

DISPOSITIVO INTELIGENTE DE EMULACIÓN DE SENSORES DE CO₂ DE ALTO COSTO
PARA APLICACIONES AMBIENTALES.

FREY DANIEL ANDRADE VELASCO
ESTEBAN ARENAS POSADA

INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO

FACULTAD DE INGENIERÍA
TECNOLOGÍA EN ELECTRÓNICA
MEDELLÍN

2024

DISPOSITIVO INTELIGENTE DE EMULACIÓN DE SENSORES DE CO2 DE ALTO
COSTO PARA APLICACIONES AMBIENTALES.

FREY DANIEL ANDRADE VELASCO

ESTEBAN ARENAS POSADA

Trabajo de grado para optar al título de Tecnólogo en electrónica

Asesores

BAYARDO EMILIO CADAVID GOMEZ

MSc. Automatización y Control Industrial

JOSE ALFREDO PALACIO FERNANDEZ

PhD. Ingeniería Ambiental

INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO

FACULTAD DE INGENIERÍA

TECNOLOGÍA EN ELECTRÓNICA

MEDELLÍN

2024

Contenido

Introducción	11
1. Planteamiento del problema.....	17
1.2 Descripción.....	17
1.3 Formulación	18
2. Justificación	18
3. Objetivos	19
3.1 Objetivo general	19
3.2. Objetivos Específicos	19
4. Marco teórico.....	20
4.1. Antecedentes de la Monitorización de CO ₂	20
4.1.2 Experiencias en el área metropolitana.....	21
4.2. Principios físicos para la construcción de sensores de gases.	22
4.2.1. Gases: Conceptos básicos.....	22
4.2.2. Sensores para la detección y medición de gases.....	24
4.2.3. Sensores de gas con plataforma electroquímica.	25
4.2.4. Sensores de gas de plataforma de Óxidos metálicos electrónicos (MOGS).....	27
4.2.5. Redes neuronales	28
4.2.6. Teorías de cambio climático.....	32
4.2.7. Teorías de la Calidad del Aire	32
4.3. Tecnologías de Monitorización de CO ₂	32
4.3.1. Sensores Convencionales	32
4.3.2. Tecnologías Emergentes.....	32
4.4. Conceptos clave.....	33
4.4.1. Calidad del Aire.....	33
4.4.2. Mitigación del Cambio Climático	33
4.5 Bases Teóricas	34
4.5.1 Estado Gaseoso y Comportamiento de los gases	34
4.5.2 Gases Reales vs. Ideales.....	34

4.5.3 Propiedades de los Gases	35
4.5.4 Clasificación de los Gases según su Naturaleza Química.....	36
4.6 Sensores implementados:	42
5. Metodología	45
5.3. Instrumentos de Recolección de información:	54
6. Resultados del proyecto	57
7. Conclusiones	64
8. Recomendaciones	65
9. Referencias bibliográficas.....	66

Tabla de imágenes

<i>Figura 1:</i> Ejemplo de dispositivo de monitorización de CO ₂ utilizado en áreas urbanas	20
<i>Figura 2:</i> Distribución territorial de las emisiones de CO ₂ . (a) AMVA (b) Comunas de Medellín.	21
<i>Figura 3:</i> Distribución de CO ₂ de acuerdo con la hora promedio de desplazamiento.....	22
<i>Figura 4:</i> La figura muestra la plataforma, el material usado para su construcción y el gas que detecta con mayor selectividad.	25
<i>Figura 5:</i> Ilustración esquemática de un sensor de oxígeno Alphasense configuración de dos electrodos y un electrolito.	26
<i>Figura 6:</i> Sensor de oxígeno Alphasense de alto costo.....	26
<i>Figura 7:</i> Circuito demostrativo del sensado de sensor de gases MOGS.	28
<i>Figura 8:</i> Esquema de una red neuronal artificial.	29
<i>Figura 9:</i> Función de activación lineal.	31
<i>Figura 10:</i> Placa de Arduino.	39
<i>Figura 11:</i> Arquitectura de una Red Neuronal. AWS.....	41
<i>Figura 12::</i> Sensor Gravity CO ₂ Sensor V2.0 SEN0159 (Sensor de Bajo Costo).....	43
<i>Figura 13:</i> Dwyer CDT-2N44 Wall Mount Carbon Dioxide Temperature Transmitter (Sensor de Alto Costo)	44
<i>Figura 14:</i> Vista Isométrica del dispositivo de pruebas	47
<i>Figura 15:</i> vista frontal.....	47
<i>Figura 16:</i> Vista Lateral	47
<i>Figura 17:</i> vista trasera.....	48
<i>Figura 18:</i> vista superior	48
<i>imagen 19:</i> Diagrama de flujo	50
<i>Figura 20:</i> elementos para prueba de calibración.....	51
<i>Figura 21:</i> inyección de O ₂	52
<i>Figura 22:</i> inyección CO ₂ con antorcha	52
<i>Figura 23:</i> inyección CO ₂ con pipeta.....	53
<i>Figura 24:</i> interfaz de PLX	54
<i>Figura 25:</i> sensor electroquímico	54
<i>Figura 26:</i> sensor alto costo	55
<i>Figura 27:</i> protoboard	55
<i>Figura 28:</i> cables jumper	56
<i>Figura 29:</i> Programa PLX (Prueba con pipeta de CO ₂)	57
<i>Figura 30:</i> Programa PLX (Prueba con O ₂).....	58
<i>Figura 31:</i> Programa PLX (Prueba con Antorcha con CO ₂)	58
<i>Figura 32:</i> Red Neuronal con datos de la pipeta con CO ₂	59
<i>Figura 33:</i> Tendencia de los datos en la Red Neuronal con datos de la pipeta con CO ₂	61
<i>Figura 34:</i> Código para toma de Datos (Arduino)	71

<i>Figura 35:</i> Código para entrenamiento de Red Neuronal (MATLAB)	72
<i>Figura 36:</i> Código para entrenamiento de Red Neuronal (ARDUINO)	74
<i>Figura 37:</i> Código para entrenamiento de Red Neuronal (ARDUINO)	78

Tablas

Tabla 1.	
<i>comparación de los sensores</i>	44
Tabla 2.	
<i>Obtención de resultados</i>	62

Resumen

Dispositivo inteligente de emulación de sensores de CO₂ de alto costo para aplicaciones ambientales

Este proyecto propone el diseño y desarrollo de un dispositivo que emule la funcionalidad de sensores de dióxido de carbono (CO₂) de alto costo, utilizando sensores económicos. La problemática identificada radica en el alto costo de los equipos de medición de precisión, lo que limita su uso en aplicaciones ambientales de bajo presupuesto. El propósito del dispositivo es mejorar la accesibilidad a datos precisos mediante el uso de sensores de bajo costo calibrados con redes neuronales.

La metodología se centró en la construcción de un sistema experimental que incluye sensores económicos y de referencia, un Arduino UNO, y la implementación de redes neuronales que ajustan las mediciones para simular la precisión de los equipos avanzados. Se diseñó una cápsula de pruebas para inyectar CO₂ en un entorno controlado y registrar los datos generados. Los resultados demostraron que, tras el entrenamiento de las redes neuronales, los sensores económicos alcanzaron niveles de precisión cercanos a los sensores de alto costo.

Se concluye que la integración de sensores económicos con algoritmos de inteligencia artificial puede democratizar el acceso a tecnologías de monitoreo ambiental, abriendo la posibilidad de implementar redes de monitoreo en regiones con recursos limitados. Como trabajos futuros, se plantea la optimización del modelo neuronal y la expansión del sistema a otros gases contaminantes.

