

# **Medición de CO<sub>2</sub> para la mejora de la calidad del aire en espacios interiores: una revisión de literatura**

## **CO<sub>2</sub> Measurement for indoor air quality improvement: a literature review**

John Barco-Jiménez<sup>1</sup>

Álvaro José Cervelión Bastidas<sup>2</sup>

Sixto Enrique Campaña Bastidas<sup>3</sup>

*Universidad Nacional Abierta y a Distancia, Colombia*

### **Resumen**

Mantener una buena calidad del aire interior es vital para la salud y la seguridad en los laboratorios clínicos, ya que implica proteger al personal y garantizar la exactitud de la investigación. La pandemia de covid-19 demostró la importancia de prevenir la propagación de enfermedades transmitidas por el aire. El CO<sub>2</sub> constituye un indicador clave en este contexto: sus niveles muestran si la ventilación funciona correctamente y si los espacios están sobreocupados. Las concentraciones elevadas suelen reflejar una ventilación deficiente, lo cual aumenta el riesgo de transmisión de enfermedades respiratorias. A pesar de los avances tecnológicos, existe una carencia de estudios centrados en el uso de la monitorización de CO<sub>2</sub> y de ventilación inteligente en laboratorios clínicos; la mayoría de las investigaciones se enfoca en hogares o edificios comerciales, cuyos requisitos son menos estrictos. Herramientas como los sensores de infrarrojo no dispersivo (NDIR) y modelos de IA —por ejemplo, redes de memoria a largo plazo (LSTM) o algoritmos *Random Forest*— pueden predecir la calidad del aire y optimizar la ventilación. Sin embargo, su uso en entornos clínicos sigue siendo limitado. Para profundizar en este aspecto, esta revisión examina tecnologías de sensores, modelos predictivos y la interacción humano-ambiente. Se recopilaron artículos de las bases de datos Scopus e IEEE publicados entre 2020 y 2025, seleccionando 41 para un análisis detallado bajo criterios

---

<sup>1</sup> Escuela de Ciencias Básicas Tecnologías e Ingeniería – UNAD, <https://orcid.org/0000-0002-9152-2132/> john.barco@unad.edu.co

<sup>2</sup> Escuela de Ciencias Básicas Tecnologías e Ingeniería – UNAD, <https://orcid.org/0000-0001-5823-8992/> alvaro.cervelion@unad.edu.co

<sup>3</sup> Escuela de Ciencias Básicas Tecnologías e Ingeniería – UNAD, <https://orcid.org/0000-0001-9937-2784/> sixto.campana@unad.edu.co

específicos. Los hallazgos resaltan la necesidad de sistemas adaptativos que consideren tanto los datos ambientales como el comportamiento humano. Dichos sistemas pueden conducir a una gestión de calidad del aire más segura, eficiente y adecuada para entornos clínicos, donde la fiabilidad y la resiliencia son esenciales.

**Palabras clave:** monitorización de CO<sub>2</sub>, calidad del aire, laboratorios clínicos, tecnologías IoT, salud ambiental, prevención de riesgos, ocupación en edificios.

## **Abstract**

Maintaining good indoor air quality is vital for health and safety in clinical labs. It is about protecting staff and ensuring research accuracy. The COVID-19 pandemic showed the importance of preventing airborne disease spread. CO<sub>2</sub> is a key indicator here. CO<sub>2</sub> levels show if ventilation is working and if spaces are too crowded. High levels often mean poor ventilation, which can increase the risk of spreading respiratory illnesses. Despite advances in technology, there is a lack of research on using CO<sub>2</sub> monitoring and smart ventilation in clinical labs. Most work focuses on homes or commercial buildings, which have less strict requirements. Tools like Non-Dispersive Infrared Sensors (NDIR) and AI models, such as Long Short-Term Memory (LSTM) networks or Random Forest algorithms, can predict air quality and improve ventilation. However, they are not widely used or studied in clinical labs. To understand this better, this review looks at sensor technologies, predictive models, and how people interact with their environment. Articles searched Scopus and IEEE databases for studies published between 2020 and 2025. After reviewing the results and using specific criteria, 41 articles were chosen for detailed analysis. The review highlights the need for adaptive systems that consider both environmental data and human behavior. This could lead to smarter air quality management that is safer, more energy-efficient, and better suited for clinical environments, which need high reliability and resilience.

**Keywords:** CO<sub>2</sub> Monitoring, air quality, clinical laboratories, iot technologies, environmental health, risk prevention, building occupancy.

## **1. Introducción**

La calidad del aire en espacios cerrados, especialmente en entornos especializados como los laboratorios clínicos, es indudablemente crítica para mantener la salud y la seguridad ocupacional. La pandemia de covid-19 atrajo la atención mundial hacia los riesgos de transmisión de

patógenos por vía aérea, subrayando la importancia de mantener condiciones ambientales óptimas para mitigar los riesgos sanitarios. Una ventilación efectiva no solo protege al personal médico y a los pacientes, sino que también garantiza la consistencia y la fiabilidad de las actividades diagnósticas y de investigación. Entre los diversos factores a considerar, la concentración de dióxido de carbono (CO<sub>2</sub>) se destaca como un indicador clave para evaluar la ventilación interior y la posible acumulación de contaminantes en suspensión. Los niveles elevados de CO<sub>2</sub> suelen indicar ventilación insuficiente, lo que puede provocar la acumulación de aerosoles y partículas potencialmente infecciosas, incrementando así el riesgo de transmisión de enfermedades respiratorias. Si bien diversos contaminantes —como material particulado, dióxido de nitrógeno, ozono, monóxido de carbono, compuestos orgánicos volátiles y hongos en el aire— se han utilizado para evaluar la calidad del aire interior (IAQ), el CO<sub>2</sub> sigue siendo un indicador ampliamente aceptado, principalmente debido a su correlación directa con la ocupación humana y el hacinamiento. Por lo tanto, la monitorización continua del CO<sub>2</sub>, junto con estrategias de ventilación adaptativas, se ha convertido en una herramienta esencial para proteger la salud y mantener los estándares operativos en entornos de laboratorio.

