGI, JSON, NCEP CFSv2 o MYQL (Figura 2 a)). El software especializado ofrece la ventaja de reducir el tiempo de programación y procesamiento al tiempo que mejora la precisión de los datos. Del mismo modo, los sistemas integrados proporcionan precisión de datos a un costo menor, pero vienen con un tiempo de programación y procesamiento más largo. Por lo tanto, los investigadores deben elegir entre la rentabilidad y el tiempo de procesamiento para lograr resultados exitosos.

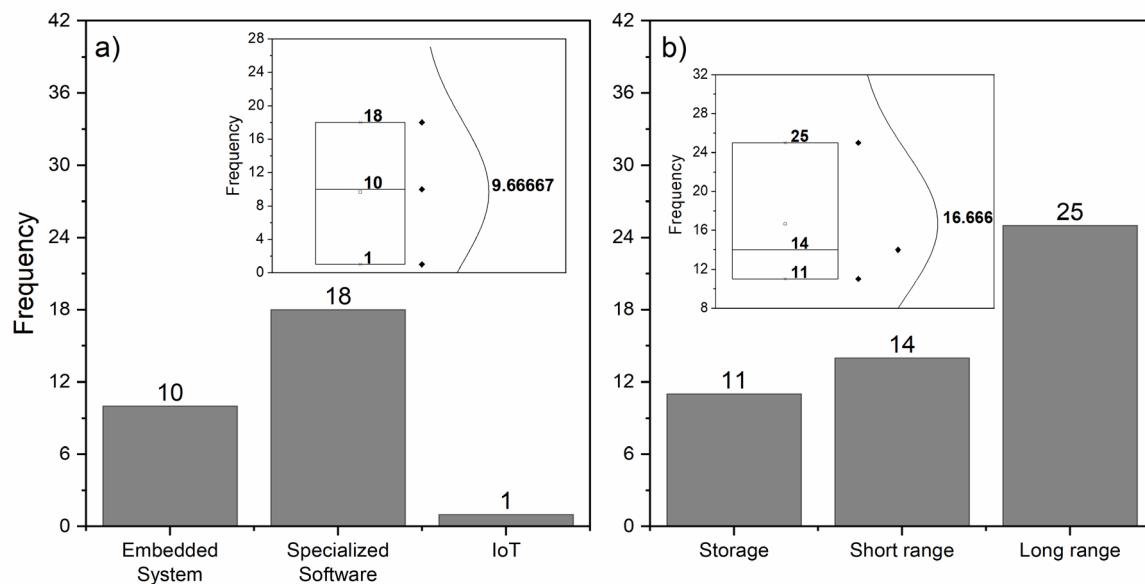


Figura 2. Histograma, diagrama de caja y curva normal de a) programación y b) comunicación.

La investigación centrada en el desarrollo de estaciones meteorológicas a menudo involucra sensores y microcontroladores integrados para obtener registros meteorológicos sin procesar y procesados en general (58,86,87). Estos diseños varían desde estaciones meteorológicas tradicionales hasta aplicaciones de vehículos aéreos no tripulados (UAV), como la incorporación de drones meteorológicos (88). La integración de tecnología de bajo costo es una característica común en estas aplicaciones. Por ejemplo, se incluyen sistemas de suministro como células fotovoltaicas o baterías de iones de litio para mejorar el rendimiento de los dispositivos utilizados en el monitoreo de cultivos, la agricultura inteligente, la detección de contaminación y el análisis de nutrientes (5,36,42,45). Por el contrario, en las investigaciones en las que el objetivo principal es el procesamiento de la información para pronosticar las condiciones meteorológicas, se emplea predominantemente un software especializado (89,90). Las aplicaciones de IoT para la programación son menos frecuentes, ya que el procesamiento de datos generalmente se realiza con software integrado en el hardware disponible. Los tipos de programación exhiben una distribución normal (prueba de Shapiro-Wilk con ), con un valor medio que indica que aproximadamente de los trabajos utilizan sistemas integrados, software especializado e IoT para el registro y procesamiento de datos. Una prueba de correlación de Kendall realizada en tipos de programación (ver Apéndice) no revela ninguna correlación significativa entre ellos, por lo tanto, solo se aplica un método para registrar y procesar datos. $p > 0.059.7 \pm 8.520\%$

Los datos meteorológicos y del suelo generalmente se presentan en tablas, gráficos o figuras a través de interfaces gráficas de usuario (GUI), lo que permite la evaluación y el análisis del comportamiento dinámico de las variables. Esta información debe ser accesible y procesable por software; por lo tanto, el almacenamiento y el reenvío de bases de datos y señales de tiempo espacial son esenciales. Los microcontroladores como los dispositivos Arduino o Microchip tienen una memoria interna limitada que se puede usar para almacenar registros meteorológicos, de suelo y de contaminantes directamente. Sin embargo, a medida que la memoria se llena, la potencia de procesamiento disminuye. Aunque se puede encontrar una mayor capacidad de memoria en algunos microcontroladores, incorporar dispositivos externos es una mejor opción debido a su

mayor capacidad de memoria, fácil desacoplamiento y robustez. Por ejemplo, Chacón y García (36), utilizó tarjetas SD para almacenar temperatura, humedad, presión atmosférica, brillo, UV, precipitación y velocidad del viento para evitar la pérdida de información. Del mismo modo, otros autores (36,72) han utilizado dispositivos y bases de datos EEPROM (Mesa 2) para garantizar la disponibilidad de señales meteorológicas y de tiempo espacial del suelo, que pueden ser adecuadas para evaluar la calidad histórica del aire y del suelo o pueden emplearse en AQF y Soil Quality Forecast (SQF).

Al igual que el método de programación, no existen correlaciones significativas (véase el Apéndice) entre los diferentes tipos de comunicación de rango (Figura 2 b)). Los métodos de comunicación exhiben una distribución normal (prueba de Shapiro-Wilk) con un valor medio de . Por lo tanto, de los documentos de  $ip > 0.0516.7 \pm 7.433.33\%$  comunicaciones de ira corta y larga junto con dispositivos de almacenamiento.

Tabla 2. Protocolos de comunicación

Almacenamiento	Corto alcance	Largo alcance
Micro SD	Radiofrecuencia	GSM/GPRS
EEPROM	Zigbee	WiFi
Base de datos	Xbee	Sitio web
	Bluetooth	

Si bien el almacenamiento de datos en diferentes dispositivos electrónicos preserva la información, la comunicación eficiente y segura entre el software integrado en microcontroladores, GUI y sitios web es crucial. Se han implementado protocolos de comunicación inalámbrica para facilitar la transferencia de datos desde dispositivos de almacenamiento a dispositivos de procesamiento de datos cercanos o distantes. Actualmente, los protocolos de comunicación inalámbrica encuentran una amplia aplicación en biotecnología, agricultura, ecología y operaciones militares debido a su fácil configuración y alcance de comunicación relativamente ilimitado. Las aplicaciones remotas con GUI muestran datos en tiempo real de las estaciones de monitoreo del clima / suelo como una serie de tiempo gráfica, lo que permite a los usuarios observar el comportamiento de los registros meteorológicos / del suelo. Los sistemas inalámbricos rápidos se integran comúnmente para habilitar esta funcionalidad.

Tabla 3. Características de los protocolos de comunicación (91,92)

	Protocolos de comunicación		
	Zigbee/Xbee	Bluetooth	WiFi
Ancho de banda de operación	2,4 GHz	2,402 – 2,480 GHz	2,4 – 5 GHz
Gama	70- 400 metros	1 - 100 metros	1 – 90 metros Nodos
Topología de red	Red de malla	Piconets adhoc	(dispositivos) ilimitados
Número de dispositivos por red	2 - 65000	2 - 8	Ilimitado
Velocidad máxima de transmisión	250 Kbps	1 Mbps	9,6 Gbps

Los sistemas Zigbee se han utilizado para enviar datos para generar alertas locales a corto plazo utilizando modelos matemáticos basados en parámetros meteorológicos registrados desde dispositivos de monitoreo cercanos, aprovechando su frecuencia de aproximadamente (250 kbps Tabla 3). Zigbee permite una rápida transmisión de datos facilitando la gestión en tiempo real de la calidad del aire y el suelo, mejorando la configuración de parámetros en la agricultura de precisión, la evaluación de contaminantes, los métodos de pronóstico o el análisis de las condiciones climáticas (33,38,40,50).

Xbee es otro protocolo de comunicación con características similares a Zigbee; sin embargo, su arquitectura y marca registrada son diferentes. Las aplicaciones de Xbee se centran principalmente en el monitoreo del clima / suelo utilizando estaciones inalámbricas rentables en granjas con distancias de comunicación de hasta metros. Por ejemplo, Devaraju et.al. 400 (58) diseñó una estación meteorológica con protocolo de comunicación Modbus utilizando módulos Xbee. Los datos se transmiten a una aplicación de software en PC/portátil; y cargaron datos en un servidor en línea. Por otro lado, se ha mejorado la gestión de invernaderos y cultivos mediante la transmisión de datos entre sensores y sistemas de control. Los módulos Xbee se emplean para transmitir mediciones de temperatura, humedad y nutrientes, lo que permite la evaluación de las condiciones óptimas de riego en tiempo real para plantaciones como los cultivos de café (39,71).

Las estaciones meteorológicas / de suelo portátiles y de bajo costo se instalan con frecuencia en áreas rurales, generalmente cubriendo un área de hasta metros; por lo tanto, los dispositivos Bluetooth se utilizan para establecer conexiones inalámbricas entre las estaciones de monitoreo y los teléfonos inteligentes o PC / computadoras portátiles. Esta configuración mejora la gestión del agua, particularmente en las prácticas de riego, y permite predecir el rendimiento en aplicaciones de agricultura inteligente y de precisión 100 (26,43).

Las aplicaciones mencionadas son abordadas por otros investigadores que utilizan protocolos de comunicación de larga duración. Actualmente, la transmisión de datos a través de WiFi y el almacenamiento de los datos en la nube o en páginas web han surgido como opciones asequibles y económicas para transmitir y procesar información meteorológica y del suelo. Instalación de dispositivos desarrollados en el marco de la 4<sup>é</sup>simo revolución industrial como IoT, Big Data e IA; permite el rápido intercambio de información entre dispositivos geográficamente distantes. De esta manera, los datos meteorológicos/del suelo enviados pueden ser procesados por un software de laboratorio especializado, lo que permite optimizar la agricultura y la gestión atmosférica (57,68,74).

### Métodos de pronóstico en la calidad del aire/suelo y aplicaciones de contaminantes

El objetivo principal de diferentes trabajos de investigación es describir las condiciones climáticas o del suelo utilizando mediciones o bases de datos. Además, la mayoría de los autores han centrado sus trabajos en predecir el comportamiento de estas condiciones. El uso de los diferentes métodos de pronóstico no sigue una distribución normal (Shapiro-Wilk) porque existen numerosas técnicas de predicción sin un enfoque dominante claro. Por lo tanto, la frecuencia de uso de cada método de pronóstico es generalmente baja. En promedio, de la investigación aplicada de los métodos de pronóstico ( $p < 0.055.15\%92.31\%$ Figura 3), lo que significa que los trabajos podrían usar uno o más modelos de predicción juntos. El rendimiento de los algoritmos de IA podría mejorarse integrando modelos estadísticos y matemáticos para lograr una mayor precisión en el pronóstico.