Palabras claves: sensores de bajo costo, CO₂, red neuronal, Arduino, calibración

Abstract

Smart Device for Emulating High-Cost CO₂ Sensors for Environmental Applications

Authors: Frey Daniel Andrade Velasco, Esteban Arenas Posada

This project aims to design and develop a smart device capable of emulating the functionality of high-cost carbon dioxide (CO₂) sensors using low-cost alternatives. The identified problem is the limited accessibility to precise measurement devices due to their high cost, restricting their use in low-budget environmental applications. The device's purpose is to provide accurate data through low-cost sensors calibrated with neural networks.

The methodology involved constructing an experimental setup integrating low-cost and reference sensors, an Arduino UNO, and neural networks to adjust the readings to emulate high-precision equipment. A test capsule was designed to inject CO₂ in a controlled environment for data collection. The results revealed that, after neural network training, the low-cost sensors.

The project concludes that combining low-cost sensors with artificial intelligence algorithms can democratize access to environmental monitoring technologies, enabling their use in resource-constrained regions. Future work includes optimizing the neural network model and extending the system to other pollutant gases.

Keywords: *low-cost sensors, CO₂, neural network, Arduino, calibration.*

Glosario

Arduino UNO: Placa de desarrollo basada en el microcontrolador ATmega328P, ampliamente utilizada en proyectos electrónicos por su facilidad de uso y su capacidad para interactuar con diferentes sensores y actuadores.

Calibración: Proceso de ajuste y verificación de la precisión de un instrumento de medición, asegurando que sus lecturas sean consistentes y confiables frente a un estándar conocido.

Dióxido de Carbono (CO₂): Gas incoloro e inodoro compuesto por un átomo de carbono y dos de oxígeno, fundamental en procesos naturales como la fotosíntesis y considerado uno de los principales gases de efecto invernadero.

NDIR (Non-Dispersive Infrared): Tecnología utilizada en sensores para medir concentraciones de gases como el CO₂, basada en la absorción de luz infrarroja sin necesidad de dispersión.

Red Neuronal: Modelo computacional inspirado en el cerebro humano, compuesto por neuronas artificiales interconectadas que procesan información y aprenden patrones mediante entrenamiento.

Sensor de bajo costo: Dispositivo económico diseñado para medir una variable física o química, cuyo desempeño puede mejorarse mediante técnicas de calibración y procesamiento de datos.

Introducción

El presente proyecto aborda el diseño y desarrollo de un dispositivo inteligente que emule sensores de dióxido de carbono (CO₂) de alto costo utilizando sensores de bajo costo, con el objetivo de mejorar el acceso a tecnologías de monitoreo ambiental precisas. La necesidad de este trabajo surge de las limitaciones económicas que enfrentan muchas regiones y sectores al intentar implementar soluciones avanzadas para el control de gases contaminantes, como el CO₂, el cual desempeña un papel crucial en el cambio climático y la calidad del aire.

El proyecto se concibe como una solución integral que combina hardware económico y algoritmos de inteligencia artificial, específicamente redes neuronales, para calibrar las lecturas de sensores de bajo costo y hacerlas comparables a las de equipos de referencia. Para ello, se desarrolló un sistema experimental que incluye sensores, un Arduino UNO como plataforma de control, y un diseño específico de cápsula para pruebas controladas de inyección de gases.

La metodología aplicada incluyó etapas de diseño, implementación y validación, donde los datos recolectados de los sensores se procesaron mediante algoritmos entrenados en MATLAB® para ajustar la precisión de las mediciones. Una de las principales limitaciones encontradas fue la sensibilidad de los sensores de bajo costo a las condiciones ambientales, lo que hizo necesario realizar ajustes en las condiciones de prueba y la calibración continua del sistema.

A pesar de estas restricciones, los resultados obtenidos son prometedores y sientan las bases para futuras investigaciones y desarrollos en la implementación de tecnologías de monitoreo ambiental accesibles y confiables.

Estado del Arte

La medición precisa de dióxido de carbono (CO₂) es fundamental para el monitoreo ambiental y la mitigación del cambio climático. Diferentes estudios han explorado diversos enfoques tecnológicos, desde sistemas basados en vehículos aéreos no tripulados (UAVs), sensores de bajo costo, medición in situ desde aeronaves, hasta instrumentos avanzados de espectrometría. A continuación, se presenta un análisis de los principales métodos empleados, junto con sus ventajas y limitaciones.

Los UAVs han demostrado ser una herramienta eficaz para la cuantificación de emisiones, especialmente en entornos industriales complejos. El trabajo de Bonne et al. (2024) desarrolló un sistema basado en el espectrómetro AUSEA, el cual ofrece alta precisión en la medición simultánea de CO₂ y metano (CH₄) con frecuencia de muestreo de 24 Hz. Este sistema, montado en drones, proporciona datos en tiempo real permitiendo detectar fugas menores y medir emisiones puntuales y difusas en sitios industriales. Sin embargo, estos sistemas enfrentan desafíos relacionados con condiciones meteorológicas adversas y limitaciones en la autonomía de vuelo (Bonne et al., 2024).

Otro enfoque relevante es la medición in situ desde aeronaves, como se describe en el trabajo de Sun et al. (2020). Esta metodología permite capturar perfiles verticales de CO₂ y validar datos de satélites como el OCO-2. Las aeronaves ofrecen la ventaja de cubrir grandes áreas y proporcionar datos a diferentes altitudes, lo cual es crucial para mejorar los modelos atmosféricos. No obstante, su uso implica altos costos operativos y desafíos logísticos, lo que limita la frecuencia de estas campañas de medición (Sun et al., 2020).

Por otro lado, los sensores de bajo costo han ganado popularidad debido a su potencial para desplegar redes densas de monitoreo y mejorar la resolución espacial. Lin et al. (2023) evaluaron la eficacia de estos sensores para la medición de CH₄, destacando su sensibilidad a factores ambientales como temperatura y humedad. Sin embargo, estos sensores requieren calibraciones frecuentes para mantener su precisión y son susceptibles a interferencias de otros gases como el monóxido de carbono (CO) (Lin et al., 2023). Wang et al. (2024) demostraron que el uso de

algoritmos de aprendizaje automático, como la regresión lineal múltiple y los bosques aleatorios, puede mejorar la precisión de los sensores de bajo costo, ampliando su aplicabilidad en ambientes urbanos complejos (Wang et al., 2024).

Finalmente, el uso de espectrómetros avanzados en plataformas aéreas representa un enfoque de alta precisión. Staebell et al. (2021) describieron la calibración del instrumento MethaneAIR, que permite medir tanto CO₂ como CH₄ con alta resolución espectral desde aeronaves. Estos instrumentos proporcionan datos valiosos para identificar emisiones difusas y validar modelos atmosféricos, aunque su costo y complejidad técnica representan desafíos significativos (Staebell et al., 2021).

La medición de gases como el CO₂ en volúmenes variables ha sido un desafío constante para la ciencia, lo que ha dado lugar al desarrollo de diversas metodologías con el fin de mejorar la precisión, eficiencia y adaptabilidad a diferentes entornos. Las técnicas más modernas incluyen desde sistemas portátiles de espectrometría hasta métodos de dilución isotópica y sensores infrarrojos no dispersivos (NDIR). Estos enfoques varían en su complejidad, requerimientos de calibración y precisión, permitiendo su aplicación en contextos como la investigación atmosférica, agrícola y de ecosistemas controlados.

Uno de los avances más destacados es el uso de espectrómetros portátiles basados en espectroscopía de cavidad por anillo (CRDS), que permiten medir CO₂ y CH₄ directamente en campo, con la capacidad de trabajar en configuraciones de circuito cerrado para volúmenes menores a un litro. Estos sistemas ofrecen mediciones rápidas y precisas siempre que se utilicen buenas prácticas de inyección y calibración, alcanzando incertidumbres menores al 3% en condiciones ideales (Wilkinson et al., 2018). Otro método relevante es el empleo de cámaras de infrarrojos NDIR, que utilizan reflectores parabólicos para concentrar la luz y eliminar la necesidad de cámaras de gas tradicionales, simplificando su uso industrial y ofreciendo mediciones robustas y lineales en rangos de concentración superiores a 400 ppm (Vafaei et al., 2020).