A pesar de los avances significativos en la monitorización de la calidad del aire interior, la literatura presenta vacíos respecto a la aplicación específica de tecnologías de monitorización de CO<sub>2</sub> y sistemas de control inteligente en laboratorios clínicos (Motuzienė *et al.*, 2025; Liang, 2023). La mayoría de estudios se centran en edificios inteligentes y entornos residenciales, donde los requisitos operativos son menos estrictos que en instalaciones clínicas (Sánchez-Fernández *et al.*, 2023). Aunque tecnologías como los sensores de CO<sub>2</sub> de infrarrojo no dispersivo (NDIR) han demostrado alta precisión y estabilidad, y los modelos de aprendizaje automático —como las redes de memoria a largo plazo (LSTM) y los algoritmos *Random Forest*— muestran resultados prometedores para el control predictivo de la ventilación (Zhu *et al.*, 2020; Flayyih *et al.*, 2025), su implementación en entornos críticos sigue estando poco explorada. Además, la interacción dinámica entre el comportamiento humano, las variables ambientales y la eficacia de la ventilación no ha sido suficientemente abordada (Kanthila *et al.*, 2021). En consecuencia, esta revisión busca responder a las siguientes preguntas fundamentales: ¿Qué tecnologías de medición de CO<sub>2</sub> muestran una mayor idoneidad para su despliegue en entornos clínicos? Asimismo, ¿qué modelos predictivos exhiben el mayor grado de precisión para facilitar una

gestión eficaz de la ventilación en estos entornos especializados? Finalmente, ¿cómo influye la interacción entre el comportamiento humano y las condiciones ambientales en la calidad del aire interior y en el desarrollo de estrategias de ventilación sólidas?

Esta revisión de la literatura busca llenar dichos vacíos a través de un examen sistemático de tecnologías de medición de CO<sub>2</sub>, modelos predictivos impulsados por inteligencia artificial y estudios sobre interacciones humano-ambiente particularmente relevantes para los laboratorios clínicos. Con este propósito, se realizó una búsqueda exhaustiva en Scopus, IEEE Xplore y ScienceDirect, abarcando el periodo 2020–2025. Los artículos recopilados se organizaron temáticamente en tres áreas principales: tecnologías para la detección de CO<sub>2</sub> y sistemas de monitorización integrada, modelado predictivo y aplicaciones de IA para el control de la calidad del aire y la ocupación, y los diversos factores conductuales y ambientales que influyen en la dinámica de la ventilación. Esta estructura temática busca promover una comprensión profunda de cómo las tecnologías de monitorización de CO<sub>2</sub> pueden aplicarse eficazmente en laboratorios clínicos. La revisión va más allá de la simple identificación de tecnologías de sensores y algoritmos de vanguardia; resalta la necesidad crítica de sistemas adaptativos. Estos sistemas deben ser capaces de integrar datos de sensores con información sobre respuestas conductuales, asegurando un enfoque robusto para la gestión de la calidad del aire. En última instancia, este trabajo busca contribuir a la creación de entornos interiores más seguros y saludables, promoviendo estrategias de gestión de calidad del aire basadas en evidencia, que mejoren tanto el bienestar de los ocupantes como la eficiencia energética en estos entornos críticos.

## **2. Metodología**

Para responder a la pregunta de investigación, se llevó a cabo una revisión sistemática de la literatura siguiendo la guía metodológica propuesta en (Carrera-Rivera *et al.*, 2022). Este proceso se estructuró en cuatro etapas principales: definición del alcance mediante el marco PICOP, formulación de la estrategia de búsqueda, aplicación de criterios de inclusión y exclusión, y un proceso de selección y síntesis de los estudios basado en el diagrama PRISMA.

En primer lugar, se empleó el marco PICOP (Flayyih *et al.*, 2025) con el fin de delimitar claramente el alcance de la revisión. La población de interés incluyó laboratorios clínicos y entornos de atención en salud, espacios donde la calidad del aire impacta directamente en la seguridad

de pacientes y personal. La intervención se definió como la implementación de tecnologías y metodologías de medición de dióxido de carbono (CO<sub>2</sub>), mientras que la comparación consideró distintos sistemas de monitorización y su efectividad en la reducción de riesgos asociados. El resultado esperado se centró en la mejora de la calidad del aire, la disminución de contagios y la optimización de las condiciones ambientales. Finalmente, el lugar de aplicación se restringió a espacios cerrados dentro de laboratorios clínicos, donde la monitorización continua resulta indispensable.