De Figura 3, los modelos de pronóstico se agrupan en tres conjuntos principales: modelos matemáticos, estadísticos y de IA. Los modelos matemáticos o basados en el conocimiento se aplican comúnmente debido a su alto potencial de análisis basado en axiomas y conceptos físicos y químicos. Por ejemplo, Ramadán et.al (79) utilizó el Análisis en Dominio de Frecuencia (FDA) para mejorar la medición de las constantes dieléctricas del suelo en estaciones de suelo de valor agregado. Zeng et.al (3) concentraciones estimadas entre puntos de monitoreo separados espacialmente, utilizando interpolación espacial (SI) combinada con algoritmos de aprendizaje automático. Espinosa et.al PM<sub>2.5</sub>(52) concentraciones predichas en el sureste de España mediante la identificación y optimización de modelos de regresión lineal múltiple a través de un método de Optimización Multiobjetivo (MOO), utilizando un algoritmo de aprendizaje para predecir el nivel de contaminación y minimizar el error de cada regresión lineal. En estos trabajos se obtuvieron resultados exitosos de precisión, pero en general, el tiempo de procesamiento es notable y no consideran algunas variables o factores de ruido, lo que podría disminuir la precisión del pronóstico. Por lo tanto, solo de los trabajos emplearon modelos matemáticos (NO<sub>2</sub> 6%Figura 3).

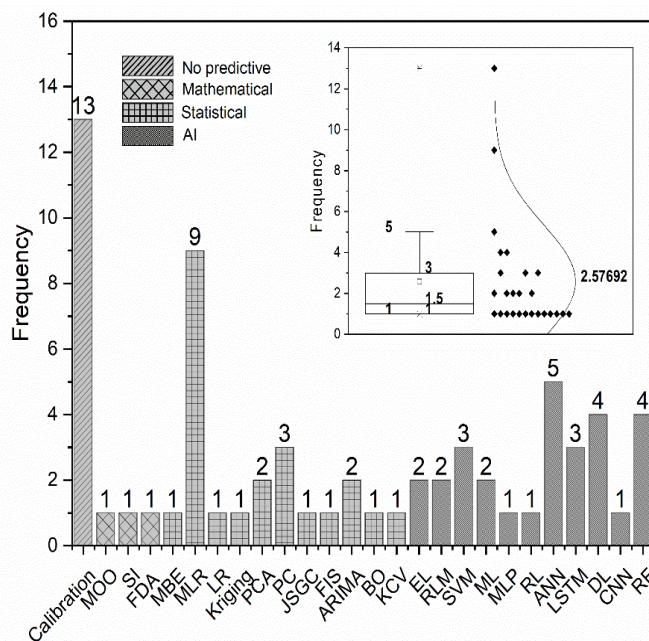


Figura 3. Histograma, diagrama de caja y curva normal de los métodos de pronóstico

Los modelos estadísticos se utilizan más ampliamente, teniendo en cuenta la investigación, debido al menor tiempo de procesamiento manteniendo una precisión razonable, pero se pierden los axiomas físicos/químicos. Es notable que un enfoque común en diferentes trabajos es el uso de una o más regresiones lineales, denominadas Regresión Multilineal (MLR). Por ejemplo, Jeong et.al 46% (70) empleó MLR para correlacionar las concentraciones con las variables climáticas en invierno logrando un pronóstico estacional hábil. Además, los investigadores han utilizado varias técnicas de correlación como la correlación Jammalamadaka-SenGupta (JSGC) y la correlación de Pearson (PC), así como técnicas de estimación espacial como Kriging, Fuzzy Interference System (FIS), análisis de series temporales como Autoregressive Integrate Moving Average (ARIMA) y sistemas optimizados como Bayesian Optimization (BO). De particular interés, muchos investigadores han evaluado y

validado aplicaciones de IA mediante el uso de K-fold Cross-Validation (KCV). El método garantiza que los resultados sean independientes de los datos de entrenamiento y sondeo  $PM_{10}$  (59,60).

En cuanto a los modelos de IA, diferentes documentos y artículos enumeran explícitamente el algoritmo de IA utilizado, como el perceptrón multicapa (MLP), la memoria a corto plazo (LSTM), el aprendizaje por conjuntos (EL) y las máquinas de vectores de soporte (SVM). Sin embargo, otros trabajos solo mencionan tipos de aprendizaje automático (ML) que agrupan algoritmos similares. De hecho, el término "ML" rara vez se usa por sí solo. Por ejemplo, Bernardes et.al (59) y Yamamoto et.al (60) probaron diferentes métodos de regresión, incluidos modelos de ML para calibrar sensores meteorológicos de bajo costo como un grupo de métodos no específicos aplicados. En el mismo contexto, los paradigmas de ML a veces se mencionan como un solo tipo de algoritmo de IA; Pero los paradigmas agrupan diferentes algoritmos con características similares. Los algoritmos de aprendizaje supervisado buscan la mejor función aproximada que se ajuste a un conjunto de datos específico de valores de entrada y salida. Los algoritmos de aprendizaje no supervisado, por otro lado, usan solo datos de entrada para determinar patrones o tendencias sin conocimiento de los datos de salida. Estos patrones se evalúan en grupos para identificar las mejores aproximaciones. Los algoritmos de aprendizaje por refuerzo (RL) se utilizan cuando se desconocen los valores de entrada y salida; en cambio, se considera un conjunto de reglas para evaluar un grupo de eventos aleatorios para que el algoritmo aprenda sobre múltiples formas de lograr un objetivo.

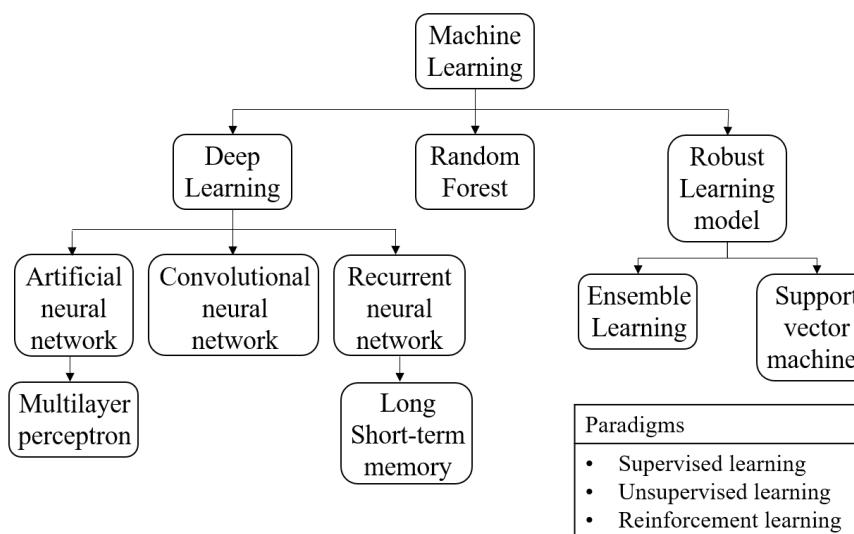


Figura 4. Tipos de algoritmos de aprendizaje automático y sus paradigmas

Los trabajos de investigación sin aplicaciones de pronóstico se etiquetan como "Calibración". Principalmente, la validación del diseño de una estación de monitoreo está determinada por el registro de mediciones confiables en diferentes dispositivos sensores (de las obras). La fiabilidad se consigue mediante procesos de calibración y ajuste. Sin embargo, hay algunos trabajos en los que se aplican métodos de IA para evaluar el nivel de calibración en estaciones meteorológicas/ de suelo, pero no se consideran métodos de pronóstico porque el objetivo es la calibración. Por lo tanto, en este trabajo, el término "método de calibración" se utiliza únicamente para referirse a trabajos de investigación sin aplicación de pronóstico.26%

En Figura 4, se muestra el orden jerárquico de los algoritmos de ML considerados. El aprendizaje profundo (DL) agrupa algoritmos multicapa basados en funciones cerebrales humanas, comúnmente llamadas redes neuronales; a menudo se usa para identificar patrones y sus algoritmos están diseñados bajo los paradigmas de aprendizaje no supervisado y de refuerzo. El método Random Forest (RF) combina la salida de múltiples árboles de decisión entrenados para generar un único resultado. Los modelos de aprendizaje robustos (RLM) son un conjunto de métodos de IA utilizados conjuntamente para obtener un mejor rendimiento predictivo. Específicamente, EL agrupa algoritmos de aprendizaje y SVM clasifica datos no etiquetados utilizando un conjunto de ejemplos de entrenamiento dados, basados en un conjunto de marcos de aprendizaje estadístico.

#### Principales configuraciones tecnológicas y tendencias de las estaciones meteorológicas/de suelo

Para identificar las principales configuraciones de estaciones meteorológicas/de suelo utilizadas por los investigadores, se realizó un PCA sobre los tipos de sensores meteorológicos/de suelo (Figura 5). Las variables se agruparon en cinco estaciones principales de agua/suelo. La estación meteorológica/del suelo 1 tiene el mayor valor propio (), por lo tanto, se espera que en este componente se proyecten o agrupen variables comunes como temperatura, humedad, precipitación, presión atmosférica, velocidad y dirección del viento. Sin embargo, el pH del suelo y el NPK se incluyen porque hay aplicaciones en las que se prueba el nivel de acidez del suelo y se correlaciona con los datos de las variables climáticas, como en la gestión del riego de cultivos o la agricultura inteligente 4.23(33,40,42,72). Este resultado está respaldado por la correlación entre las variables de la Tabla A.1 y la Tabla B.1.

Por otro lado, la estación meteorológica/de suelo 2 incluye la medición de las concentraciones. Estos gases están asociados con la contaminación y la creciente prevalencia de enfermedades pulmonares; por lo tanto, sus aplicaciones se centran principalmente en evaluar el AQF. Sin embargo, este resultado es un caso atípico porque, por lo general, no hay muchas investigaciones que midan estas variables de manera conjunta; en cambio, se registran como complementarias y necesarias (valor propio) junto con otras condiciones climáticas para predecir los niveles de contaminación y calibrar las estaciones de monitoreo de bajo costo  $COCO_2PM_{2.5} - PM_{10}1.65$  (23,62,64).