Adicionalmente, se han desarrollado técnicas de análisis manométrico e isotópico que ofrecen alta precisión para determinar concentraciones bajas de CO₂ en muestras de aire. Por ejemplo, el

método de dilución isotópica ha demostrado ser capaz de medir CO₂ con una incertidumbre del 0,15% en muestras atmosféricas, lo que garantiza resultados fiables comparables a los métodos gravimétricos (Verkouteren & Dorko, 1989). Otra técnica relevante es la medición del CO₂ en frascos pequeños mediante sistemas de fuelles y analizadores de infrarrojos, logrando precisiones hasta $\pm 0,2$ mol/mol, lo que facilita su uso en investigaciones ecológicas y atmosféricas a escala local y global (Bowling et al., 2001).

En conclusión, los avances en la medición de CO₂ en volúmenes variables reflejan un progreso significativo hacia técnicas más precisas, portátiles y accesibles, aplicables en múltiples disciplinas científicas. La selección de un método específico depende de las condiciones ambientales, los requisitos de precisión y la complejidad del entorno operativo, con cada enfoque aportando ventajas particulares para la medición de gases en diferentes contextos.

Existen varios métodos avanzados para calibrar sensores de CO₂, cada uno enfocado en mejorar la precisión y adaptarse a distintos entornos. Una técnica destacada es la calibración mediante sensores NDIR sin cámara, la cual emplea reflectores parabólicos para mejorar la linealidad en las mediciones y reducir la deriva térmica, facilitando su uso industrial (Vafaei et al., 2020).

Otra metodología relevante es el uso de sensores con membranas de permeación para la autocalibración. Esta técnica minimiza la dependencia de condiciones ambientales y asegura respuestas estables mediante un estándar interno de gas, lo que reduce significativamente los errores (Lazik & Sood, 2016).

En contextos de múltiples sensores comerciales, como el proyecto Carbosense en Suiza, la co-localización de sensores con instrumentos de referencia ha demostrado ser eficaz para garantizar la precisión durante largos periodos. Sin embargo, se requieren filtros adicionales en entornos de alta humedad para mantener la calidad de los datos (Müller et al., 2020).

Finalmente, la calibración dinámica mediante modelado estadístico permite ajustar las mediciones en tiempo real, evitando esperas prolongadas para alcanzar el estado estacionario del

sensor. Esto mejora los tiempos de respuesta y asegura la precisión en cambios rápidos de concentración (Yang et al., 2013).

Además, encontramos la tesis "Calibración de sensores de bajo costo para el monitoreo ambiental de CO₂, NO₂ y SO₂ en una zona rural de la ciudad de Cienfuegos" aborda el problema de la contaminación atmosférica y el uso de sensores económicos para monitorear estos gases en regiones con recursos limitados. Se discute la clasificación de los contaminantes en primarios y secundarios, así como sus fuentes de emisión, como la actividad industrial y la quema de combustibles fósiles, que generan efectos adversos sobre la salud y el medio ambiente, especialmente en ciudades como Cienfuegos. Las normativas internacionales y cubanas sobre límites máximos permisibles son analizadas, aunque las normas locales no incluyen al CO₂, a pesar de su contribución al cambio climático. La tesis también describe los efectos nocivos de estos contaminantes en el sistema respiratorio humano, donde el NO₂ y SO₂ representan riesgos significativos.

La tesis destaca la implementación de sensores de bajo costo como alternativa a los métodos de referencia, explorando la viabilidad de su uso para el monitoreo ambiental en comunidades de bajos recursos. Se emplean sensores infrarrojos para el CO₂ y electroquímicos para NO₂ y SO₂, los cuales, aunque menos precisos que los equipos de referencia, son una opción económica y accesible. Además, se enfatiza la importancia de la calibración para mejorar la fiabilidad de los datos obtenidos por estos sensores, mediante técnicas como la calibración de cero, SPAN y multipunto, y comparaciones en condiciones controladas y en campo. (Rosa Amalia Gonzáles, 2022)

El documento "Uso de sensores electroquímicos de bajo costo para el monitoreo de la calidad del aire en el distrito de San Isidro - Lima, Perú" presenta un estado del arte sobre tecnologías de monitoreo de la calidad del aire, resaltando la importancia de alternativas económicas frente a estaciones fijas de alta precisión que resultan costosas. La creciente demanda por monitorear la calidad del aire, especialmente en zonas urbanas afectadas por altas concentraciones de contaminantes, ha impulsado el uso de sensores portátiles y de bajo costo. Estos sensores, aunque menos precisos que las estaciones convencionales, ofrecen una solución efectiva para ampliar la cobertura y mejorar la resolución espacial del monitoreo atmosférico. La metodología presentada

en el documento se enfoca en el uso de sensores electroquímicos para medir contaminantes clave, como CO₂, SO₂, NO₂ y compuestos orgánicos volátiles (COV), y utiliza algoritmos de inteligencia artificial para mejorar la precisión y confiabilidad de los datos obtenidos.

Además, el documento detalla el funcionamiento y las limitaciones de estos sensores, que requieren calibración frecuente y son sensibles a factores ambientales como la temperatura y la humedad. Se emplearon redes neuronales para predecir y validar concentraciones de contaminantes, utilizando modelos de aprendizaje automático como el algoritmo de Levenberg-Marquardt para ajustar y optimizar los datos obtenidos. Este enfoque permite predecir las concentraciones de gases en tiempo real, lo que facilita la toma de decisiones en gestión ambiental y control de calidad del aire. El estudio subraya la viabilidad de los sensores de bajo costo como complemento de las estaciones de monitoreo tradicionales, contribuyendo a una mayor accesibilidad en el monitoreo de la contaminación atmosférica en zonas urbanas y proporcionando datos útiles para medidas preventivas y legislativas en pro de la salud pública.(Ana Luna, Alvaro Talavera, Luis Cano, 2017).

1. Planteamiento del problema

1.2 Descripción

En primer lugar, el costo prohibitivo de los sensores de CO₂ de alta precisión dificulta su adquisición y despliegue en una escala amplia, especialmente en regiones con recursos limitados como en algunas áreas metropolitanas de Medellín. Esta limitación afecta directamente la capacidad de los investigadores, agencias gubernamentales y organizaciones ambientales locales para obtener datos precisos y actualizados sobre la concentración de CO₂, lo que a su vez perjudica la toma de decisiones informadas sobre políticas y acciones de mitigación en la región.

El área metropolitana de Medellín, caracterizada por su topografía montañosa y su densa población, enfrenta desafíos ambientales significativos relacionados con la calidad del aire. Sin embargo, la implementación de sensores de CO₂ de alta precisión es esencial para monitorear y mitigar los niveles de contaminación. La falta de acceso a estas tecnologías debido a su alto costo limita gravemente la capacidad de las autoridades locales para implementar estrategias efectivas de gestión ambiental y protección de la salud pública.

Además del costo, la complejidad técnica y los requisitos de mantenimiento especializado de los sensores convencionales representan otro desafío considerable. Estos dispositivos requieren calibración regular y atención meticulosa, lo que puede ser difícil de gestionar para organizaciones locales con recursos limitados o personal no especializado. En muchas regiones, donde las instituciones pueden carecer de los recursos necesarios para mantener una red de sensores complejos, esta complejidad técnica puede resultar en mediciones inexactas o inconsistentes, comprometiendo la fiabilidad de los datos recopilados y, por ende, la efectividad de las políticas de mitigación.