Posteriormente, se diseñó una estrategia de búsqueda exhaustiva en tres bases de datos científicas de amplia cobertura: Scopus, ScienceDirect e IEEE Xplore. Estas fueron seleccionadas por su relevancia en los campos de la ingeniería, las ciencias ambientales y la medicina. La cadena de búsqueda se formuló a partir de los términos PICOP y se aplicó en títulos, resúmenes y palabras clave. El criterio de búsqueda incluyó artículos publicados entre 2020 y 2025, en idioma inglés, dentro de las áreas de ingeniería, ciencias ambientales, medicina, negocios y gestión, y limitados al tipo de documento artículo de revista.

Para garantizar la pertinencia y calidad de los estudios, se establecieron criterios rigurosos de inclusión y exclusión. Se consideraron únicamente artículos que abordaran la medición, monitorización o predicción de la concentración de CO<sub>2</sub> en edificios, con especial énfasis en laboratorios clínicos o contextos de salud. Se excluyeron investigaciones en las que el CO<sub>2</sub> no fuera la variable principal, aquellas sin metodologías claras de medición o predicción, estudios fuera de entornos edificados o cerrados, publicaciones fuera del periodo de análisis o en otros idiomas, así como documentos distintos de artículos científicos.

El proceso de selección se desarrolló en varias fases. En la búsqueda inicial se identificaron 103 artículos, de los cuales se eliminaron 8 duplicados, quedando 95 registros únicos. A continuación, se realizó un cribado de títulos y resúmenes, descartando 54 por no cumplir con los criterios establecidos. De esta forma, se seleccionaron 41 artículos para revisión a texto completo, todos los cuales fueron finalmente confirmados como pertinentes y se incluyeron en el análisis definitivo. Este procedimiento se representó mediante un diagrama PRISMA que ilustra las etapas de identificación, cribado, elegibilidad e inclusión.

Finalmente, los estudios seleccionados se organizaron y analizaron de acuerdo con tres preguntas de investigación centrales. La primera (RQ1) se orientó a identificar tecnologías, dispositivos y sistemas

utilizados para la medición y monitorización de CO<sub>2</sub> en interiores. La segunda (RQ2) examinó la aplicación de técnicas de inteligencia artificial y aprendizaje automático para el modelado, predicción y control de la concentración de CO<sub>2</sub> y de la ocupación en espacios cerrados. La tercera (RQ3) exploró la influencia del comportamiento humano, los factores ambientales y la operación de edificios en la dinámica del CO<sub>2</sub> y su relación con las prácticas de ventilación y los resultados en salud. Esta organización permitió clasificar los artículos en tres categorías principales: tecnologías de sensores, técnicas de modelado predictivo y factores conductuales y ambientales. En conjunto, el proceso metodológico posibilitó integrar evidencia técnica, modelos basados en IA y análisis del comportamiento humano, lo que proporcionó una visión integral sobre el estado actual de la monitorización de CO<sub>2</sub> en entornos clínicos (Motuzienė *et al.*, 2025; Kanthila *et al.*, 2021; Sun *et al.*, 2024; Ziwei *et al.*, 2024). La siguiente Tabla describe la distribución de la literatura revisada en cada una de las preguntas de investigación planteadas.

**Tabla 1.** Citaciones por pregunta de investigación

RQ1: Tecnologías y sistemas para la medición de CO <sub>2</sub>	RQ2: Modelado con IA y control	RQ3: Factores ambientales y comportamentales
Motuzienė <i>et al.</i> , 2025; Liang <i>et al.</i> , 2023; Sánchez-Fernández <i>et al.</i> , 2023; Flayyih <i>et al.</i> , 2025; Sun <i>et al.</i> , 2024; MH-Z19C Datasheet, 2023; Ródenas <i>et al.</i> , 2022; Chojer <i>et al.</i> , 2020; Carminati <i>et al.</i> , 2021; Liu <i>et al.</i> , 2023; Tsanousa <i>et al.</i> , 2023; Godasiaei <i>et al.</i> , 2025; Piras <i>et al.</i> , 2025; Oh & Song, 2021; Ravelo <i>et al.</i> , 2024; Alavi <i>et al.</i> , 2022; Cretu <i>et al.</i> , 2024; Shieh, 2025; Seseña <i>et al.</i> , 2022; Stamp <i>et al.</i> , 2020; Basak <i>et al.</i> , 2025; Trueblood <i>et al.</i> , 2021; Sun, 2023; Gan <i>et al.</i> , 2021.	Motuzienė <i>et al.</i> , 2025; Liang <i>et al.</i> , 2023; Sánchez-Fernández <i>et al.</i> , 2023; Flayyih <i>et al.</i> , 2025; Sun <i>et al.</i> , 2024; Kanthila <i>et al.</i> , 2021; Soleimani-Alyar <i>et al.</i> , 2024; Summa <i>et al.</i> , 2025; Oh & Song, 2021; Ravelo <i>et al.</i> , 2024; Cretu <i>et al.</i> , 2024; Shieh, 2025; Gan <i>et al.</i> , 2021; Zhang <i>et al.</i> , 2024; Zhao <i>et al.</i> , 2024; Sood <i>et al.</i> , 2024; Almeida <i>et al.</i> , 2025; Benzaama <i>et al.</i> , 2024; Hu & Lv, 2020; Chen <i>et al.</i> , 2023; Wei <i>et al.</i> , 2022; Kim & Park, 2023; Su <i>et al.</i> , 2023; Altomonte <i>et al.</i> , 2020.	Motuzienė <i>et al.</i> , 2025; Kanthila <i>et al.</i> , 2021; Basak <i>et al.</i> , 2025; Diarra <i>et al.</i> , 2023; Zhang <i>et al.</i> , 2024; Zhao <i>et al.</i> , 2024; Kim & Park, 2023; Ziwei <i>et al.</i> , 2024.