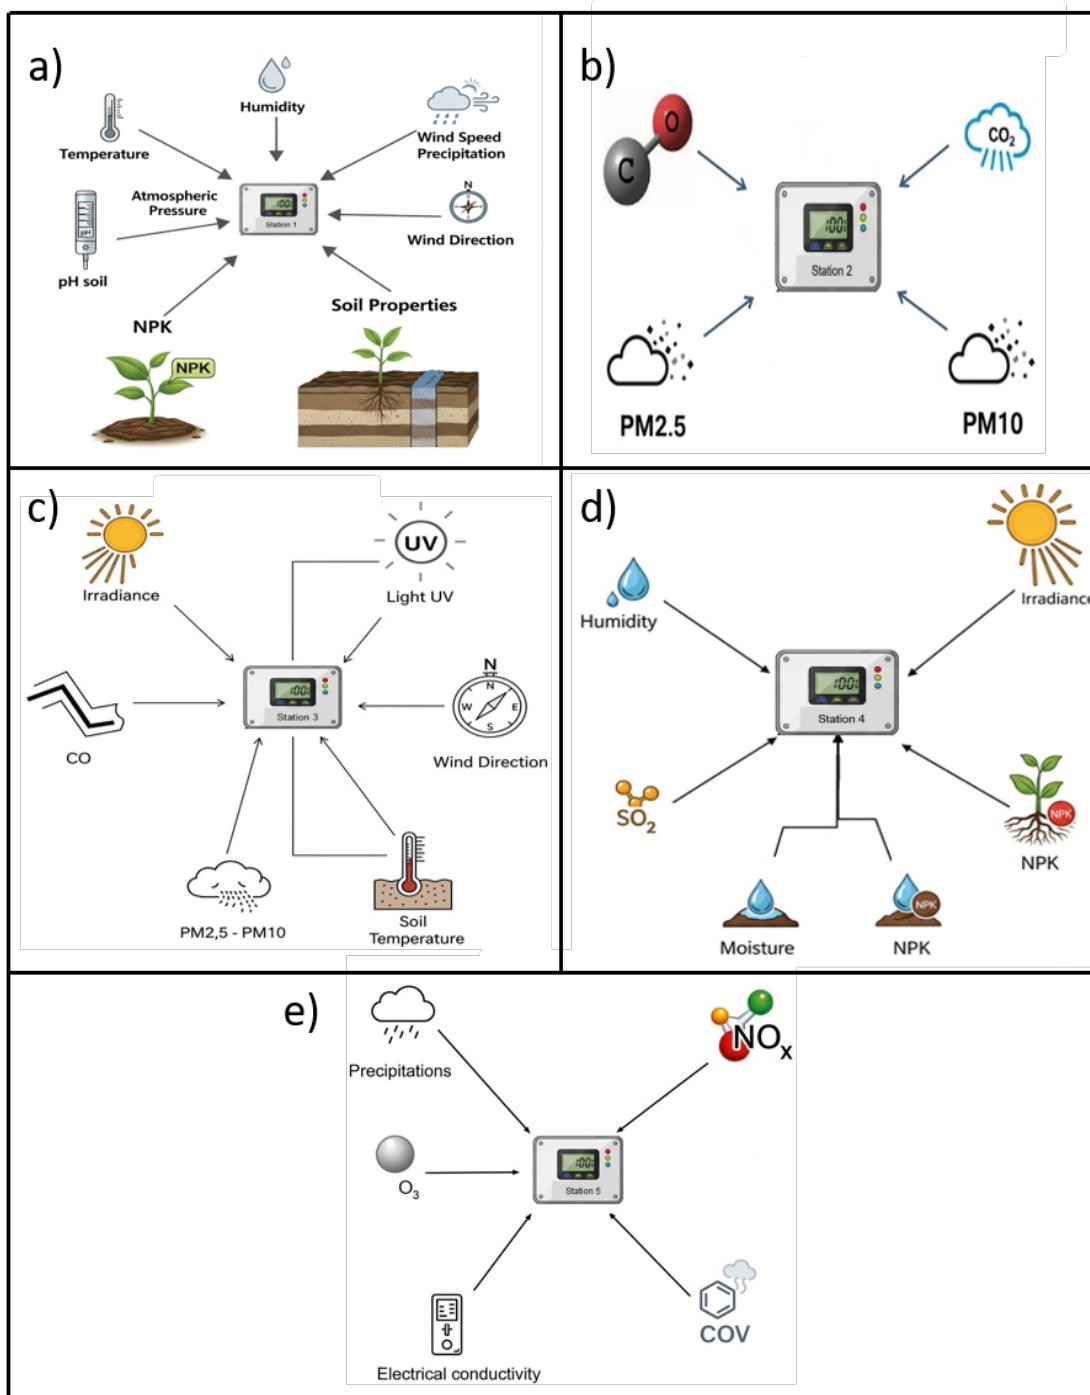


Figura 5. Configuraciones tecnológicas para estaciones meteorológicas/de suelo a) 1, b) 2, c) 3, d) 4 y e) 5.

Del mismo modo, la estación meteorológica / de suelo 3 mide y concentra, al mismo tiempo que agrega registros de irradiancia, luz ultravioleta, dirección del viento y registros de temperatura del suelo. Las características de la radiación solar en la superficie de la Tierra dependen de diferentes factores ambientales y tanto la energía incidente como el amplio espectro de radiación se atenúan mediante procesos de absorción y dispersión en la atmósfera. Además, los cambios en la radiación solar tienen correlaciones con concentraciones contaminantes, como, la disminución de la transmitancia espectral en presencia de neblina y partículas en el aire, debido a colisiones de fotones, con contaminantes, moléculas ionizadas e iones  $COPM_{2.5} - PM_{10}$   $PM_{2.5} - PM_{10}$

(93). Interacciones como la absorción, la dispersión de Compton y el efecto fotoeléctrico disminuyen la energía de los fotones y aumentan la energía interna de los gases atmosféricos, lo que potencialmente puede afectar la temperatura del suelo. Además, la dirección del viento contribuye a la transferencia de energía por convección, actuando como un factor externo en el comportamiento termodinámico del aire contaminado (45,63). Las interacciones fenomenológicas observadas y los resultados de PCA para la estación meteorológica/de suelo 3 sugieren un interesante enfoque de investigación en la evaluación de la correlación entre la radiación solar y los contaminantes.

Con respecto a Figura 5, la estación meteorológica / de suelo 4 podría ser valiosa en aplicaciones agrícolas. Tanto la humedad como el contenido de humedad afectan significativamente el brote y el crecimiento del cultivo. Los niveles de humedad bajos o altos pueden disminuir la tasa de crecimiento o aumentar el riesgo de enfermedades, respectivamente (40). Además, el control de las concentraciones de nutrientes del suelo, como nitrógeno, fósforo y potasio, es esencial para controlar y mejorar la producción y la calidad de los cultivos en invernaderos o granjas. Sin embargo, estas mediciones no son suficientes (21,72). Los contaminantes en el aire y el suelo, como las partículas de metales pesados, pueden afectar negativamente a los cultivos; en este caso, se considera el monitoreo, ya que los insecticidas utilizados en los procesos de fumigación pueden contener trazas de este gas que pueden afectar negativamente el rendimiento del cultivo, como se observa en viñedos con aplicación excesiva  $PM, SO_2, SO_3$  (46). La correlación irradiancia-contaminantes se mencionó anteriormente; además, la irradiancia tiene una correlación directa con la humedad (véase el Apéndice); por lo tanto, se espera el registro de la irradiancia 0.36(52,63). Por lo tanto, la estación meteorológica/de suelo 4 tiene el potencial de registrar, predecir y controlar las variables que afectan la calidad del suelo y la salud de los cultivos.

La estación meteorológica/de suelo 5 se destaca como un resultado digno de mención, ya que considera la medición de los elementos precursores del ozono troposférico (u ozono troposférico), es decir, los gases, y los COV producidos por la combustión o el uso de plaguicidas. Los gases reaccionan con los COV en presencia de la luz solar para crear ozono troposférico (), que puede provocar enfermedades respiratorias o afectar la fotosíntesis, la tasa de crecimiento, la expresión génica y la función de la membrana celular en las plantas  $NO_x, NO_xO_3$  (94,95). Por lo tanto, registrar y controlar estas variables en las aplicaciones de SQF puede ser crucial para mejorar el rendimiento de los cultivos en granjas o invernaderos. Las precipitaciones y la CE son indicadores adicionales debido a su correlación con el pH y el NKP (33,47).

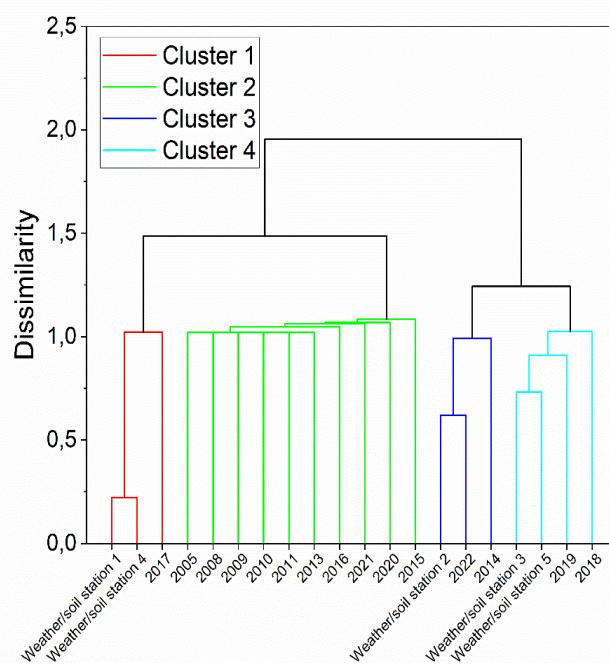


Figura 6. (Dendrograma) Agrupación de estaciones meteorológicas/de suelo y año de publicación

Se calculó la agrupación de distritos de tipo jerárquico para agrupar las estaciones meteorológicas/de suelo y los años en cuatro grupos en función de sus usos predominantes en diferentes obras. La agrupación por distritos cuantifica un coeficiente de disimilitud, de modo que los valores más bajos de disimilitud significan que dos o más elementos están significativamente cerca o tienen características comunes. Figura 6 muestra que las estaciones meteorológicas/de suelo 1 y 4 generalmente se usan juntas (grupo 1: línea roja). Este resultado es esperado porque existe una correlación directa entre la temperatura-humedad y el pH-NKP del suelo (ver Apéndice) medido en la investigación AQF y SQF. Además, en 2017, hubo 11 documentos centrados principalmente en aplicaciones de manejo de suelos; por lo tanto, los trabajos con registro de variables comunes de clima/suelo están representados por la publicación del año 2017 y las estaciones de clima/suelo 1 y 4 en el mismo grupo. Sin embargo, 2017 no es el único año editorial significativo para este tipo de trabajo, ya que desde 2005 se han registrado señales en bruto. Cabe destacar que el clúster 2 (línea verde) no incluye ninguna estación meteorológica/de suelo e incluye 10 años de publicación, de 2005 a 2021. Sin embargo, el clúster 2 está cerca del clúster 1 (Figura 6), lo que sugiere que las señales registradas con las estaciones meteorológicas/de suelo 1 y 4 se realizaron entre 2005 y 2021, incluso durante el período de pandemia de COVID-19 en 2020. Además, los dispositivos del clúster 1 tienden a utilizarse en trabajos futuros, a pesar de la correlación entre las estaciones meteorológicas/de suelo 1 y 4, y el año de publicación 2022 muestra una tendencia significativamente inversa (véase el Apéndice).

El clúster 3 se muestra en Figura 6 (línea azul) incluye mediciones de contaminantes obtenidas a través de la estación meteorológica/de suelo 2, que abarcan los años de publicación 2014 y 2022. Este resultado se alinea con las expectativas porque la estación meteorológica/de suelo 2 exhibe una correlación significativamente directa con el año 2022 y una correlación no significativa con el año 2014 (ver Apéndice). Los trabajos en 2022 tienden a predecir el comportamiento de los

contaminantes utilizando aplicaciones estadísticas y de IA. Por ejemplo, Gladkova y Saychenko (65,96) utilizar modelos estadísticos de IA de memoria a corto plazo (LSTM) y promedio móvil integrado autorregresivo (ARIMA) para pronosticar las concentraciones en 7 ciudades de Rusia, aprovechando la capacidad de interrelacionar eventos con un retraso de tiempo indefinido. Del mismo modo, otras investigaciones incorporan IA, modelos estadísticos y matemáticos para predecir la dinámica y las concentraciones de contaminantes en los últimos años  $PM_{2.5}$  –  $PM_{10}$  (52,70). Como resultado, este tipo de trabajos han atraído la atención de la investigación debido a sus potenciales aplicaciones en la gestión de políticas públicas enfocadas en salvaguardar el medio ambiente, la calidad de los alimentos y la salud pública.

En contraste, el clúster 4 agrupa (línea cian) de estaciones de monitoreo utilizadas en aplicaciones de suelo o agricultura durante los años 2018 y 2019. Esta observación se alinea con el hecho de que hay menos trabajos que utilizan datos del suelo para monitorear, controlar o predecir las condiciones del suelo en comparación con el número de documentos de investigación de AQF. Es notable que el grupo 4 está muy cerca del grupo 3, lo que indica un interés de investigación en registrar y evaluar datos de suelo para aplicaciones agrícolas e invernaderos en la actualidad. Además, los datos del suelo podrían complementarse con mediciones de contaminantes en futuros trabajos de SQF.

En términos de continente editorial, los resultados de la agrupación jerárquica (Figura 7) muestran que los investigadores de Asia centran sus trabajos en el diseño tecnológico de estaciones meteorológicas/de suelo para registrar o controlar aplicaciones de sistemas (grupo 1: línea roja). Por otro lado, los trabajos en América del Sur tienden a centrarse en la evaluación de AQF a través de contaminantes y sus variables correlacionadas, como la irradiancia y la dirección del viento. Del mismo modo, Europa se orientó hacia la investigación de SQF, pero también está estrechamente asociada con el grupo 2 (línea verde), lo que indica una probabilidad de encontrar investigación de AQF también en esta región.