En resumen, el principal problema en muchas regiones del país es la falta de accesibilidad a tecnologías de monitorización de CO₂ precisas y asequibles, lo que obstaculiza la capacidad de comprender y abordar eficazmente los problemas ambientales relacionados con el CO₂.

1.3 Formulación

¿Cómo desarrollar un sistema inteligente que emule la respuesta de un sensor de CO₂ de alto costo para monitorear y controlar los niveles de dióxido de carbono en entornos interiores, considerando su relevancia en términos tecnológicos, científicos y prácticos?

2. Justificación

La importancia de abordar la falta de accesibilidad a tecnologías de monitorización de CO₂ en ciudades del país, radica en su impacto directo en la capacidad de comprender, abordar los problemas ambientales relacionados con este gas de efecto invernadero. Dado el crecimiento urbano y la actividad industrial en las regiones, es crucial contar con datos precisos y actualizados sobre las concentraciones de CO₂ para informar la toma de decisiones en políticas y acciones de mitigación ambiental.

La justificación de este problema se fundamenta en la necesidad de democratizar el acceso a la monitorización ambiental, garantizando que tanto organizaciones como investigadores y agencias gubernamentales tengan la capacidad de obtener datos confiables sobre el CO₂, independientemente de sus recursos financieros o técnicos. Al superar las barreras económicas y técnicas asociadas con los sensores convencionales, se facilita la implementación de estrategias efectivas de gestión y mitigación ambiental, promoviendo así un enfoque más informado y sostenible hacia la protección del medio ambiente.

3.Objetivos

3.1 Objetivo general

Desarrollar un sistema inteligente basado en sensores infrarrojos de alto costo para que emule la detección precisa de dióxido de carbono mediante sensores de bajo costo electroquímicos para aplicaciones ambientales.

3.2. Objetivos Específicos

- Diseñar y construir un prototipo para alojar los sensores que realizan la detección de CO₂
- Implementar un sistema de adquisición y procesamiento de datos
- Validar el funcionamiento del sensor en condiciones controladas y reales
- Analizar los datos recopilados para identificar patrones y niveles críticos de CO₂

4.

Marco teórico

4.1. Antecedentes de la Monitorización de CO2

La monitorización de CO2 es una práctica esencial para evaluar la calidad del aire y comprender el impacto de las emisiones de gases de efecto invernadero en el medio ambiente como se observa en la figura 1. Se han desarrollado diversos métodos para la monitorización de CO2, incluyendo:

- **Sensores de infrarrojos no dispersivos (NDIR):** Estos sensores son ampliamente utilizados debido a su precisión y confiabilidad. Sin embargo, pueden ser costosos y requerir mantenimiento especializado.

- **Espectrometría de masas:** Esta técnica ofrece una alta precisión y la capacidad de detectar una amplia gama de gases, pero también es costosa y compleja.

- **Sensores ópticos:** Estos sensores son emergentes y ofrecen una alternativa rentable y fácil de usar a los sensores convencionales. Sin embargo, aún se encuentran en desarrollo y pueden tener limitaciones en cuanto a precisión y rango de detección.



Figura 1: Ejemplo de dispositivo de monitorización de CO2 utilizado en áreas urbanas

(Fuente: https://www.draeger.com/es_mx/Safety/FGDS-CovidPrevention)

4.1.2 Experiencias en el área metropolitana

En el área metropolitana de Medellín se han realizado diversos proyectos y estudios relacionados con la calidad del aire y el monitoreo de CO₂ en los lugares que muestra la figura 2. Algunos ejemplos incluyen:

Proyecto de Calidad del Aire Urbano (2008-2012): Este proyecto, implementado por la Alcaldía de Medellín y el Área Metropolitana del Valle de Aburrá, estableció una red de estaciones de monitoreo de la calidad del aire en la región.

Estudio de Emisiones de CO₂ del Sector Transporte en Medellín (2016): Este estudio, realizado por la Universidad de Antioquia, estimó las emisiones de CO₂ del sector transporte en la ciudad.

Red de Monitoreo Ambiental Comunitario (2020): Esta red, impulsada por organizaciones ambientalistas y comunitarias, utiliza sensores de bajo costo para monitorear la calidad del aire en diferentes barrios de la ciudad .

Estos proyectos y estudios han proporcionado información valiosa sobre la calidad del aire en el área metropolitana de Medellín y han identificado la necesidad de fortalecer las estrategias de monitoreo de CO₂ ya que en la figura 3 se ven los valores en los que la calidad del aire no es tan buena.

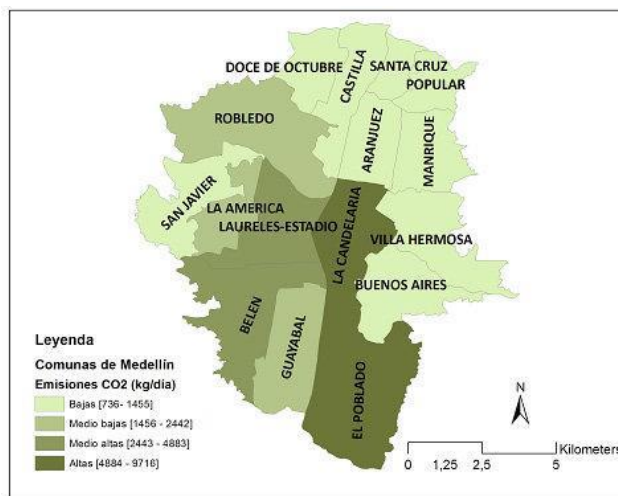
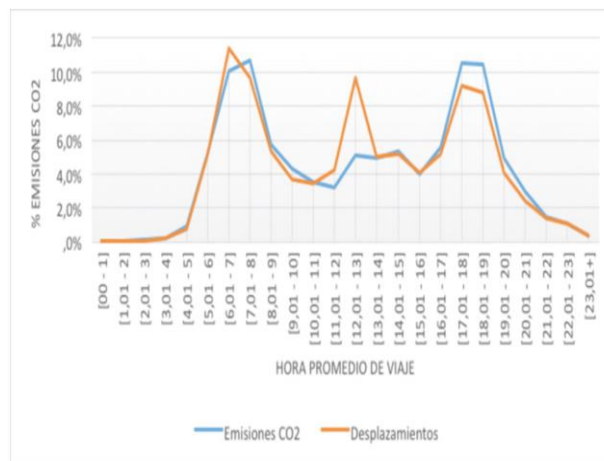


Figura 2: Distribución territorial de las emisiones de CO₂. (a) AMVA (b) Comunas de Medellín.

(Fuente: Bedoya, V. R., Marquet, O., & Miralles-Guasch, C. (2016). Estimación de las emisiones de CO₂ desde la perspectiva de la demanda de transporte en Medellín. ResearchGate)



Distribución de CO2 de acuerdo con la hora promedio de desplazamiento. Fuente: Elaboración propia.

Figura 3: Distribución de CO2 de acuerdo con la hora promedio de desplazamiento.

(Fuente: Bedoya, V. R., Marquet, O., & Miralles-Guasch, C. (2016). Estimación de las emisiones de CO2 desde la perspectiva de la demanda de transporte en Medellín. ResearchGate)

4.2. Principios físicos para la construcción de sensores de gases.

Desde hace varios años, la tecnología de los sensores de gas como los electroquímicos y semiconductores, han tomado gran importancia en la química analítica y en algunos otros campos de la investigación, además del desarrollo para la detección de gases nocivos en el ambiente, caracterizándose por el fácil uso y bajo costo.

4.2.1. Gases: Conceptos básicos

En el estudio, la aplicación y medición de los gases, debe de aplicarse la teoría que describe su comportamiento, en este orden de ideas partimos de que las moléculas de los gases se mueven continuamente debido a la temperatura. Cuanto mayor sea la temperatura, con más velocidad se moverán las moléculas. La escala en la que se mide la temperatura es una escala que no tiene valores negativos y se conoce como escala Kelvin, o escala absoluta. No hay valores por debajo de cero Kelvin. La temperatura de un gas debe medirse siempre en esta escala.