--	--	--

### 3. Resultados

#### 3.1 Tecnologías de medición de CO<sub>2</sub> y sensores

La literatura revisada muestra que la medición de CO<sub>2</sub> se apoya principalmente en tecnologías de absorción infrarroja no dispersiva (NDIR), reconocidas por su precisión, estabilidad a largo plazo y capacidad de respuesta rápida (Liang *et al.*, 2023; Sun *et al.*, 2024). Este principio se basa en la absorción de radiación infrarroja por las moléculas de CO<sub>2</sub> a longitudes de onda específicas, lo que permite cuantificar con fiabilidad su concentración en el aire. Dispositivos como el TESTO 535, que emplea el principio de doble canal de absorción infrarroja, ofrecen un rango de medición entre 0 y 5000 ppm con alta resolución y márgenes de error reducidos (Soleimani-Alyar *et al.* 2024). Estas características explican por qué la tecnología NDIR se ha consolidado como el estándar en la monitorización de gases, especialmente en aplicaciones que requieren precisión y estabilidad, como los sistemas HVAC, la agricultura de precisión y, potencialmente, los entornos clínicos.

La aplicación de sensores NDIR no se limita a dispositivos de laboratorio, sino que abarca un amplio espectro de productos adaptados a diferentes necesidades. Ejemplos relevantes incluyen el HOB0 MX1102A, utilizado en aulas para monitorización continua y equipado con calibración automática, con una precisión de  $\pm 50$  ppm en un rango de 0 a 5000 ppm (Summa *et al.*, 2025). Otros modelos, como el MH-Z19B (2023), SenseAir S8 (Ródenas *et al.*, 2022), Telaire T6615 (Chojer *et al.*, 2020) y la familia de sensores Sensirion SCD30/SCD41 (Carminati *et al.*, 2021), se caracterizan por su bajo consumo energético, interfaces de comunicación versátiles y facilidad de integración en sistemas IoT y aplicaciones educativas. Algunos dispositivos destacan por propiedades específicas: el COZIR SprintIR ofrece lecturas de alta velocidad adecuadas para aplicaciones en tiempo real, mientras que el SCD41 combina tamaño compacto con bajo consumo energético, lo que lo hace ideal para dispositivos portátiles y aplicaciones de internet de las cosas.

En el ámbito industrial y de investigación, los sensores con rangos extendidos, como el Vaisala GMP343, permiten mediciones de hasta

50.000 ppm con márgenes de error cercanos al 1,5 % de la lectura, lo que resulta útil en contextos donde se requieren valores superiores a los habituales en edificios o laboratorios (Chojer *et al.*, 2020). Esta diversidad de dispositivos refleja que la monitorización de CO<sub>2</sub> no responde a una solución única, sino que debe ajustarse a las condiciones de cada entorno. Factores como el tiempo de respuesta (T90), que indica la rapidez del sensor para alcanzar el 90 % de la lectura final, el consumo energético en aplicaciones con baterías, la necesidad de calibración automática o manual y los rangos de temperatura y humedad admisibles, son determinantes en la selección del sensor más adecuado.

De esta manera, los avances en la tecnología de sensores NDIR han permitido consolidar un conjunto de herramientas adaptables a múltiples escenarios de monitorización. La variedad de configuraciones disponibles facilita su incorporación tanto en edificios inteligentes como en dispositivos portátiles de bajo consumo, ofreciendo una base sólida para su futura aplicación en laboratorios clínicos, donde la precisión, la fiabilidad y la capacidad de integración con sistemas de control ambiental resultan críticas para garantizar la seguridad y el confort de los usuarios (Flayyih *et al.*, 2025; Sun *et al.*, 2024; Carminati *et al.*, 2021).

### **3.2 Modelado predictivo y control inteligente de CO<sub>2</sub>**

La literatura revisada evidencia un creciente interés en el uso de técnicas de inteligencia artificial y aprendizaje automático para predecir y controlar la concentración de CO<sub>2</sub> en espacios interiores. Estos modelos se han mostrado especialmente útiles para estimar la ocupación y anticipar variaciones en la calidad del aire, ofreciendo una base sólida para implementar estrategias de ventilación más eficientes. Estudios recientes destacan que el desempeño de las redes neuronales recurrentes puede alcanzar valores de R<sup>2</sup> de hasta 0,92, con errores absolutos mínimos al pronosticar concentraciones de CO<sub>2</sub> (Diarra *et al.*, 2023). De manera similar, algoritmos de clasificación como los árboles de decisión y redes neuronales profundas, incluyendo Long Short-Term Memory (LSTM) y perceptrones multicapa, han logrado tasas de precisión cercanas al 97 % en la detección de ocupación a partir de datos de sensores de temperatura y CO<sub>2</sub> (Cretu *et al.*, 2024).