Por otro lado, no hay un grupo asociado con ninguna estación meteorológica / de suelo específica y los continentes de América del Norte y África (grupo 4: línea cian), a pesar de que hay trabajos con aplicaciones de datos de aire / suelo. La proximidad del grupo 4 al grupo 3 (línea azul) sugiere una brecha potencial en la investigación de AQF y SQF en estos continentes. En este contexto, existe un potencial de investigación centrada en el registro y procesamiento de datos de aire/ suelo y contaminantes en lugares específicos dentro de América del Norte y África, incluso con la aplicación de modelos de pronóstico para examinar la correlación con las estaciones de monitoreo (ver Apéndice). Por el contrario, los investigadores asiáticos pueden utilizar la información sólida obtenida de las estaciones meteorológicas 1 y 4 para aplicar nuevos métodos de predicción.

Finalmente, los trabajos en América del Sur y Europa se actualizan con temas de AQF y SQF, pero se espera que haya un número creciente de esfuerzos de investigación en estas áreas. La identificación de estas tendencias y brechas de investigación puede servir como una guía valiosa para estudios futuros y contribuir a una comprensión más completa de la dinámica del clima, el suelo y la calidad del aire en todo el mundo.

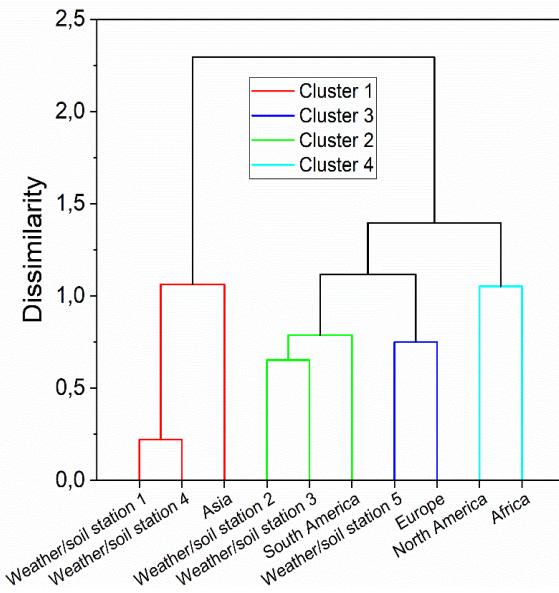


Figura 7. (Dendrograma) Agrupación de estaciones meteorológicas/de suelo y continente de publicación

#### Principales configuraciones y tendencias de los modelos de pronóstico híbridos

A lo largo del siglo XXI, los investigadores han evaluado diferentes métodos para predecir el comportamiento de las condiciones del aire / suelo y la dinámica de los contaminantes. Estos métodos incluyen modelos matemáticos, estadísticos y de IA. Sin embargo, cada vez es más común adoptar un enfoque híbrido que combina dos o más métodos para organizar, filtrar y procesar datos, mejorando el proceso de rendimiento general o la precisión de la predicción. Generalmente, los modelos matemáticos y estadísticos se emplean a menudo como herramientas de preprocessamiento, lo que facilita la eliminación de datos irrelevantes y agrupa datos significativos.

Para identificar las combinaciones predominantes de estos modelos de pronóstico híbridos, utilizados simultáneamente en diferentes trabajos de pronóstico o registro, se realizó un PCA en una amplia gama de modelos, incluidos aquellos trabajos con solo procesos de calibración informados (Figura 8), este análisis dio como resultado la identificación de componentes principales, denominados colectivamente modelos de pronóstico híbridos (HFM). Así, los HFM son modelos que aplican dos o más técnicas matemáticas, estadísticas y de pronóstico para mejorar el rendimiento del procesamiento de datos.

HFM1 (con el valor propio más alto) incluye principalmente modelos de pronóstico de ML, específicamente algoritmos de RL como LSTM. El LSTM y otros modelos de RL se complementan con la aplicación del método estadístico KCV, que a menudo se usa para evaluar la habilidad de un modelo de ML evaluando su rendimiento en datos no utilizados durante el entrenamiento. Además, LSTM es especialmente eficaz cuando se requieren pronósticos precisos entre dos eventos que están separados desde hace mucho tiempo, como daños a la salud o riesgos asociados con una mayor concentración. El algoritmo LSTM puede predecir la tendencia de este tipo de contaminantes para prevenir riesgos para la salud *PM<sub>2.5</sub>*(63,65). Por lo tanto, HFM1 se utiliza predominantemente

en aplicaciones AQF a largo plazo con una precisión exitosa. De igual forma, HFM11 comparte características comparables, ya que también utiliza algoritmos LSTM pero incluye la estimación de indicadores basados en series temporales (ARIMA), esta información adicional mejora la predicción de los niveles de contaminantes (65).

Los valores espaciales estimados por diferentes métodos han mostrado resultados significativos en la investigación. Específicamente, HFM2 (Figura 8) agrupa un método de inferencia espacial basado en la interpolación geoestadística mediante regresión gaussiana (kriging) y el método CNN, que generalmente es la primera capa de la red neuronal utilizada para extraer características espaciales. Estos métodos encuentran aplicaciones en la agricultura (45) o evaluación AQF (63). Además, MBE se incluye como una medida de la habilidad del modelo. Además, el "método de calibración" o los trabajos sin método de pronóstico se incluyen como temas potenciales a evaluar mediante métodos espaciales de pronóstico. Por lo tanto, HFM2 se utiliza principalmente para predecir las condiciones del aire / suelo por separado entre diferentes puntos espaciales.

HFM3 incluye métodos estadísticos caracterizados por ignorar la función objetivo que conecta eventos o conceptos abstractos. FIS es un método que utiliza lógica difusa para mapear datos de entrada a salida, como lo demuestran Pruthi y Liu (53), que combinan FIS con una red neuronal para lograr predicciones de alta resolución de concentraciones para los próximos tres días basadas en datos de series temporales. Del mismo modo, BO sirve como soporte matemático para validar la idoneidad del análisis predictivo realizado con métodos DL en estaciones meteorológicas *PM<sub>2.5</sub>* (5). Si bien los trabajos revisados no combinaron explícitamente los métodos matemáticos del SI y la FDA con FIS y BO, existe potencial para su aplicación conjunta en la estimación de valores espaciales.

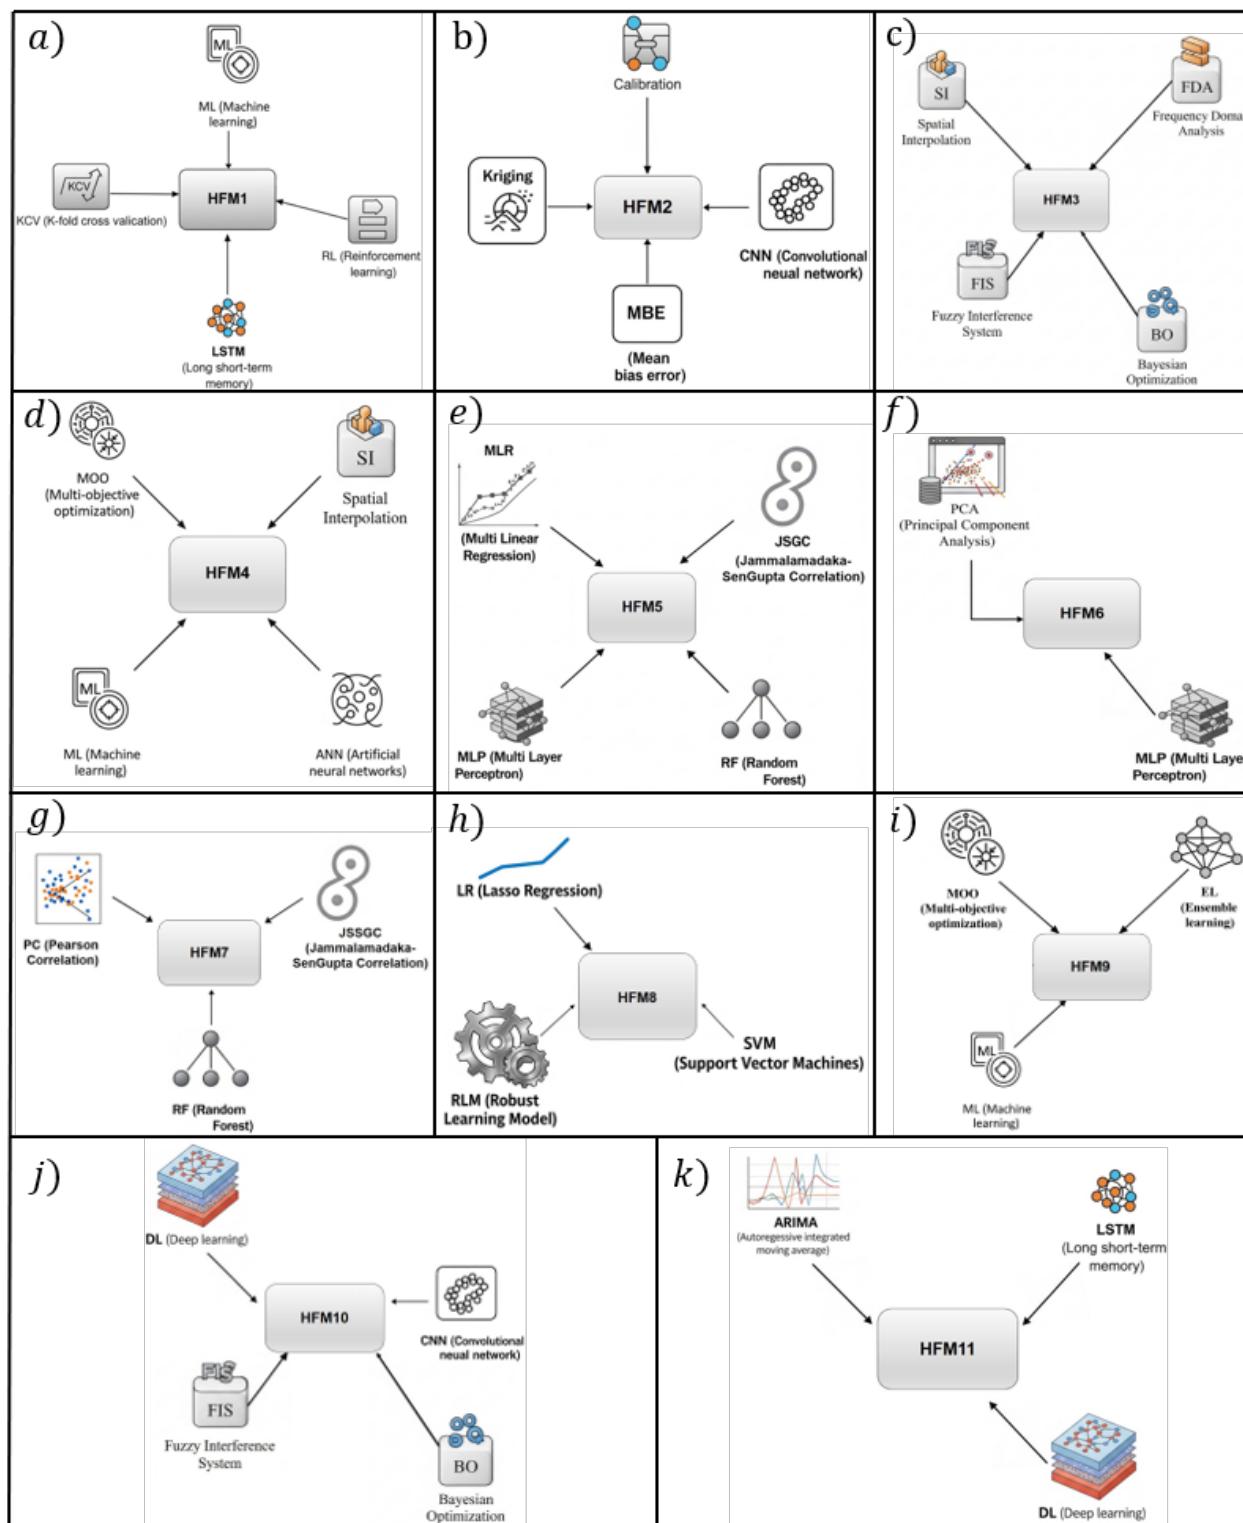


Figura 8. Configuraciones para modelos de pronóstico híbridos a) HFM1, b) HFM2, c) HFM3, d) HFM4, e) HFM5, f) HFM6, g) HFM7, h) HFM8, i) HFM9, j) HFM10, k) HFM11

Por otro lado, HFM10 emplea una combinación de FIS y BO con el método CNN, generando una mejor precisión de predicción para los valores espaciales. El método CNN se emplea con frecuencia en aplicaciones espaciales para facilitar la convolución de información multicapa, contribuyendo a mejores pronósticos. A pesar de que HFM11 tiene un valor propio más bajo () en comparación con

HFM3 (), se espera que HFM11 se aplique con mayor frecuencia en aplicaciones AQF y SQF debido a la mayor capacidad de procesamiento computacional del método CNN 1.082.46 (5,53).