Las moléculas de gas ocupan un volumen y en él se mueven y desplazan, por razones prácticas el volumen de un gas se mide en litros (L). El sistema internacional (SI) tiene como unidad el metro cúbico (m³), un m³ contiene 1000 L.

Debido al movimiento de las moléculas del gas estas chocan entre sí, y por lo tanto ejercerán una presión que es el producto del área por la distancia. Esta presión en el sistema internacional se expresa en Pascales (Pa). En el manejo de gases atmosféricos el clima cambiará dependiendo de la presión, es común entonces que esta se expresa en atmósferas (atm) o en bares (b).

Las mezclas de gases se acercan a los gases ideales siempre que las presiones de estos estén cerca de una atmósfera y la temperatura no sean demasiado bajas. Por lo tanto, se consideran las siguientes suposiciones: Las moléculas de gas no ocupan volumen y las moléculas no tienen atracciones intermoleculares, es decir, su interacción es independiente del gas. Según lo anterior cada gas tiene una presión conocida como presión parcial, calculada con la de la ley de los gases ideales, ecuación 1, y esta presión contribuye a la presión total de la mezcla de los gases. (Polo Diez, 2015)

$$PV = nRT \quad (1)$$

En donde:

P: Presión parcial del gas que hace parte de la mezcla

V: Volumen del recipiente que contiene la mezcla

n: número de moles del gas que aporta a la mezcla

R: constante universal de los gases

T: temperatura de la mezcla de gases.

La presión total ejercida por una mezcla de gases es la suma de las presiones parciales de los gases componentes, que se conoce como la ley de Dalton de las presiones parciales. Ecuación 2

$$P_{total} = P_{gas1} + P_{gas2} + P_{gas3} \quad (2)$$

Otra forma de expresar la presión parcial es mediante la fracción molar (x_1), que expresa la relación entre el número de moles del gas y el número de moles del gas total por la presión total de la mezcla de gases. Ecuación 3

$$P_{gas1} = x_1 P_{total}(3)$$

Las expresiones (2), (3), son formas de expresar la ley de Dalton y son útiles cuando se conocen la relación molar y la presión total, las presiones parciales de todos los gases, el cálculo del número de moles si se conoce la presión parcial y la presión total. (Polo Diez, 2015)

Cuando hay una mezcla de gases una de las propiedades principales es la presión parcial de los gases que lo constituyen, la concentración es otra de ellas. Son diversas las unidades para expresarla, una de ellas es el porcentaje de volumen por volumen (% v/v) o partes por millón (ppm) unidad referida a su volumen, es decir, ml del gas X1 respecto a m³ de la mezcla, o sea que relaciona el volumen de una cantidad determinada con respecto al volumen de cada millón de unidades de mezcla, debe tenerse en cuenta que esta proporción depende de la temperatura y presión de la mezcla. Otras unidades son; mg/L, g/m³ y µg/mL

4.2.2. Sensores para la detección y medición de gases

Un sensor es un dispositivo de entrada - salida que produce un cambio en la salida ante un estímulo físico o químico en la entrada. La señal de salida es medible y generalmente proporcional al estímulo de entrada. Un sensor es también un transductor de energía y con respecto a esta, ellos pueden ser radiantes, mecánicos, térmicos, magnéticos, y electroquímicos. Es prolífica la variedad de tipos de sensores dentro de cada categoría. En la figura 1 puede observarse una clasificación de los sensores según la plataforma de sensado. La plataforma o estructura que convierte la reacción entre la especie de gas con elemento de la estructura que hace la detección en una señal eléctrica, definen la tecnología y por lo tanto el tipo del sensor. En los sensores de gases las plataformas más comunes son electrónicas y electroquímicas, con tecnologías de detección basadas en semiconductores de óxido metálico y celdas electroquímicas respectivamente plataformas de sensores, gama de tipos de sensores, opciones de medición que pueden resultar del uso de estas plataformas como se muestra en la figura 4 nos da la descripción de que material usa y el gas que detecta con mayor selectividad.

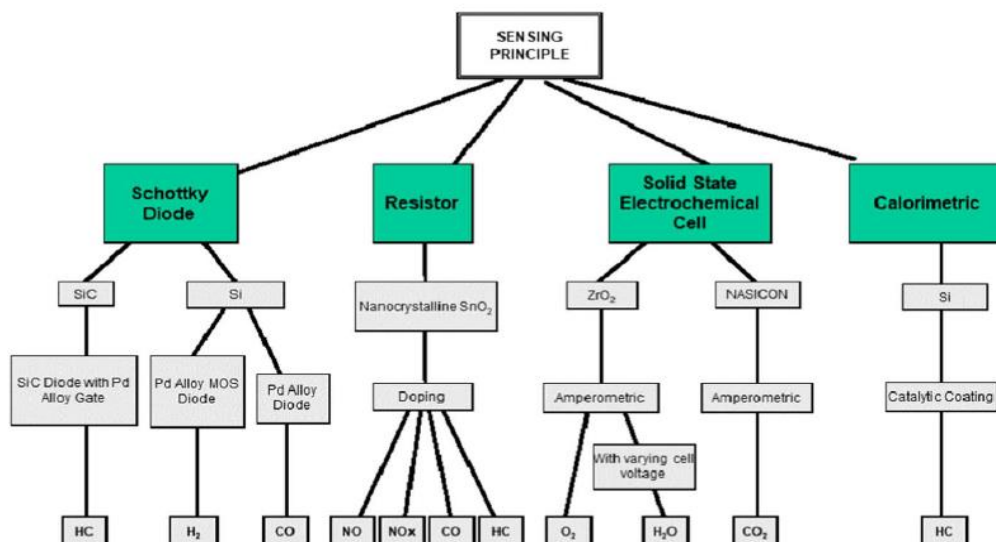


Figura 4: La figura muestra la plataforma, el material usado para su construcción y el gas que detecta con mayor selectividad.

Fuente: (Gary W, 2020)

4.2.3. Sensores de gas con plataforma electroquímica.

Los sensores electroquímicos se han utilizado ampliamente en la detección química (gases) y bioquímica. Un sensor electroquímico es una celda electroquímica, contiene una configuración de dos o tres electrodos y un electrolito. En el sistema de dos electrodos el sensor contiene un electrodo de trabajo (sensor) y un contraelectrodo (Referencia), (Figura 5). Los sensores electroquímicos más comunes para la detección de gases son los de electrolito de fase sólida y fase líquida. La reacción electroquímica ocurre en la superficie del electrodo de trabajo que entra en contacto con el gas, esta reacción puede ser una oxidación o una reacción de reducción que hace que el electrodo de trabajo sea un ánodo o un cátodo, respectivamente. (Gary W, 2020)




Figura 5: Ilustración esquemática de un sensor de oxígeno Alphasense configuración de dos electrodos y un electrolito.

Fuente: (Gary W, 2020)

Nota. La figura muestra la composición física de los sensores electroquímicos y como se convierte en un transductor al conectar una resistencia externa que entrega un voltaje proporcional a la especie de gas que incide en la superficie de capilaridad. Fuente: (Alphasense, 2017).

En el diagrama esquemático del sensor de oxígeno de la figura 6, se infiere que se genera una corriente por la resistencia de carga colocada entre el electrodo de trabajo y el de referencia, son dos pines del sensor, ver figura 3, la cual es proporcional a la tasa de consumo de oxígeno. El valor de resistencia de carga suele estar entre 10 y 100 Ω ; una resistencia baja da como resultado una pequeña caída de voltaje que es difícil de medir y una resistencia alta impone un voltaje en el ánodo y el cátodo que puede causar reacciones secundarias desfavorables.