La integración de múltiples fuentes de información potencia aún más la capacidad predictiva. Modelos de boosting que combinan datos de sensores de CO<sub>2</sub>, detectores de movimiento, cargas eléctricas y puntos de acceso Wi-Fi han alcanzado niveles de acierto superiores al 99 % en la estimación de ocupación (Liang *et al.*, 2023). Este enfoque multimodal



permite superar las limitaciones inherentes a los sensores de CO<sub>2</sub>, como los retrasos de respuesta, y mejora la robustez del control en entornos de alta variabilidad. Asimismo, modelos autorregresivos con variables exógenas (ARX) han demostrado eficacia en la predicción de CO<sub>2</sub> y material particulado fino (PM<sub>2.5</sub>), aportando flexibilidad y estabilidad en escenarios como restaurantes y edificios de alta rotación de usuarios (Zhao *et al.*, 2024).

Los avances en técnicas de predicción también incluyen enfoques innovadores como el Negative Group Delay (NGD), que permite anticipar señales de concentración de CO<sub>2</sub> en tiempo real al modificar la respuesta de fase de la señal (Ravelo *et al.*, 2024). Esta capacidad de pronóstico adelantado se ha validado tanto en simulaciones como en experimentos, mostrando un potencial significativo para compensar el retardo natural de los sensores y mejorar la gestión en sistemas de ventilación controlada. En paralelo, modelos híbridos como el Piecewise Autoregressive Exogenous (PWARX) han sido aplicados para predecir dinámicas conjuntas de CO<sub>2</sub> y humedad relativa, mientras que técnicas de Gradient Boosting Regression (GBR) han establecido referentes de desempeño en edificios enfermos, alcanzando errores mínimos y valores de R<sup>2</sup> cercanos a uno (Flayyih *et al.*, 2025; Benzaama *et al.*, 2024).

Otro aporte relevante proviene de los sistemas de control predictivo basados en modelos adaptativos, los cuales integran arquitecturas LSTM de múltiples escalas temporales. Estos esquemas permiten ajustar en tiempo real la ventilación natural según concentraciones de CO<sub>2</sub> bajo, medio o elevado, equilibrando calidad del aire, eficiencia energética y confort térmico (Chen *et al.*, 2023; Wei *et al.*, 2022). La inclusión de marcos de optimización multiobjetivo, con algoritmos como XGBoost, ha demostrado que es posible mantener concentraciones adecuadas de CO<sub>2</sub> mientras se optimiza el consumo energético y se minimiza la incomodidad térmica (Sood *et al.*, 2024; Almeida *et al.*, 2025). Finalmente, la combinación de metodologías emergentes como la visión por computadora con modelos de aprendizaje profundo, entre ellos YOLOv8x, ha permitido validar cambios en la ocupación y mejorar la respuesta de los sistemas HVAC, reduciendo hasta en un 13,45 % la variación en la predicción de la demanda energética (Zhang *et al.*, 2024).

En conjunto, los hallazgos revisados muestran que los modelos basados en IA no solo incrementan la precisión en la predicción de la concentración de CO<sub>2</sub> y la ocupación, sino que también facilitan una gestión más dinámica e integral de la ventilación. Su aplicación en

edificios inteligentes y espacios críticos como laboratorios clínicos representa una vía prometedora para garantizar ambientes interiores más seguros, sostenibles y eficientes (Motuzienė *et al.*, 2025; Liang *et al.*, 2023; Flayyih *et al.*, 2025; Sun *et al.*, 2024; Ravelo *et al.*, 2024; Cretu *et al.*, 2024; Diarra *et al.*, 2023; Wei *et al.*, 2022).

### **3.3 Factores conductuales y ambientales en la dinámica del CO<sub>2</sub>**

El comportamiento de los ocupantes frente a la concentración de CO<sub>2</sub> constituye un elemento central en la gestión de la ventilación y la calidad del aire interior. La evidencia muestra que las personas no suelen reaccionar ante concentraciones bajas; sin embargo, cuando los niveles superan las 1.000 ppm, se activa con frecuencia la apertura de ventanas u otras medidas de ventilación (Kim & Park, 2023). Este umbral se repite en distintos estudios y confirma la relación directa entre la percepción de la calidad del aire y las acciones inmediatas para mejorarla (Kanthila *et al.*, 2021). Además, la temperatura exterior y la concentración de CO<sub>2</sub> se identifican como factores determinantes en estas respuestas, con efectos positivos y negativos, respectivamente, sobre la decisión de ventilar ((Kim & Park, 2023).

El análisis de estrategias de ventilación natural indica que la ventilación cruzada, lograda mediante la apertura simultánea de puertas y ventanas, es la opción más eficaz para reducir la concentración de CO<sub>2</sub> en espacios educativos (Sánchez-Fernández *et al.*, 2023). En aulas de 150 m<sup>3</sup>, se ha registrado un aumento de 34 ppm/min con 20 estudiantes frente a 21 ppm/min con 13 estudiantes, lo que demuestra la influencia directa de la densidad de ocupación en la acumulación de CO<sub>2</sub>. Asimismo, durante los recesos, la concentración disminuye, lo que permite predecir tiempos de recuperación en función de la estrategia aplicada y del nivel inicial de CO<sub>2</sub> (Sánchez-Fernández *et al.*, 2023). Este fenómeno adquiere mayor relevancia en edificaciones modernas con altos niveles de aislamiento, que limitan la ventilación incidental presente en construcciones más antiguas.