*NO<sub>2</sub>* El gas es un contaminante tóxico y un precursor de nitratos. Su presencia en la atmósfera se correlaciona con efectos nocivos en los pulmones y las vías respiratorias. Así, diferentes investigaciones se han centrado en predecir concentraciones para evitar niveles de contaminación que supongan un riesgo tanto para la salud humana como para el medio ambiente *PM<sub>2.5</sub> NO<sub>2</sub> PM<sub>2.5</sub>* (3,50,52). En estos estudios, el uso de HFM4 y HFM9 tiene un propósito similar. Por ejemplo, Zeng et.al (3) y Agarwal et.al (50) aplicó un modelo basado en RNA entrenado con condiciones climáticas, y registros para generar AQF en tiempo real. Por otro lado, Espinosa et.al *PM<sub>2.5</sub> PM<sub>10</sub> O<sub>3</sub> NO<sub>2</sub>*(52) utilizó los métodos MOO y EL para predecir las concentraciones durante una semana en diferentes puntos de monitorización. La metodología describe la optimización minimizando el error cuadrático medio de múltiples modelos de regresión lineal obtenidos del método de entrenamiento (EL) incorporando datos meteorológicos y geográficos. Además, se utilizó ANN para calibrar AQmesh (sensores de calidad del aire) y sensores de temperatura de bajo costo filtrando los efectos negativos de múltiples factores ambientales en las mediciones, mejorando así la precisión de la estimación y los valores de temperatura *NO<sub>x</sub>* (49,60). En este contexto, tanto HFM4 como HFM9 presentan oportunidades prometedoras tanto para pronosticar niveles de contaminante *NO<sub>2</sub>* principalmente concentraciones espacio-temporales, como para calibrar dispositivos sensores.

HFM6 es un caso especial, ya que solo hay un estudio de investigación que utiliza modelos de PCA y MLP conjuntamente para predecir y concentraciones *PM<sub>2.5</sub> PM<sub>10</sub>*(23). En este estudio, las mediciones de partículas y diferentes condiciones climáticas se someten a análisis PCA para maximizar sus correlaciones y generar nuevas variables que sean ortogonales entre sí. Estas nuevas variables sirven como variables de entrada para el modelo MLP. Luego, los datos se procesan a través de transformaciones no lineales en diferentes capas (perceptrón), identificando patrones con el error más pequeño, como el error cuadrático medio. Como resultado, HFM6 demuestra un potencial prometedor para su utilización en futuros estudios de investigación similares y podría explorarse en aplicaciones SQF, particularmente en el ámbito de la agricultura inteligente.

HFM5, HFM7 y HFM8 se emplean principalmente para calibrar estaciones meteorológicas/de suelo utilizando análisis de árboles de decisión múltiples (RF) o maximizando el ancho de la brecha entre diferentes categorías (SVM) formada por mediciones de aire/suelo (30,49,59). La validación de los resultados se obtiene mediante la aplicación de diferentes métodos estadísticos. Específicamente, HFM5 se utiliza para calcular correlaciones en datos angulares, como la dirección del viento, utilizando el método JSGC; por lo tanto, HFM5 tiene potencial para calibrar la medición de variables angulares obtenidas por sensores en estaciones meteorológicas / de suelo. Por el contrario, HFM7 se emplea para calibrar sensores de variables lineales utilizando el método PC. Por otro lado, HFM8 utiliza el método LR en cada categoría formada por la aplicación de SVM para lograr la mejor precisión. A diferencia de HFM5, HFM8 no utiliza cálculos de correlación, sino que sirve como una forma alternativa de explorar aplicaciones de calibración, incluso en aplicaciones AQF y SQF.

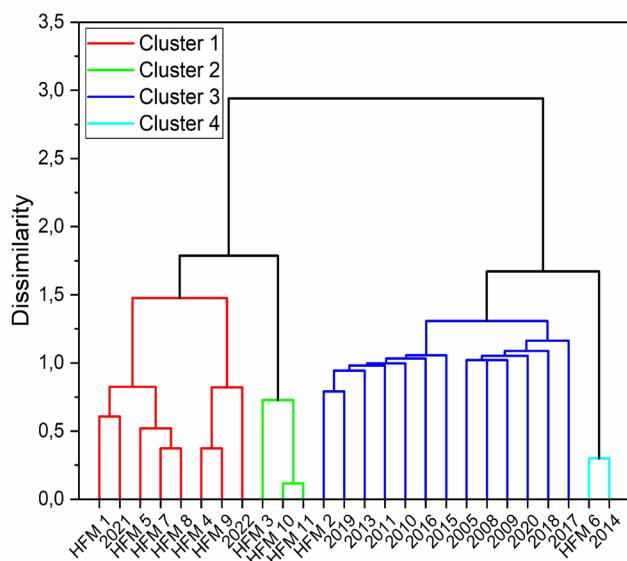


Figura 9. (Dendrograma) Agrupación de modelos de pronóstico híbridos y año de publicación

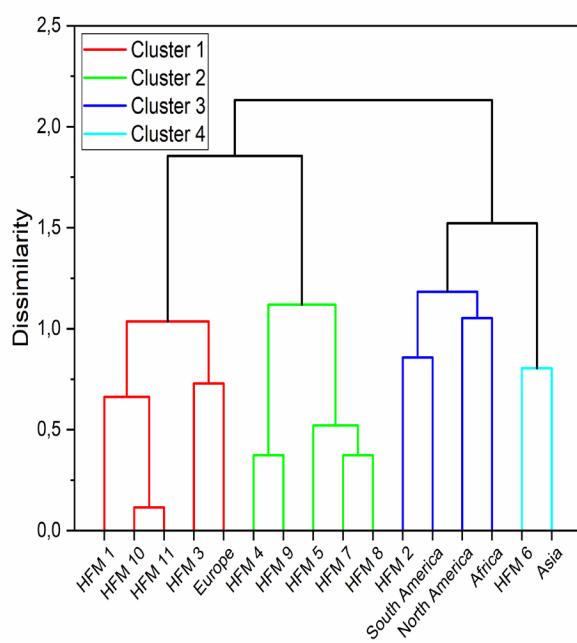


Figura 10. (Dendrograma) Agrupación de modelos híbridos de pronóstico y continente de publicación

Por otro lado, durante las últimas dos décadas se han realizado investigaciones centradas en el registro de estaciones de aire/suelo y en el diseño de estaciones meteorológicas/de suelo precisas, especialmente para aplicaciones agrícolas (HFM2) (grupo 3: línea azul). Sin embargo, a pesar de la existencia de tales trabajos hasta 2019, su tendencia está disminuyendo en comparación con el uso creciente de aplicaciones de IA. El clúster 4 (línea cian) incluye solo la aplicación de los métodos PCA y MLP en 2014; este resultado destaca una brecha en la investigación en la que estos modelos podrían proponerse para evaluar AQF, SQF y calibración de sensores en los estudios actuales.

La agrupación jerárquica se realizó considerando el continente de publicación y las HFM, lo que dio como resultado cuatro clústeres (Figura 10). Los grupos 1 y 2 (línea roja y verde respectivamente) agrupan todos los HMF utilizados para pronosticar y evaluar la calidad del aire, incluida la calibración de estaciones meteorológicas/de suelo a través de IA, en Europa. Por ello, la mayoría de las investigaciones novedosas se concentran en Europa, destacando la importante financiación en investigación destinada a proponer y aplicar políticas públicas ambientales que permitan reducir el impacto negativo de las emisiones de gases de efecto invernadero. Además, existe una fuerte [0.38](#)lencia al uso de HFM11 en este continente, con una correlación significativa de (ver Apéndice).

Por otro lado, las investigaciones centradas en el diseño de estaciones meteorológicas o de suelo para aplicaciones agrícolas son más comunes en América del Sur, América del Norte y África (clúster 3: línea azul). En Asia, HFM6 es el principal método de pronóstico híbrido; por lo tanto, se divulga otro enfoque potencial de investigación con respecto al pronóstico de contaminantes, nutrientes o variables físicas en los suelos asiáticos.

#### [Principales vínculos entre las estaciones meteorológicas/de suelo y los modelos de predicción híbridos](#)

Finalmente, se calculó el análisis jerárquico de agrupamiento de distritos, considerando tanto las estaciones meteorológicas/de suelo como las HFM (Figura 11). Las estaciones meteorológicas/de suelo 1 y 4 son estaciones de monitoreo de uso general equipadas con sensores de aire y suelo para capturar las condiciones climáticas y del suelo, incluidas la temperatura, la humedad, la velocidad y dirección del viento, NKP, pH y otras. Por otro lado, las estaciones meteorológicas/de suelo se utilizan específicamente como dispositivos electroquímicos de detección, diseñados específicamente para obtener mediciones de las variables antes mencionadas. De hecho, estas estaciones de monitoreo están agrupadas en el grupo 1, exhibiendo la mayor distancia jerárquica en comparación con otros grupos (Figura 11). De ahí que exista una falta de información sobre el uso de métodos de predicción para calibrar o predecir el comportamiento espacio-temporal de las variables obtenidas por estas estaciones de monitoreo. Sin embargo, es crucial reconocer que las medidas obtenidas por las estaciones meteorológicas/de suelo 1 y 4 no se emplean únicamente como variables de entrada para entrenar algoritmos destinados a predecir otras variables, sino que tampoco suelen ser el objetivo de la predicción o calibración en los trabajos de investigación. Además, existe una correlación negativa significativa entre la estación meteorológica/del suelo 4 y la aplicación de RF para calibrar sensores variables circulares (véase el Apéndice), lo que indica una tendencia a evitar su aplicación conjunta. En resumen, si bien las variables de la estación meteorológica / del suelo pueden no tener un interés claro entre los investigadores, su utilización sigue siendo fundamental para avanzar en los trabajos de AQF y SQF.