Figura 6: Sensor de oxígeno Alphasense de alto costo.

(Alphasense, 2017).

Nota. La figura muestra las características dimensionales y de ubicación del pinado de los sensores Alphasense. Fuente: (Alphasense, 2017).

Los tipos de sensores que son construidos con esta tecnología son sensores de amoníaco (NH_3), Dióxido de Carbono (CO_2), monóxido de carbono (CO), Cloro (Cl_2), Ácido sulfhídrico (H_2S), Metano (CH_4), Cianuro de hidrógeno (HCN), dióxido de Nitrógeno (NO_2) etc. Varios de estos

sensores tienen sensibilidad cruzada con otros gases y por lo tanto el fabricante especificará el porcentaje de proporción de esa sensibilidad.

4.2.4. Sensores de gas de plataforma de Óxidos metálicos electrónicos (MOGS)

Sensores de gas de óxido de metal de tipo resistivo son generalmente de bajo costo, de bajo consumo, portátiles y altamente estables, pero principalmente sufren de poca selectividad. Los materiales de óxido de metal sensibles al gas de detección pueden ser de tipo n o tipo p. El método más prometedor para aumentar la selectividad en MOGS es mezclar el material de detección de óxido de metal primario con otro óxido de metal, catalizador de metal noble, polímero o nanotubos de carbono. (Gary W, 2020).

El mecanismo de detección de esta plataforma se basa en el intercambio de electrones entre el gas objeto de detección (analito) y la superficie del material del sensor por quimisorción (adsorción del gas) o reacción catalítica, es decir, la interacción entre la capa porosa sensible al gas y el gas objetivo, provoca un cambio en la resistencia eléctrica de la capa porosa. Las capas sensibles al gas están serigrafiadas en un chip de alúmina, que comprende un calentador integrado y un patrón de electrodo. (Alphasense, 2019).

La concentración cambiante del portador de carga se puede medir simplemente como un cambio de resistencia respecto al tiempo en el momento que el material del sensor crea una ruta de corriente a través de un espacio entre electrodos. El rendimiento de los sensores de óxido de metal depende en gran medida de la temperatura de funcionamiento. Cuando el sensor está en uso, estará expuesto a variaciones en el caudal y las condiciones ambientales. Sin un control de temperatura adecuado, el sensor puede desviarse de su temperatura de funcionamiento óptima, lo que resulta en un cambio, tanto en la resistencia de referencia como en la sensibilidad al gas. (Alphasense, 2019).

El rango de aplicación de gases para esta plataforma es limitado debido a que, si la concentración del gas objetivo aumenta, igual lo hace la resistencia del sensor. Para la mayoría de

los gases, la concentración del gas tiene una relación no lineal con la resistencia del sensor. Puede verse una relación lineal para este sensor con los gases H₂S, CO y VOCs (compuestos orgánicos volátiles), mientras se mantenga controlada la temperatura. El sensor para este tipo de plataforma es un óxido de metal de tipo resistivo que utiliza un divisor de potencial. (Alphasense, 2019). Una disposición esquemática simple del circuito de sensado se muestra en la figura 7.




Figura 7: Circuito demostrativo del sensado de sensor de gases MOGS.

Fuente:(Alphasense,2019)

Nota. La figura muestra cómo se construye el divisor de tensión resistivo de los Sensores de gas de plataforma de Óxidos metálicos electrónicos Fuente: (Alphasense, 2019).

Un valor de R1 entre 100 y 200 k Ω y un voltaje aplicado V+ inferior a 1 V sería típico. La salida de este circuito puede amplificarse y filtrarse antes de medirse, con el ajuste necesario para la aplicación específica prevista y el rango de concentración de gas.

4.2.5. Redes neuronales

Las Redes Neuronales son un campo dentro de la Inteligencia Artificial que se inspira en las conexiones entre neuronas del cerebro humano, intentando crear modelos artificiales que emplean técnicas algorítmicas convencionales para hallar la solución de un problema en particular. Las redes neuronales son, en síntesis, unidades de procesamiento que intercambian datos o información y que se utilizan para reconocer patrones, como, por ejemplo, la tendencia que podría tener la medición de un gas por un sensor de bajo costo. Tienen la capacidad de aprender y mejorar su funcionamiento. (Jianli , Shengnan. 2019)

El modelo de neurona artificial consta básicamente de un conjunto de entradas de un número determinado de componentes, en forma de vector, que genera una única salida. Existe, además, un

conjunto de pesos sinápticos que representan la interacción entre las neuronas presináptica y postsináptica. La regla de propagación brinda el potencial post sináptico y la función de activación proporciona el estado de activación de la neurona en función del estado anterior y del valor postsináptico. Finalmente, la función de salida se obtiene a partir del estado de activación.

Una red neuronal artificial (RNA), ver figura 8, está compuesta por nodos (elementos del proceso) y conexiones. Cada nodo posee una función de transferencia. Las entradas son externas y las salidas se obtienen a partir de las conexiones salientes de la RNA. Una RNA posee una determinada estructura que permite visualizar cómo son las conexiones sinápticas de la red. Las neuronas suelen agruparse en capas, una de entrada, la cual recibe los datos del entorno; otra de salida, que proporciona la respuesta de la red a los estímulos de la entrada y capas ocultas que forman parte del procesamiento interno de la red y no tienen contacto directo con el entorno exterior.




Figura 8: Esquema de una red neuronal artificial.

Fuente: (Topalović, Davidović.2019)

Nota. La figura muestra la estructura de una neurona, con sus nodos (capa cada nodo de cada capa interconecta cada nodo de la siguiente capa. Puede observarse que la salida y_0 es una combinación lineal de las entradas.

4.2.5.1. Aprendizaje de una red neuronal

El proceso de aprendizaje de una RNA consiste en actualizar los pesos a través de algoritmos de aprendizaje, que es un procedimiento numérico de ajuste de pesos con el fin de minimizar el error cometido. Existen diferentes métodos de entrenamiento como el de retropropagación con el algoritmo de Levenberg-Marquardt. Para el cual los patrones para el aprendizaje y las pruebas se pueden tomar del conjunto de datos de entrenamiento. Cuando se finaliza el proceso de entrenamiento, se debe comprobar si la red neuronal puede resolver el problema que se desea solucionar; es decir, se busca validar el resultado obtenido. (Jianli , Shengnan. 2019)

Para ello, se requiere de otro conjunto de datos, denominado conjunto de validación o testeo. Cada ejemplo del conjunto de evaluación contiene los valores de las variables de entrada, con su correspondiente solución tomada; pero la solución no se le otorga a la red neuronal. Finalmente se compara la solución estimada por la red con la real concluyendo con el proceso de validación.

Para evaluar el desempeño de la red puede usarse indicadores como el error porcentual absoluto medio, MAPE (Mean Absolute Percentage Error), ecuación 4, que mide el tamaño del error (absoluto) en términos porcentuales.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|x_i - \bar{x}_i|}{|x_i|} \quad (4)$$

Siendo N el número total de valores; x_i y \bar{x}_i los valores reales y previstos por la red respectivamente.

Otra forma de poderse evaluar el desempeño es mediante el empleo de la raíz del error cuadrático medio o RMSE (Root Mean Squared Error), la cual es una medida de desempeño cuantitativa utilizada para evaluar métodos de pronóstico. Este es un estimador que mide el promedio de los errores al cuadrado, es decir, la diferencia entre el estimador y lo que se estima, evaluando la calidad de un conjunto de predicciones en cuanto a su variación y el grado de sesgo. (Topalović, Davidović.2019).