Más allá de los parámetros físicos, la calidad ambiental interior está condicionada por factores personales y perceptuales. La satisfacción de los ocupantes depende de su conciencia ambiental, de variables individuales y de la percepción de control sobre el entorno (Flayyih *et al.*, 2025). Estos aspectos son esenciales en el diseño de edificios de bajo consumo energético, donde debe equilibrarse la eficiencia con el confort

de los usuarios. La literatura también advierte que concentraciones elevadas de CO<sub>2</sub> afectan la salud, reducen el rendimiento cognitivo y aumentan los síntomas asociados al síndrome del edificio enfermo (Su *et al.*, 2023). Esto refuerza la importancia de tratar al CO<sub>2</sub> no solo como un indicador de ventilación y densidad de ocupación, sino como un elemento crítico para la toma de decisiones en materia de salud y seguridad en espacios sensibles.

La revisión de estos factores evidencia que la dependencia exclusiva de la percepción humana resulta insuficiente, dado que la respuesta espontánea aparece únicamente cuando los niveles superan cierto umbral (Kim & Park, 2023). En consecuencia, se requieren sistemas automáticos de monitorización de CO<sub>2</sub> que activen la ventilación antes de que las concentraciones alcancen valores críticos. En este sentido, la integración de tecnologías de detección, estrategias arquitectónicas como la ventilación cruzada y un diseño centrado en el usuario representan un enfoque integral para garantizar la seguridad y el bienestar en entornos interiores. Este planteamiento resulta especialmente relevante en laboratorios clínicos, donde la calidad del aire no solo afecta al confort, sino que constituye un factor decisivo para la bioseguridad (Altomonte *et al.*, 2020).

#### **4. Conclusiones**

La medición de CO<sub>2</sub> mediante sensores de absorción infrarroja no dispersiva se consolida como la tecnología más precisa y estable para la monitorización ambiental. Su rapidez de respuesta y fiabilidad a largo plazo la hacen adecuada no solo para aplicaciones en climatización y agricultura, sino también para contextos clínicos donde la exactitud resulta indispensable. La diversidad de dispositivos disponibles, como TESTO 535, MH-Z19B, SenseAir S8 y Sensirion SCD30/SCD41, demuestra que no existe una solución única, sino que la elección del sensor debe adaptarse a las condiciones y necesidades específicas de cada entorno.

La incorporación de algoritmos avanzados de aprendizaje automático y profundo ha mostrado un alto nivel de eficacia en la predicción tanto de la concentración de CO<sub>2</sub> como de la ocupación, alcanzando errores mínimos y resultados consistentes. Estos modelos permiten anticipar variaciones en la calidad del aire y ajustar de manera proactiva la ventilación, lo que contribuye a una gestión energética más eficiente y a la creación de ambientes saludables. En este sentido, propuestas como el *Negative Group Delay* o arquitecturas híbridas combinadas con sensores IoT evidencian el potencial del control predictivo en tiempo real,

reduciendo la dependencia de mediciones físicas continuas y favoreciendo entornos más sostenibles.

Sin embargo, la monitorización de CO<sub>2</sub> por sí sola no resulta suficiente para un control integral del ambiente interior. Su integración con variables como temperatura, humedad, movimiento, consumo eléctrico y técnicas de visión por computadora ha permitido que los sistemas basados en IA alcancen niveles de precisión cercanos al 99 % en la detección de ocupación. Este enfoque multimodal no solo corrige las limitaciones inherentes a los sensores de CO<sub>2</sub>, como el retardo de respuesta, sino que además fortalece la capacidad de adaptación en espacios con dinámicas variables de uso. Finalmente, los marcos de optimización multiobjetivo impulsados por IA permiten equilibrar eficiencia energética, confort térmico y calidad del aire, confirmando la aplicabilidad de estas soluciones tanto en edificios inteligentes como en entornos críticos como los laboratorios clínicos.

## Referencias

- Alavi, H. S., Zhong, S. & Lalanne, D. (2025). Indoor Air Quality Forecast in Shared Spaces– Predictive Models and Adaptive Design Proposals. *DOAJ*  
<https://doaj.org/article/850024a37d6e4e2991494d317b173d25>
- Almeida, F., Castelli, M., Côte-Real, N. & Manzoni, L. (2025). Optimizing Space Heating in Buildings: A Deep Learning Approach for Energy Efficiency. *Energies*, 18(10), p. 2471, DOI: 10.3390/en18102471
- Altomonte S. *et al.* (2020). Ten questions concerning well-being in the built environment. *Building and Environment*, 180, p. 106949, DOI: 10.1016/j.buildenv.2020.106949
- Basak J. K. *et al.*, (2025). Application of Machine Learning Models for Predicting Methane Concentrations in Pig Barns Using Biophysical Data. *Water Air & Soil Pollution*, 236(5), DOI: 10.1007/s11270-025-07954-8
- Benzaama, M.-H., Touati, K., Mendili, Y. E., Guern, M. L., Streiff, F. & Goodhew, S. (2024). Machine Learning-Based Indoor Relative Humidity and CO<sub>2</sub> Identification Using a Piecewise Autoregressive