Los contaminantes del aire y las partículas () pueden ser registrados de manera efectiva por estaciones de monitoreo de bajo costo, como las estaciones meteorológicas / de suelo 2 y 3. Esta ventaja radica en la capacidad de obtener una base de datos útil y confiable para entrenar modelos DL como CNN y MLP, lo que permite predicciones precisas en el tiempo y el espacio de los niveles de contaminantes. De hecho, HFM2 y HFM6 se agrupan con las estaciones meteorológicas/de suelo 2 y 3. Es notable que estos trabajos de investigación se originan predominantemente en América

del Sur y Asia, lo que sugiere una oportunidad para explorar estos temas en otros continentes. Además, los métodos de predicción espacial y a largo plazo están estrechamente asociados con el clúster 2 (línea verde), lo que indica que los métodos LSTM, CNN, KCV, FIS, BO y ARIMA se aplican generalmente para  $\text{CO}_2$ ,  $\text{PM}_{2.5}$  –  $\text{PM}_{10}$ , concentraciones de partículas y gases de carbono en Europa. La prevalencia de estos

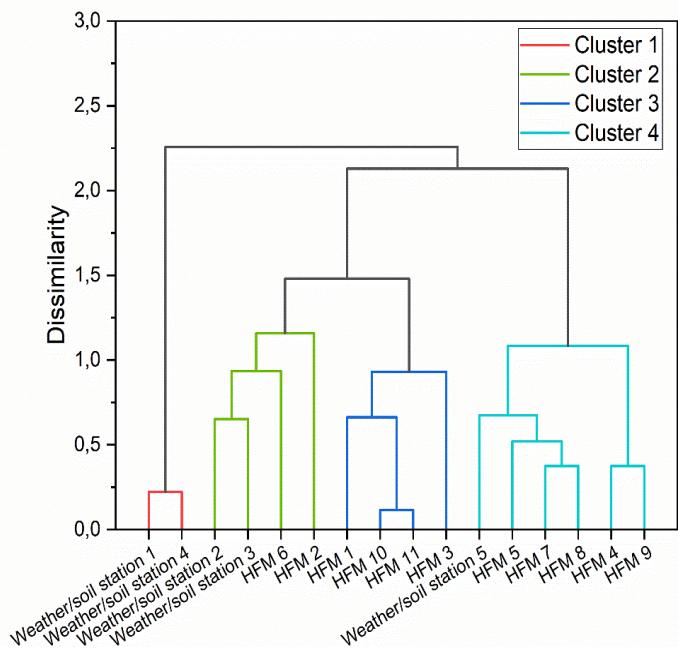


Figura 11. (Dendrograma) Agrupación de modelos híbridos de predicción y estaciones meteorológicas/de suelo

Los métodos de investigación europeos destacan su potencial para abordar los desafíos de la previsión de la calidad del aire en esta región.

La estación meteorológica/de suelo 5 demuestra una fuerte relación con los registros de contaminación del suelo, ya que incluye la medición de los gases COV y COV, que se sabe que tienen efectos negativos en las plantas. Por lo tanto, la predicción de estas variables tiene un gran interés de investigación actual. De hecho, los modelos de pronóstico ANN y EL se han aplicado con éxito para predecir concentraciones. Además, los sensores podrían calibrarse mediante modelos de RF y SVM para lograr la mejor precisión y mejorar la calidad de la predicción. Luego, la estación meteorológica / de suelo 5 tiene un doble propósito en la predicción de variables de suelo y la calibración de sensores de suelo a través de las aplicaciones de HFM4, HFM5, HFM7, HFM8 y HFM9. En particular, la estación meteorológica/de suelo 5 tiene una correlación significativa con HFM4 y HFM5 (véase el Apéndice); lo que indica una tendencia clara en la calibración y el pronóstico y las señales de tiempo de variables circulares como la dirección del viento, mediante el uso de métodos ANN, RF y JSGC.

$\text{NO}_x$ ,  $\text{O}_3$   $\text{NO}_2$   $\text{NO}_2$

En general, se recomienda que la investigación futura se centre en la evaluación de AQF en continentes distintos de Europa, utilizando las estaciones meteorológicas / de suelo 2 y 3 junto con los modelos de pronóstico LSTM, CNN y MLP. Sin embargo, existe la oportunidad de aplicar estos métodos para calibrar sensores que miden y partículas. Por otro lado, para la evaluación de SQF, los investigadores deben usar la estación meteorológica / de suelo 5 y utilizar los métodos de pronóstico ANN, RF, SVM y EL para calibrar los sensores de suelo y predecir concentraciones de gases como , y COV. Las estaciones meteorológicas / de suelo 1 y 4 podrían utilizarse de manera efectiva para registrar variables esenciales, que pueden servir como predictores o entradas en modelos de pronóstico. Cabe señalar que cualquier combinación que no esté representada actualmente por los clústeres en  $\text{CO}$ ,  $\text{CO}_2$ ,  $\text{NO}_x$ ,  $\text{O}_3$  Figura 11 siguen siendo áreas de investigación inexploradas con potencial para ser consideradas en futuros trabajos. Estas combinaciones inexploradas ofrecen vías prometedoras para avanzar en el campo de la ingeniería ambiental y mejorar las aplicaciones de pronóstico de la calidad del aire y el suelo.

## Conclusiones

Actualmente, el uso de tecnologías de IA cubre la mayoría de los temas de conocimiento, incluido el pronóstico de las condiciones climáticas y del suelo, especialmente la predicción confiable de los niveles de contaminantes del aire y el suelo. Los modelos de pronóstico basados en estas tecnologías de IA de vanguardia han demostrado la capacidad de lograr predicciones precisas utilizando mediciones meteorológicas / del suelo como variables de entrada y variables objetivo. Además, los estudios de investigación se centran en el diseño de dispositivos de medición para enviar, recibir, almacenar y procesar datos utilizando software integrado y protocolos de comunicación de largo alcance como Wi-Fi.

Hay tres configuraciones tecnológicas principales utilizadas a lo largo de las investigaciones. La primera, es una estación de monitoreo holístico que permite el registro tanto de las condiciones climáticas y contaminantes en el aire, como de nutrientes, condiciones físico-químicas y contaminantes en el suelo. Esta configuración no es compatible con las aplicaciones de IA, ya que su objetivo es garantizar el registro y almacenamiento de datos de alta calidad.

La segunda configuración tecnológica, además de la estación de monitoreo de gases de efecto invernadero, incluye métodos de IA para evaluar AQF, con un enfoque específico en registros de tiempo largo-corto y pronóstico de gases de carbono y partículas, aplicando métodos de pronóstico de IA como LSTM, CNN y MLP que están respaldados por modelos estadísticos y matemáticos como KCV, kriging, PCA, FIS, BO, ARIMA, SI y FDA.

La tercera configuración agrupa los SQF y los dispositivos de calibración, con especial atención al registro de datos de señales espaciales y temporales de contaminantes del suelo, correlacionados con efectos nocivos en las plantas atribuidos a la presencia de gases y COV. Además, la predicción espacial y temporal de estos contaminantes se evalúa utilizando los métodos ANN, RF, SVM, que se complementan con los métodos estadísticos MLR, JSGC, PC y LR, y el método matemático MOO. Además, este tipo de tecnología incluye la calibración basada en métodos de IA como preprocessamiento de los datos de registro para mejorar la precisión de la predicción.  $\text{NO}_x$ ,  $\text{O}_3$

Estos hallazgos proporcionan información crucial sobre configuraciones tecnológicas inexploradas, que tienen un potencial sustancial para futuros esfuerzos de investigación. Además, presentan una

descripción general completa de las tendencias actuales en los trabajos de investigación de AQF y SQF. Aprovechando el poder de las tecnologías avanzadas de IA, la ingeniería ambiental puede lograr una mayor precisión en el pronóstico del clima y las condiciones del suelo, junto con la mitigación efectiva de contaminantes, lo que en última instancia contribuye a un medio ambiente sostenible y más saludable para todos.

## Apéndice

<https://hdl.handle.net/20.500.14112/30954>

### Declaraciones y declaraciones

Los autores declaran que no tienen conflictos ni intereses contrapuestos.

Esta investigación no recibió ninguna subvención específica de agencias de financiación en los sectores público, comercial o sin fines de lucro.

### Agradecimientos

Los autores agradecen el apoyo brindado por el programa de Ingeniería Ambiental de la Universidad Mariana por su generoso financiamiento de este proyecto, aprobado por el acuerdo 252 del 7 de diciembre de 2021. Adicionalmente, extendemos nuestro agradecimiento al Programa de Jóvenes Investigadores e Innovadores, así como al anuncio interno de la Universidad Mariana para el año 2022, por sus valiosos aportes a esta investigación.

### Contribución de autoría (CRediT)

Conceptualización, Investigación: Giovanni Alexander Cuaran Páez. Conceptualización, Metodología, Análisis formal, Investigación, Redacción – Borrador original: Luis Gabriel Lafaurie Ponce. Conceptualización, Redacción – Revisión y edición, Visualización: Jenny Lucía Huertas Delgado. Redacción – Revisión y edición: Daniel Alejandro Molina Cuaichar.

## References

1. Balogun AL, Tella A, Baloo L, Adebisi N. A review of the inter-correlation of climate change, air pollution and urban sustainability using novel machine learning algorithms and spatial information science. *Urban Climate*. 2021 Dec;40:100989. <https://doi.org/10.1016/j.uclim.2021.100989>
2. De Vries W, Dobbertin MH, Solberg S, Van Dobben HF, Schaub M. Impacts of acid deposition, ozone exposure and weather conditions on forest ecosystems in Europe: an overview. *Plant Soil*. 2014 Jul;380(1-2):1-45. <https://doi.org/10.1007/s11104-014-2056-2>
3. Zeng Z, Gui K, Wang Z, Luo M, Geng H, Ge E, et al. Estimating hourly surface PM2.5 concentrations across China from high-density meteorological observations by machine learning. *Atmospheric Research*. 2021 Jun;254:105516. <https://doi.org/10.1016/j.atmosres.2021.105516>
4. Espinosa R, Palma J, Jiménez F, Kamińska J, Sciavicco G, Lucena-Sánchez E. A time series forecasting based multi-criteria methodology for air quality prediction. *Applied Soft Computing*. 2021 Dec;113:107850. <https://doi.org/10.1016/j.asoc.2021.107850>
5. Akinosh TD, Oyedele LO, Bilal M, Barrera-Animas AY, Gbadamosi AQ, Olawale OA. A scalable deep learning system for monitoring and forecasting pollutant concentration levels on UK highways. *Ecological Informatics*. 2022 Jul;69:101609. <https://doi.org/10.1016/j.ecoinf.2022.101609>

6. Wang J, Li H, Yang H, Wang Y. Intelligent multivariable air-quality forecasting system based on feature selection and modified evolving interval type-2 quantum fuzzy neural network. *Environmental Pollution*. 2021 Apr;274:116429. <https://doi.org/10.1016/j.envpol.2021.116429>
7. Organization WH. Ambient air pollution: a global assessment of exposure and burden of disease. World Health Organization; 2016. <https://www.cleanairjournal.org.za/article/view/7001>
8. Koushal S, Arya D, Anbarasan S, Haloi D, M R, Rahman T, et al. Soil Pollution: Sources, Effects, and Mitigation Strategies. *AJSSPN*. 2025 Feb 15;11(1):280-90. <https://doi.org/10.9734/ajsspn/2025/v11i1480>
9. Kumar A, Attri AK. Correlating respiratory disease incidences with corresponding trends in ambient particulate matter and relative humidity. *Atmospheric Pollution Research*. 2016 Sep;7(5):858-64. <https://doi.org/10.1016/j.apr.2016.05.005>
10. Combes A, Frachineau G. Fine particle environmental pollution and cardiovascular diseases. *Metabolism*. 2019 Nov;100:153944. <https://doi.org/10.1016/j.metabol.2019.07.008>
11. Keikhosravi G, Fadavi SF. Impact of the inversion and air pollution on the number of patients with Covid-19 in the metropolitan city of Tehran. *Urban Climate*. 2021 May;37:100867. <https://doi.org/10.1016/j.uclim.2021.100867>
12. Organization WH. WHO global air quality guidelines: particulate matter (PM2.5 and PM10), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide [Internet]. World Health Organization; 2021. 290 p. Available from: <https://www.who.int/publications/i/item/9789240034228>
13. Renard JB, Surcin J, Annesi-Maesano I, Delaunay G, Poincelet E, Dixsaut G. Relation between PM2.5 pollution and Covid-19 mortality in Western Europe for the 2020-2022 period. *Science of The Total Environment*. 2022 Nov;848:157579. <https://doi.org/10.1016/j.scitotenv.2022.157579>
14. Różański SŁ, Castejón JMP, McGahan DG. Child risk assessment of selected metal(loid)s from urban soils using in vitro UBM procedure. *Ecological Indicators*. 2021 Aug;127:107726. <https://doi.org/10.1016/j.ecolind.2021.107726>
15. Khan ZI, Ahmad K, Yasmeen S, Akram NA, Ashraf M, Mehmood N. Potential health risk assessment of potato (*Solanum tuberosum L.*) grown on metal contaminated soils in the central zone of Punjab, Pakistan. *Chemosphere*. 2017 Jan;166:157-62. <https://doi.org/10.1016/j.chemosphere.2016.09.064>
16. da Silva Júnior AH, Mulinari J, de Oliveira PV, de Oliveira CRS, Reichert Júnior FW. Impacts of metallic nanoparticles application on the agricultural soils microbiota. *Journal of Hazardous Materials Advances*. 2022 Aug;7:100103. <https://doi.org/10.1016/j.hazadv.2022.100103>
17. Masood A, Ahmad K. A review on emerging artificial intelligence (AI) techniques for air pollution forecasting: Fundamentals, application and performance. *Journal of Cleaner Production*. 2021 Nov;322:129072. <https://doi.org/10.1016/j.jclepro.2021.129072>
18. Liu H, Yan G, Duan Z, Chen C. Intelligent modeling strategies for forecasting air quality time series: A review. *Applied Soft Computing*. 2021 Apr;102:106957. <https://doi.org/10.1016/j.asoc.2020.106957>
19. Liu H, Yin S, Chen C, Duan Z. Data multi-scale decomposition strategies for air pollution forecasting: A comprehensive review. *Journal of Cleaner Production*. 2020 Dec;277:124023. <https://doi.org/10.1016/j.jclepro.2020.124023>
20. Zhou C, Li S, Wang S. Examining the Impacts of Urban Form on Air Pollution in Developing Countries: A Case Study of China's Megacities. *IJERPH*. 2018 Jul 24;15(8):1565. <https://doi.org/10.3390/ijerph15081565>