La expresión para el cálculo del RMSE se muestra en la ecuación 5.

$$RMSE = \sqrt{\frac{\sum (x_i - \bar{x})^2}{2N}} = 1 \quad (5)$$

4.2.5.2. La función de activación

La función de activación de salida para salidas analógicas debe ser del tipo lineal con una pendiente determinada por un valor K constante o variable si se desea que ésta cambie; está pendiente está determinada por los valores de umbral de la rampa. En algunos casos se requiere que la respuesta de una neurona artificial sea en forma continua y lineal desde un nivel mínimo hasta un valor máximo de saturación, dependiendo de un nivel de umbral \square que casi siempre en este caso se fija en cero. Sin funciones de activación, las salidas pueden ser cualquier cosa en el rango $[-\text{Inf}, +\text{Inf}]$, por lo que las neuronas realmente no conocen los límites del valor.

Usualmente este tipo de función de activación, ver figura 9, se emplea para resolver problemas linealmente separables, en donde se puedan agrupar sus respuestas en forma lineal. Generalmente el valor más alto que puede tomar linealmente es 1, y el más bajo puede ser 0 o -1. (Jianli, Shengnan, 2019)




Figura 9: Función de activación lineal.

Fuente: (https://www.researchgate.net/figure/Figura-1-Funciones-de-activacion-a-Funcion-logistica-o-LogSig-b-Funcion-Gaussiana-o_fig1_38320164), tomado 05/04/2022

Nota. La figura muestra la función lineal con los intervalos de activación posibles.

4.2.6. Teorías de cambio climático

El cambio climático es un fenómeno complejo causado por la emisión de gases de efecto invernadero, como el CO₂, a la atmósfera. Estas emisiones atrapan el calor del sol y provocan el calentamiento global. El calentamiento global tiene una serie de impactos negativos en el planeta, incluyendo el aumento del nivel del mar, eventos climáticos extremos y cambios en los patrones de precipitación.

4.2.7. Teorías de la Calidad del Aire

La calidad del aire se refiere a la condición del aire que respiramos. La contaminación atmosférica, causada por la emisión de contaminantes como el CO₂, puede tener graves efectos en la salud humana, incluyendo enfermedades respiratorias, enfermedades cardíacas y cáncer.

Esta estructura proporciona una base sólida para comprender el contexto y las teorías detrás del proyecto de monitorización de CO₂ en el Área Metropolitana de Medellín, permitiendo una integración efectiva de la literatura existente en el estudio propuesto.

4.3. Tecnologías de Monitorización de CO₂

4.3.1. Sensores Convencionales

Los sensores convencionales de CO₂, como los sensores de infrarrojos no dispersivos (NDIR), son ampliamente utilizados debido a su precisión y confiabilidad. Estos sensores funcionan midiendo la absorción de luz infrarroja por las moléculas de CO₂.

4.3.2. Tecnologías Emergentes

Las tecnologías emergentes para la monitorización de CO₂ ofrecen alternativas rentables y fáciles de usar a los sensores convencionales. Algunas de estas tecnologías incluyen:

Sensores ópticos: Estos sensores utilizan principios físicos como la fluorescencia o la resonancia plasmónica para detectar CO₂.

Sensores electroquímicos: Estos sensores funcionan midiendo la reacción química entre el CO₂ y un electrodo.

Sensores basados en MEMS: Estos sensores utilizan microfabricación para crear dispositivos miniaturizados para la detección de CO₂.

Las tecnologías emergentes aún se encuentran en desarrollo y pueden tener limitaciones en cuanto a precisión y rango de detección. Sin embargo, ofrecen un gran potencial para mejorar la accesibilidad y la escalabilidad del monitoreo de CO₂.

4.4. Conceptos clave

4.4.1. Calidad del Aire

La calidad del aire se refiere a la condición del aire que respiramos. La contaminación atmosférica, causada por la emisión de contaminantes como el CO₂, puede tener graves efectos en la salud humana, incluyendo enfermedades respiratorias, enfermedades cardíacas y cáncer.

4.4.2. Mitigación del Cambio Climático

La mitigación del cambio climático se refiere a las acciones que se toman para reducir las emisiones de gases de efecto invernadero y evitar los peores impactos del cambio climático. Estas acciones pueden incluir:

Reducción del uso de combustibles fósiles: Esto se puede lograr mediante el uso de fuentes de energía renovables, como la energía solar y eólica, y la mejora de la eficiencia energética.

Protección de los bosques: Los bosques absorben CO₂ de la atmósfera, por lo que su protección es importante para mitigar el cambio climático.

Desarrollo de tecnologías bajas en carbono: Se necesitan nuevas tecnologías para reducir las emisiones de CO₂ de sectores como la industria, el transporte y la agricultura.

4.5 Bases Teóricas

4.5.1 Estado Gaseoso y Comportamiento de los gases

Los gases, debido a la débil fuerza de atracción entre sus moléculas, presentan una disposición altamente desordenada en el espacio y pueden llenar completamente el volumen de un recipiente (Atkins & de Paula, 2018). Además, son capaces de comprimirse y expandirse fácilmente en respuesta a cambios en la presión y temperatura. Esta capacidad de adaptarse a diversas condiciones es esencial en aplicaciones donde se requiere control de gases para procesos industriales y de investigación.

Por ejemplo, en la detección de gases en la industria alimentaria, el control del dióxido de carbono (CO_2) es fundamental para mantener la calidad y seguridad de ciertos alimentos (González et al., 2020). El CO_2 es un gas triatómico que, en concentraciones controladas, puede ayudar a preservar productos, pero a niveles elevados o en espacios confinados puede ser peligroso (Bertolini et al., 2021). Su comportamiento no ideal bajo condiciones de alta presión lo convierte en un gas que debe ser monitoreado con precisión.

4.5.2 Gases Reales vs. Ideales

El modelo de gas ideal es una aproximación útil para simplificar el estudio de los gases en condiciones normales de presión y temperatura. Sin embargo, en condiciones extremas (como altas presiones o bajas temperaturas), los gases reales presentan interacciones intermoleculares que los alejan de este modelo (Silbey et al., 2019). Estas interacciones, conocidas como fuerzas de Van der Waals, afectan las propiedades de los gases y requieren modelos más complejos para predecir su comportamiento.

El comportamiento no ideal del CO_2 , debido a sus interacciones intermoleculares, es un aspecto a considerar en proyectos que involucren sensores de gas (Ortiz & Molina, 2022). La variabilidad de sus propiedades bajo diferentes condiciones ambientales afecta la precisión de los sensores y la interpretación de los datos. Es aquí donde el uso de sensores avanzados o calibración con redes neuronales puede mejorar la precisión en la medición del CO_2 .

4.5.3 Propiedades de los Gases

Los gases se distinguen de otros estados de la materia por varias propiedades específicas: expansibilidad, compresibilidad, baja densidad, fluidez y difusión. Estas características son fundamentales para entender su comportamiento en distintos contextos y aplicaciones tecnológicas.

Expansibilidad y Compresibilidad

A diferencia de sólidos y líquidos, los gases no tienen forma ni volumen fijos. Pueden expandirse para llenar completamente el volumen de un recipiente debido a que sus moléculas están en movimiento constante y tienen una disposición muy dispersa. Esta característica es crucial para su uso en sensores y dispositivos de medición, ya que permite que los gases lleguen a todas las partes de un sensor de manera uniforme (Atkins & de Paula, 2018). Además, los gases son altamente compresibles, lo que significa que al aplicarles presión, su volumen disminuye significativamente. Este principio es aprovechado en diversas aplicaciones industriales, como en cilindros de gas comprimido utilizados en entornos industriales y de salud (Silbey et al., 2019).

Baja Densidad

La densidad de un gas es considerablemente menor que la de los sólidos o líquidos, debido a la gran distancia entre sus moléculas. Esta baja densidad facilita el movimiento de moléculas de gas en el espacio, lo que permite que estos se mezclen fácilmente con otros gases y reaccionen rápidamente en procesos químicos (Levine, 2017). En aplicaciones prácticas, esta propiedad es importante en procesos de ventilación y aireación, donde se requiere una rápida difusión de gases para asegurar la calidad del aire en espacios cerrados (Bertolini et al., 2021).