- Exogenous Model: A Cob Prototype Study. *Energies*, 17, 1, p. 243, DOI: 10.3390/en17010243
- Carminati, M., Sinha, G. R., Mohdiwale, S. & Ullo, S. L. (2021). Miniaturized Pervasive Sensors for Indoor Health Monitoring in Smart Cities. *Smart Cities*, 4(1), p. 146, DOI: 10.3390/smartcities4010008.
- Carrera-Rivera, A., Ochoa, W., Larrinaga, F. & Lasa, G. (2022). How-to conduct a systematic literature review: A quick guide for computer science research. *MethodsX*, 9, p. 101895. DOI: 10.1016/j.mex.2022.101895
- Chen, E. X., Han, X., Malkawi, A., Zhang, R. & Li, N. (2023). Adaptive model predictive control with ensembled multi-time scale deep-learning models for smart control of natural ventilation. *Building and Environment*, 242, p. 110519, DOI: 10.1016/j.buildenv.2023.110519
- Chojer, H., Branco, P. T. B. S., Martins, F. G., Alvim-Ferraz, M. C. M. & Sousa, S. (2020). Development of low-cost indoor air quality monitoring devices: Recent advancements. *The Science of The Total Environment*, 727, p. 138385, DOI: 10.1016/j.scitotenv.2020.138385
- Cretu, G., Stamatescu, I. & Stâmătescu, G. (2024). Modeling and Prediction of Occupancy in Buildings Based on Sensor Data Using Deep Learning Methods. *IEEE Access*, 12, p. 102994, DOI: 10.1109/access.2024.3432584
- Diarra, M. K., Maniar, A., Masson, J.-B., Marhic, B. & Delahoche, L. (2023). Occupancy State Prediction by Recurrent Neural Network (LSTM): Multi-Room Context. *Sensors*, 23(23), p. 9603, DOI: 10.3390/s23239603
- Flayyih, H. Q., Waleed, J. & Ibrahim, A. M. (2025). Indoor Air Quality Prediction in Sick Building Using Machine and Deep Learning: Comparative Analysis. *Diyala Journal of Engineering Sciences*, p. 203, DOI: 10.24237/djes.2025.18112
- Gan, V. J. L., Luo, H., Tan, Y., Deng, M. & Kwok, H. L. (2021). BIM and Data-Driven Predictive Analysis of Optimum Thermal Comfort for Indoor Environment. *Sensors*, 21, (13), p. 4401, DOI: 10.3390/s21134401
- Godasiaei, S. H., Ejohwomu, O., Zhong, H. & Booker, D. (2025). Integrating Experimental Analysis and Machine Learning for Enhancing Energy Efficiency and Indoor Air Quality in Educational Buildings.

*Building and Environment*, p. 112874, DOI: 10.1016/j.buildenv.2025.112874.

Hu Y. C. & Lv, K. (2020). Hybrid Prediction Model for the Interindustry Carbon Emissions Transfer Network Based on the Grey Model and General Vector Machine. *IEEE Access*, 8, p. 20616, DOI: 10.1109/access.2020.2968585

Kanthila, C., Boodi, A., Beddiar, K., Amirat, Y. & Benbouzid, M. (2021). Building Occupancy Behavior and Prediction Methods: A Critical Review and Challenging Locks. *IEEE Access*, 9, 79353. DOI: 10.1109/access.2021.3083534

Kim S. H. & Park, C. S. (2023). Quantification of occupant response to influencing factors of window adjustment behavior using explainable AI. *Energy and Buildings*, 296, 113349, DOI: 10.1016/j.enbuild.2023.113349

King, V., Stevens, A., Nußbaumer-Streit, B., Kamel, C. & Garritty, C. (2022). Paper 2: Performing rapid reviews. *Systematic Reviews*, 11(1), DOI: 10.1186/s13643-022-02011-5.

Liang, X., Shim, J., Anderton, O. & Song, D. (2023). Low-cost data-driven estimation of indoor occupancy based on carbon dioxide (CO<sub>2</sub>) concentration: A multi-scenario case study. *Journal of Building Engineering*, 82, 108180, DOI: 10.1016/j.jobbe.2023.108180

Liu, X., Wang, Z., Li, J., Cangelosi, A. & Yang, C. (2023). Demonstration learning and generalization of robotic motor skills based on wearable motion tracking sensors. *IEEE Transactions on Instrumentation and Measurement*, 72, 1, DOI: 10.1109/TIM.2023.3288240.

MH-Z19C Datasheet. (Aug. 2023). <https://www.alldatasheet.com/datasheet-pdf/pdf/1303687/WINSEN/MH-Z19C.html>

Motuzienė, V., Bielskus, J., Džiugaitė-Tumėnienė, R. & Raudonis, V. (2025). Occupancy-Based Predictive AI-Driven Ventilation Control for Energy Savings in Office Buildings. *Sustainability*, 17(9), 4140, DOI: 10.3390/su17094140

Oh S. & Song, S. (2021). Detailed Analysis of Thermal Comfort and Indoor Air Quality Using Real-Time Multiple Environmental Monitoring Data for a Childcare Center. *Energies*, 14(3), 643, DOI: 10.3390/en14030643