21. Thorat T, Patle BK, Kashyap SK. Intelligent insecticide and fertilizer recommendation system based on TPF-CNN for smart farming. *Smart Agricultural Technology*. 2023 Feb;3:100114. <https://doi.org/10.1016/j.atech.2022.100114>
22. Özdemir U, Taner S. Impacts of Meteorological Factors on PM 10 : Artificial Neural Networks (ANN) and Multiple Linear Regression (MLR) Approaches. *Environmental Forensics*. 2014 Oct 2;15(4):329-36. <https://doi.org/10.1080/15275922.2014.950774>
23. He HD, Lu WZ, Xue Y. Prediction of particulate matters at urban intersection by using multilayer perceptron model based on principal components. *Stoch Environ Res Risk Assess*. 2015 Dec;29(8):2107-14. <https://doi.org/10.1007/s00477-014-0989-x>
24. Tian J, Chen D. A semi-empirical model for predicting hourly ground-level fine particulate matter (PM2.5) concentration in southern Ontario from satellite remote sensing and ground-based meteorological measurements. *Remote Sensing of Environment*. 2010 Feb;114(2):221-9. <https://doi.org/10.1016/j.rse.2009.09.011>
25. Awewomom J, Dzeble F, Takyi YD, Ashie WB, Ettey ENYO, Afua PE, et al. Addressing global environmental pollution using environmental control techniques: a focus on environmental policy and preventive environmental management. *Discov Environ*. 2024 Feb 6;2(1):8. <https://doi.org/10.1007/s44274-024-00048-y>
26. Kim Y, Evans RG, Iversen WM. Remote sensing and control of an irrigation system using a distributed wireless sensor network. *IEEE Transactions on Instrumentation and Measurement*. 2008;57(7):1379-87. <https://doi.org/10.1109/TIM.2008.917198>
27. Ben Ishak A, Moslah Z, Trabelsi A. Analysis and prediction of PM10 concentration levels in Tunisia using statistical learning approaches. *Environmental and Ecological Statistics*. 2016 Sep 1;23(3):469-90. <https://doi.org/10.1007/s10651-016-0349-8>
28. Bozner M, Lesjak M, Mlakar P. A neural network-based method for short-term predictions of ambient SO<sub>2</sub> concentrations in highly polluted industrial areas of complex terrain. *Atmospheric Environment Part B Urban Atmosphere*. 1993 Jun;27(2):221-30. [https://doi.org/10.1016/0957-1272\(93\)90007-S](https://doi.org/10.1016/0957-1272(93)90007-S)
29. Chaloulakou A, Grivas G, Spyrellis N. Neural Network and Multiple Regression Models for PM 10 Prediction in Athens: A Comparative Assessment. *Journal of the Air & Waste Management Association*. 2003 Oct;53(10):1183-90. <https://doi.org/10.1080/10473289.2003.10466276>
30. Xiong J, Yao R, Wang W, Yu W, Li B. A spatial-and-temporal-based method for rapid particle concentration estimations in an urban environment. *Journal of Cleaner Production*. 2020 May;256:120331. <https://doi.org/10.1016/j.jclepro.2020.120331>
31. Baklanov A, Zhang Y. Advances in air quality modeling and forecasting. *Global Transitions*. 2020;2:261-70. <https://doi.org/10.1016/j.glt.2020.11.001>
32. Wu H, Levinson D. The ensemble approach to forecasting: A review and synthesis. *Transportation Research Part C: Emerging Technologies*. 2021;132:103357. <https://doi.org/10.1016/j.trc.2021.103357>
33. Khaydukova M, Kirsanov D, Sarkar S, Mukherjee S, Ashina J, Bhattacharyya N, et al. One shot evaluation of NPK in soils by "electronic tongue." *Computers and Electronics in Agriculture*. 2021 Jul;186:106208. <https://doi.org/10.1016/j.compag.2021.106208>
34. Bai L, Wang J, Ma X, Lu H. Air Pollution Forecasts: An Overview. *Int J Environ Res Public Health*. 2018;44. <https://doi.org/10.3390/ijerph15040780>
35. Slater LJ, Arnal L, Boucher MA, Chang AYY, Moulds S, Murphy C, et al. Hybrid forecasting: blending climate predictions with AI models. *Hydrol Earth Syst Sci*. 2023 May 15;27(9):1865-89. <https://doi.org/10.5194/hess-27-1865-2023>

36. Chacón RL, García HM. Sistema de bajo coste para la medida y monitorización en agricultura inteligente. SAAEI 2018: 25 Seminario Anual de Automática, Electrónica Industrial e Instrumentación 2018: Barcelona, España: 4-6 Julio, 2018: proceedings book. 2018;250-6. <https://acortar.link/t74tVZ>
37. Fisher DK, Kebede H. A low-cost microcontroller-based system to monitor crop temperature and water status. Computers and Electronics in Agriculture. 2010 Oct;74(1):168-73. <https://doi.org/10.1016/j.compag.2010.07.006>
38. Piamonte M, Huerta M, Clotet R, Padilla J, Vargas T, Rivas D. WSN prototype for African oil palm bud rot monitoring. Advances in Intelligent Systems and Computing. 2018;687:170-81. [https://doi.org/10.1007/978-3-319-70187-5\\_13](https://doi.org/10.1007/978-3-319-70187-5_13)
39. Abad J, Farez J, Chasi P, Guillermo JC, García-Cedeño A, Clotet R, et al. Coffee Crops Variables Monitoring: A Case of Study in Ecuadorian Andes. Advances in Intelligent Systems and Computing. 2019;893:202-17. [https://doi.org/10.1007/978-3-030-04447-3\\_14](https://doi.org/10.1007/978-3-030-04447-3_14)
40. SV G M, Galande SG. Measurement of NPK, Temperature, Moisture, Humidity using WSN [Internet]. 2015 p. 84-9. Available from: [https://www.ijera.com/papers/Vol5\\_issue8/Part%20-%203/M58038489.pdf](https://www.ijera.com/papers/Vol5_issue8/Part%20-%203/M58038489.pdf)
41. Sahitya G, Balaji N, Naidu CD, Abinaya S. Designing a wireless sensor network for precision agriculture using zigbee. Proceedings - 7th IEEE International Advanced Computing Conference, IACC 2017. 2017 Jul;287-91. <https://doi.org/10.1109/IACC.2017.0069>
42. Kapse S, Kale S, Bhongade S, Sangamnerkar S, Gotmare Y. IOT Enable Soil Testing & NPK Nutrient Detection. Jac: a Journal of Composition Theory. 2020;XIII:310-8.
43. Mesas-Carrascosa FJ, Santano DV, Meroño JE, Orden MS de la, García-Ferrer A. Open source hardware to monitor environmental parameters in precision agriculture. Biosystems Engineering. 2015 Sep;137:73-83. <https://doi.org/10.1016/j.biosystemseng.2015.07.005>
44. Fahmi N, Huda S, Prayitno E, Rasyid MUHA, Roziqin MC, Pamungkuan MU. A prototype of monitoring precision agriculture system based on WSN. 2017 International Seminar on Intelligent Technology and Its Application: Strengthening the Link Between University Research and Industry to Support ASEAN Energy Sector, ISITIA 2017 - Proceeding. 2017 Nov;2017-January:323-8. <https://doi.org/10.1109/ISITIA.2017.8124103>
45. Juan MNV, Faruk FR, Quezada YML. Design and implementation of WSN for precision agriculture in white cabbage crops. Proceedings of the 2017 IEEE 24th International Congress on Electronics, Electrical Engineering and Computing, INTERCON 2017. 2017 Oct; <https://ieeexplore.ieee.org/abstract/document/8079671>
46. Karimi N, Arabhosseini A, Karimi M, Kianmehr MH. Web-based monitoring system using Wireless Sensor Networks for traditional vineyards and grape drying buildings. Computers and Electronics in Agriculture. 2018 Jan;144:269-83. <https://doi.org/10.1016/j.compag.2017.12.018>
47. Dorji U, Pobkrut T, Kerdcharoen T. Electronic nose based wireless sensor network for soil monitoring in precision farming system. 2017 9th International Conference on Knowledge and Smart Technology: Crunching Information of Everything, KST 2017. 2017 Mar;182-6. <https://doi.org/10.1109/KST.2017.7886087>
48. Martínez VDV, García FGF, Cervantes GG, Medina M de JF, Casillas HAM. Desarrollo y validación de una estación meteorológica automatizada de bajo costo dirigida a agricultura. Revista mexicana de ciencias agrícolas. 2015;6(6):1253-64. [https://www.scielo.org.mx/scielo.php?pid=S2007-09342015000600009&script=sci\\_arttext](https://www.scielo.org.mx/scielo.php?pid=S2007-09342015000600009&script=sci_arttext)
49. Cordero JM, Borge R, Narros A. Using statistical methods to carry out field calibrations of low cost air quality sensors. Sensors and Actuators B: Chemical. 2018 Aug;267:245-54. <https://doi.org/10.1016/j.snb.2018.04.021>