- Piras, G., Agostinelli, S. & Muzi, F. (2025). Smart Buildings and Digital Twin to Monitoring the Efficiency and Wellness of Working Environments: A Case Study on IoT Integration and Data-Driven Management. *Applied Sciences*, 15(9), p. 4939, DOI: 10.3390/app15094939.
- Ravelo, B., Guerin, M. & Rahajandraibe, W. (2024). Negative Group Delay Predictor Application for CO<sub>2</sub> Gas Concentration Real-Time Forecasting.
- Ródenas M. *et al.* (2022). Review of low-cost sensors for indoor air quality: Features and applications. *Applied Spectroscopy Reviews*, 57, p. 747, Jun. DOI: 10.1080/05704928.2022.2085734
- Sánchez-Fernández, A., Aliaga, E. C., Lerma-Arce, V. & Lorenzo-Sáez, E. (2023). Evaluation of Different Natural Ventilation Strategies by Monitoring the Indoor Air Quality Using CO<sub>2</sub> Sensors. *International Journal of Environmental Research and Public Health*, 20(18), 6757, DOI: 10.3390/ijerph20186757.
- Seseña, S., Rodríguez, A. & Palop, M. L. (2022). Indoor air quality analysis in naturally ventilated university training laboratories: a health risk assessment. *Air Quality Atmosphere & Health*, 15(10), p. 1817, DOI: 10.1007/s11869-022-01220-0
- Shieh, J.-S. (2025). Development of a Human-Centric Autonomous Heating, Ventilation, and Air Conditioning Control System Enhanced for Industry 5.0 Chemical Fiber Manufacturing. <https://www.mdpi.com/2075-1702/13/5/421>
- Soleimani-Alyar, S., Soleimani-Alyar, M., Yarahmadi, R., Beyk-Mohammadloo, P. & Fazeli, P. L. (2024). The study of indoor particulate matter in office buildings based on artificial intelligence. *International Journal of Environmental Science and Technology*, Dec. DOI: 10.1007/s13762-024-06277-1
- Sood D. *et al.*, (2024). Machine learning based multi-objective optimisation of energy consumption, thermal comfort and CO<sub>2</sub> concentration in energy-efficient naturally ventilated residential dwellings. *Building and Environment*, 267, p. 112255, DOI: 10.1016/j.buildenv.2024.112255
- Stamp, S., Burman, E., Shrubsole, C., Chatzidiakou, L., Mumovic, D. & Davies, M. (2020). Long-term, continuous air quality monitoring in a

- cross-sectional study of three UK non-domestic buildings. *Building and Environment*, 180, p. 107071, DOI: 10.1016/j.buildenv.2020.107071
- Su, W., Ai, Z., Liu, J., Yang, B. & Wang, F. (2023). Maintaining an acceptable indoor air quality of spaces by intentional natural ventilation or intermittent mechanical ventilation with minimum energy use. *Applied Energy*, 348, p. 121504, DOI: 10.1016/j.apenergy.2023.121504
- Summa, S., Remia, G., Di Perna, C. & Stazi, F. (2025). Mechanically ventilated classrooms in central Italy's heritage school buildings: Proposal of archetypes and CO2 prediction models.
- Sun, Q., Liu, T., Xu, J., Li, H. & Huang, M. (2024). Rapid Recognition and Concentration Prediction of Gas Mixtures Based on SMLP. *IEEE Transactions on Instrumentation and Measurement*, 73, 1, DOI: 10.1109/tim.2024.3386203
- Sun, Y., Hu, Y., Zhang, H., Wang, F. & Chen, H. (2023). *A Parallel Supervision System for Vehicle CO2 Emissions Based on OBD-Independent Information*.
- Trueblood M. B. *et al.*, (2021). Calibration of gas flow meters using choked flow and an evacuated vessel. *Measurement Science and Technology*, 32(10), p. 105105, DOI: 10.1088/1361-6501/ac055d
- Tsanousa, A., Moschou, C., Bektsis, E., Vrochidis, S. & Kompatsiaris, I. (2023). Fusion of Environmental Sensors for Occupancy Detection in a Real Construction Site. *Sensors*, 23(23), p. 9596, Dec. DOI: 10.3390/s23239596
- Wei, Y., Jang-Jaccard, J., Xu, W., Sabrina, F., Camtepe, S. & Boulic, M. (2022). *LSTM-Autoencoder based Anomaly Detection for Indoor Air Quality Time Series Data*. arXiv (Cornell University), DOI: 10.48550/arXiv.2204.06701
- Zhang, W., Calautit, J. K., Tien, P. W., Wu, Y. & Wei, S. (2024). Deep Learning Models for Vision-Based Occupancy Detection in High Occupancy Buildings. *Journal of Building Engineering*, p. 111355, DOI: 10.1016/j.jobbe.2024.111355
- Zhao, Y., Xiong, C., Li, R., Luo, Z., Hussein, T. & Zhao, T. (2024). Research on an Adaptive Prediction Method for Restaurant Air Quality Based on Occupancy Detection. DOI: 10.2139/ssrn.4893706



- Zhu, H.-C., Ren, C. & Cao, S.-J. (2020). Fast prediction for multi-parameters (concentration, temperature and humidity) of indoor environment towards the online control of HVAC system. *Building Simulation*, 14(3), 649. DOI: 10.1007/s12273-020-0709-z.
- Ziwei H. *et al.* (2024). The applications of internet of things in smart healthcare sectors: a bibliometric and deep study. *Heliyon*, 10(3), DOI: 10.1016/j.heliyon.2024.e25392