50. Agarwal S, Sharma S, R. S, Rahman MH, Vranckx S, Maiheu B, et al. Air quality forecasting using artificial neural networks with real time dynamic error correction in highly polluted regions. *Science of The Total Environment*. 2020 Sep;735:139454. <https://doi.org/10.1016/j.scitotenv.2020.139454>
51. Fernandez L, Huerta M, Sagbay G, Clotet R, Soto A. Sensing climatic variables in a orchid greenhouse. 2017 International Caribbean Conference on Devices, Circuits and Systems, ICCDCS 2017. 2017 Jun;101-4. <https://doi.org/10.1109/ICCDGS.2017.7959719>
52. Espinosa R, Jiménez F, Palma J. Multi-objective evolutionary spatio-temporal forecasting of air pollution. *Future Generation Computer Systems*. 2022 Nov;136:15-33. <https://doi.org/10.1016/j.future.2022.05.020>
53. Pruthi D, Liu Y. Low-cost nature-inspired deep learning system for PM2.5 forecast over Delhi, India. *Environment International*. 2022 Aug;166:107373. <https://doi.org/10.1016/j.envint.2022.107373>
54. Rodríguez Á, Figueredo J. Selección e implementación de un prototipo de estación meteorológica. 2016;341-52. <https://acortar.link/MawXhB>
55. Strigaro D, Cannata M, Antonovic M. Boosting a Weather Monitoring System in Low Income Economies Using Open and Non-Conventional Systems: Data Quality Analysis. *Sensors* 2019, Vol 19, Page 1185. 2019 Mar;19(5):1185. <https://doi.org/10.3390/s19051185>
56. Saini H, Thakur A, Ahuja S, Sabharwal N, Kumar N. Arduino based automatic wireless weather station with remote graphical application and alerts. 3rd International Conference on Signal Processing and Integrated Networks, SPIN 2016. 2016 Sep;605-9. <https://doi.org/10.1109/SPIN.2016.7566768>
57. Botero-Valencia JS, Mejia-Herrera M, Pearce JM. Low cost climate station for smart agriculture applications with photovoltaic energy and wireless communication. *HardwareX*. 2022 Apr;11:e00296. <https://doi.org/10.1016/j.ohx.2022.e00296>
58. Devaraju JT, Suhas KR, Mohana HK, Patil VA. Wireless Portable Microcontroller based Weather Monitoring Station. *Measurement*. 2015 Dec;76:189-200. <https://doi.org/10.1016/j.measurement.2015.08.027>
59. Bernardes GFLR, Ishibashi R, Ivo AAS, Rosset V, Kimura BYL. Prototyping low-cost automatic weather stations for natural disaster monitoring. *Digital Communications and Networks*. 2022 May; <https://doi.org/10.1016/j.dcan.2022.05.002>
60. Yamamoto K, Togami T, Yamaguchi N, Ninomiya S. Machine Learning-Based Calibration of Low-Cost Air Temperature Sensors Using Environmental Data. *Sensors* 2017, Vol 17, Page 1290. 2017 Jun;17(6):1290. <https://doi.org/10.3390/s17061290>
61. Perez P, Reyes J. Prediction of Particulate Air Pollution using Neural Techniques. :7. <https://acortar.link/1eaA01>
62. Zimmerman N, Presto AA, Kumar SPN, Gu J, Hauryliuk A, Robinson ES, et al. A machine learning calibration model using random forests to improve sensor performance for lower-cost air quality monitoring. *Atmospheric Measurement Techniques*. 2018;11(1):291-313. <https://doi.org/10.5194/amt-11-291-2018>
63. Lin CY, Chang YS, Abimannan S. Ensemble multifeatured deep learning models for air quality forecasting. *Atmospheric Pollution Research*. 2021 May;12(5):101045. <https://doi.org/10.1016/j.apr.2021.03.008>
64. Hofman J, Nikolaou M, Shantharam SP, Stroobants C, Weijs S, Manna VPL. Distant calibration of low-cost PM and NO<sub>2</sub> sensors; evidence from multiple sensor testbeds. *Atmospheric Pollution Research*. 2022 Jan;13(1):101246. <https://doi.org/10.1016/j.apr.2021.101246>

65. Gladkova E, Saychenko L. Applying machine learning techniques in air quality prediction. *Transportation Research Procedia*. 2022;63:1999-2006. <https://doi.org/10.1016/j.trpro.2022.06.222>
66. Smith JR. Weather Station and Data Logger. Programming the PIC Microcontroller with MBASIC. 2005 Jan;691-728. <https://doi.org/10.1016/B978-075067946-6/50030-4>
67. Benghanem M. Measurement of meteorological data based on wireless data acquisition system monitoring. *Applied Energy*. 2009 Dec;86(12):2651-60. <https://doi.org/10.1016/j.apenergy.2009.03.026>
68. Cao-Hoang T, Duy CN. Environment monitoring system for agricultural application based on wireless sensor network. 7th International Conference on Information Science and Technology, ICIST 2017 - Proceedings. 2017 May;99-102. <https://doi.org/10.1109/ICIST.2017.7926499>
69. Ma RH, Wang YH, Lee CY. Wireless Remote Weather Monitoring System Based on MEMS Technologies. *Sensors* (Basel, Switzerland). 2011 Mar;11(3):2715. <https://doi.org/10.3390/s110302715>
70. Jeong JH, Choi J, Jeong JY, Woo SH, Kim SW, Lee D, et al. A novel statistical-dynamical method for a seasonal forecast of particular matter in South Korea. *Science of The Total Environment*. 2022 Nov;848:157699. <https://doi.org/10.1016/j.scitotenv.2022.157699>
71. Mat I, Kassim MRM, Harun AN, Yusoff IM. IoT in Precision Agriculture applications using Wireless Moisture Sensor Network. ICOS 2016 - 2016 IEEE Conference on Open Systems. 2017 Mar;24-9. <https://doi.org/10.1109/ICOS.2016.7881983>
72. Pratama H, Yunan A, Candra RA. Design and Build a Soil Nutrient Measurement Tool for Citrus Plants Using NPK Soil Sensors Based on the Internet of Things. *Brilliance: Research of Artificial Intelligence*. 2021 Dec;1(2):67-74. <https://doi.org/10.47709/brilliance.v1i2.1300>
73. Suresh DS, V JKP, J RC. Automated Soil Testing Device. *ITSI Transactions on Electrical and Electronics Engineering (ITSI-TEEE)* ISSN (PRINT) 2013;(1):2320-8945.
74. Madhumathi R, Arumuganathan T, Shruthi R. Soil NPK and Moisture analysis using Wireless Sensor Networks. 2020 11th International Conference on Computing, Communication and Networking Technologies, ICCCNT 2020. 2020 Jul; <https://doi.org/10.1109/ICCCNT49239.2020.9225547>
75. Shylaja SN, Veena MB. Real-time monitoring of soil nutrient analysis using WSN. 2017 International Conference on Energy, Communication, Data Analytics and Soft Computing, ICECDS 2017. 2018 Jun;3059-62. <https://doi.org/10.1109/ICECDS.2017.8390018>
76. Flores-Medina M, Flores-García F, Velasco-Martínez V, González-Cervantes G, Jurado-Zamarripa F. Monitoreo de humedad en suelo a través de red inalámbrica de sensores. *Tecnología y ciencias del agua*. 2015 Oct;6(5):75-88. [https://www.scielo.org.mx/scielo.php?pid=S2007-2422201500050006&script=sci\\_arttext](https://www.scielo.org.mx/scielo.php?pid=S2007-2422201500050006&script=sci_arttext)
77. Ananthi N, Divya J, Divya M, Janani V. IoT based smart soil monitoring system for agricultural production. *Proceedings - 2017 IEEE Technological Innovations in ICT for Agriculture and Rural Development, TIAR 2017*. 2018 Jan;2018-January:209-14. <https://doi.org/10.1109/TIAR.2017.8273717>
78. Sindhu P, Indiran G. IoT Enabled Soil Testing. *Asian Journal of Computer Science and Technology*. 2018;7(S1):54-7. <https://doi.org/10.51983/ajcst-2018.7.S1.1805>
79. Ramadan KM, Oates MJ, Molina-Martinez JM, Ruiz-Canales A. Design and implementation of a low cost photovoltaic soil moisture monitoring station for irrigation scheduling with different frequency domain analysis probe structures. *Computers and Electronics in Agriculture*. 2018 May;148:148-59. <https://doi.org/10.1016/j.compag.2017.12.038>



80. Lawrence MG. The Relationship between Relative Humidity and the Dewpoint Temperature in Moist Air: A Simple Conversion and Applications. *Bull Amer Meteor Soc.* 2005 Feb;86(2):225-34. <https://doi.org/10.1175/BAMS-86-2-225>
81. Tehrani NA, Esfahani IC, Sun H. Simultaneous humidity and temperature measurement with micropillar enhanced QCM sensors. *Sensors and Actuators A: Physical.* 2024 Feb;366:115039. <https://doi.org/10.1016/j.sna.2024.115039>
82. Topp GC, Davis JL, Annan AP. Electromagnetic determination of soil water content: Measurements in coaxial transmission lines. *Water Resour Res.* 1980 Jun;16(3):574-82. <https://doi.org/10.1029/WR016i003p00574>
83. Mane S, Das N, Singh G, Cosh M, Dong Y. Advancements in dielectric soil moisture sensor Calibration: A comprehensive review of methods and techniques. *Computers and Electronics in Agriculture.* 2024;218:108686. <https://doi.org/10.1016/j.compag.2024.108686>
84. Amankwah SK, Ireson AM, Brannen R. An improved model and field calibration technique for measuring liquid water content in unfrozen and frozen soils with dielectric probes. *Vadose Zone Journal.* <https://acsess.onlinelibrary.wiley.com/doi/pdf/10.1002/vzj2.20225>
85. The World Air Quality Index project. aqicn.org. 2023 [cited 2023 Jun 27]. Air Quality Open Data Platform. Available from: <https://aqicn.org/data-platform/tos/>
86. Rosiek S, Batlles FJ. A microcontroller-based data-acquisition system for meteorological station monitoring. *Energy Conversion and Management.* 2008 Dec;49(12):3746-54. <https://doi.org/10.1016/j.enconman.2008.05.029>
87. Babalola TE, Babalola AD, Olokun MS. Development of an ESP-32 Microcontroller Based Weather Reporting Device. *JERR.* 2022 Jul 12;27-38. <https://doi.org/10.9734/jerr/2022/v22i1117577>
88. Sziroczak D, Rohacs D, Rohacs J. Review of using small UAV based meteorological measurements for road weather management. *Progress in Aerospace Sciences.* 2022 Oct;134:100859. <https://doi.org/10.1016/j.paerosci.2022.100859>
89. Outay F, Galland S, Gaud N, Abbas-Turki A. Simulation of connected driving in hazardous weather conditions: General and extensible multiagent architecture and models. *Engineering Applications of Artificial Intelligence.* 2021 Sep;104:104412. <https://doi.org/10.1016/j.engappai.2021.104412>
90. Han E, Ines AVM, Baethgen WE. Climate-Agriculture-Modeling and Decision Tool (CAMDT): A software framework for climate risk management in agriculture. *Environmental Modelling & Software.* 2017 Sep;95:102-14. <https://doi.org/10.1016/j.envsoft.2017.06.024>
91. Danbatta SJ, Varol A. Comparison of Zigbee, Z-Wave, Wi-Fi, and Bluetooth Wireless Technologies Used in Home Automation. In: 2019 7th International Symposium on Digital Forensics and Security (ISDFS) [Internet]. Barcelos, Portugal: IEEE <https://doi.org/10.1109/ISDFS.2019.8757472>
92. Kumar, Bhuvana C, Anushya S. Comparison of ZigBee and Bluetooth wireless technologies-survey. In: 2017 International Conference on Information Communication and Embedded Systems (ICICES) [Internet]. Chennai, India: IEEE; 2017 [cited 2023 May 10]. p. 1-4. Available from: <https://doi.org/10.1109/ICICES.2017.8070716>
93. Ye S, Xue P, Fang W, Dai Q, Peng J, Sun Y, et al. Quantitative effects of PM concentrations on spectral distribution of global normal irradiance. *Solar Energy.* 2021 May;220:1099-108. <https://doi.org/10.1016/j.solener.2020.08.070>
94. Zhang C, Stevenson D. Characteristic changes of ozone and its precursors in London during COVID-19 lockdown and the ozone surge reason analysis. *Atmospheric Environment.* 2022 Mar;273:118980. <https://doi.org/10.1016/j.atmosenv.2022.118980>

95. Vazquez Santiago J, Inoue K, Tonokura K. Diagnosis of ozone formation sensitivity in the Mexico City Metropolitan Area using HCHO/NO<sub>2</sub> column ratios from the ozone monitoring instrument. Environmental Advances. 2021 Dec;6:100138. <https://doi.org/10.1016/j.envadv.2021.100138>

96. Wongrin W, Chaisee K, Suphawan K. Comparison of Statistical and Deep Learning Methods for Forecasting PM2.5 Concentration in Northern Thailand. Pol J Environ Stud. 2023 Feb 23;32(2):1419-31. <https://doi.org/10.15244/pjoes/157072>