Fluidez

Los gases son extremadamente fluidos debido a las fuerzas intermoleculares débiles y a la gran cantidad de espacio entre las moléculas. Esta característica facilita su manejo y transporte en tuberías y conductos, lo que es esencial para procesos industriales y sistemas de distribución de gas (Bates, 2020). Por ejemplo, el dióxido de carbono en procesos de fermentación debe ser controlado y transportado eficientemente para evitar concentraciones peligrosas y mantener la seguridad en el entorno de trabajo (Hernández & Ponce, 2020).

Difusión y Eficiencia en la Mezcla

La difusión es una propiedad que describe cómo las moléculas de un gas se mezclan espontáneamente con las de otro gas hasta alcanzar una distribución uniforme. Esta característica es fundamental para su uso en sistemas de detección de gases, como el monitoreo de calidad del aire, ya que permite que las moléculas de gas lleguen rápidamente al sensor, lo que proporciona mediciones precisas en tiempo real (González et al., 2020). La difusión de los gases también es aprovechada en el análisis de contaminantes en el aire y en la evaluación de la concentración de gases en ambientes industriales (Ortiz & Molina, 2022).

Estas propiedades colectivamente hacen que los gases sean ideales para aplicaciones en detección y análisis en la industria, particularmente en contextos donde se requiere monitoreo continuo de gases, como el CO₂ en espacios de producción y almacenamiento de alimentos. Además, son la base para los principios que rigen el comportamiento de gases ideales y reales, proporcionando fundamentos teóricos que permiten calcular y predecir su comportamiento en diferentes condiciones (Atkins & de Paula, 2018; Silbey et al., 2019).

4.5.4 Clasificación de los Gases según su Naturaleza Química

Los gases se pueden clasificar en diferentes categorías de acuerdo con sus propiedades químicas, lo que permite entender mejor su comportamiento, sus aplicaciones y los riesgos asociados a su manipulación. A continuación, se presentan las principales categorías:

Gases Inertes o Nobles

Estos gases no reaccionan fácilmente con otras sustancias debido a su configuración electrónica estable. Los gases inertes, también llamados gases nobles, incluyen elementos como el helio, neón, argón, kriptón, xenón y radón. Su principal aplicación está en entornos donde se necesita un ambiente sin reacciones químicas, como en procesos de soldadura y en atmósferas protectoras para la conservación de alimentos y documentos (Atkins & de Paula, 2018). Los gases nobles son fundamentales en industrias que requieren alta pureza, como la electrónica y la investigación científica (Levine, 2017).

Gases Oxidantes

Los gases oxidantes son aquellos que, si bien no son combustibles por sí mismos, facilitan la

combustión de otras sustancias. El oxígeno es el gas oxidante más común, esencial para la respiración y para muchos procesos industriales, como la metalurgia y la producción de compuestos químicos. Otros ejemplos de gases oxidantes son el ozono y los óxidos de nitrógeno, que se utilizan en el tratamiento de aguas y en aplicaciones desinfectantes (Bertolini et al., 2021). Estos gases requieren medidas de seguridad especiales, ya que pueden incrementar el riesgo de combustión al mezclarse con materiales inflamables (Silbey et al., 2019).

Gases Combustibles

Los gases combustibles, como el metano, el propano, el hidrógeno y el butano, son altamente inflamables y liberan grandes cantidades de energía en forma de calor al quemarse en presencia de oxígeno. Estos gases se utilizan ampliamente como fuentes de energía en la industria, el transporte y los hogares (Hernández & Ponce, 2020). Sin embargo, también representan un riesgo significativo de explosión y deben manejarse con precaución en condiciones controladas, especialmente en espacios cerrados donde se acumula el gas (González et al., 2020).

Gases Tóxicos

Los gases tóxicos, como el monóxido de carbono, el dióxido de azufre y el cloro, pueden ser peligrosos para la salud humana incluso en concentraciones bajas. Estos gases se encuentran comúnmente en procesos industriales y son subproductos de la combustión y la producción química. La exposición a gases tóxicos puede provocar efectos adversos para la salud, desde irritaciones leves hasta daños severos en los sistemas respiratorio y nervioso (Ortiz & Molina, 2022). Los gases tóxicos requieren equipos de detección específicos para monitorear su presencia y prevenir riesgos para la salud en el lugar de trabajo (Bates, 2020).

Gases Corrosivos

Los gases corrosivos, como el amoníaco, el cloro y el ácido clorhídrico en estado gaseoso, pueden reaccionar agresivamente con otros materiales y causar daño tanto a tejidos biológicos como a estructuras industriales. Estos gases se emplean en la industria química, en refrigeración y en la manufactura de productos de limpieza. Sin embargo, su manipulación requiere de equipo de protección y ventilación adecuada debido a sus efectos irritantes y potencialmente dañinos (Silbey et al., 2019).

¿Qué es el CO₂?

El dióxido de carbono (CO₂) es un gas incoloro e inodoro que consiste en un átomo de carbono unido a dos átomos de oxígeno mediante enlaces covalentes. Este gas es un componente natural de la atmósfera terrestre y es esencial para el ciclo de vida de los seres vivos. El CO₂ es un subproducto de la respiración de animales y humanos y es absorbido por las plantas durante la fotosíntesis, donde se transforma en oxígeno, contribuyendo así al equilibrio ecológico (Smith & Smith, 2020). También se libera durante la combustión de materiales orgánicos como el petróleo, el carbón y el gas natural, y su aumento en la atmósfera se ha asociado al cambio climático debido a su efecto invernadero, que atrapa calor y eleva la temperatura global (Pachauri et al., 2018).

En aplicaciones industriales, el CO₂ se utiliza en la fabricación de bebidas carbonatadas, extintores de incendios y en la industria de alimentos para refrigeración y conservación. Sin embargo, en altas concentraciones en espacios confinados, puede ser tóxico y perjudicial para la salud humana, causando síntomas como dolor de cabeza, náuseas e incluso asfixia (González & Torres, 2021).

Arduino UNO

La placa Arduino UNO es ampliamente recomendada para aquellos que se inician en la programación y la electrónica, siendo la opción más robusta, documentada y usada dentro de la familia de dispositivos Arduino (Arduino, n.d.). Esta placa se basa en el microcontrolador ATmega328P y cuenta con 14 pines de entrada/salida digital, de los cuales 6 se pueden usar con modulación de ancho de pulso (PWM), 6 entradas analógicas, un cristal de 16 MHz, un conector USB, un conector jack de alimentación, terminales para ICSP y un botón de reseteo (Monk, 2021).

La placa Arduino UNO ver figura 10, permite la interacción con el entorno a través de sus pines de entrada y salida (E/S), los cuales se dividen en digitales y analógicos:

1. **Entradas y salidas digitales.** La placa cuenta con 14 pines digitales numerados del 0 al 13, los cuales pueden configurarse como entradas o salidas digitales para operar a 5V, proporcionando o recibiendo hasta 40 mA (Arduino, n.d.). Los pines PWM (3, 5, 6, 9, 10 y 11)

permiten la modulación del ancho de pulso, lo que simula una salida analógica útil para el control de la velocidad de motores o el brillo de LEDs.

2. **Entradas analógicas.** Los pines A0 a A5 permiten la lectura de señales de sensores analógicos con voltajes entre 0 y 5V, con una resolución de 10 bits, dividiendo el voltaje en 1024 niveles (Monk, 2021).

3. **Pines de potencia.** La placa ofrece pines de 5V y 3.3V para la alimentación de componentes externos y varios pines de GND (tierra) que sirven como referencia de voltaje negativo (Arduino, n.d.).

4. **Pines especiales.** El pin RESET reinicia el microcontrolador, el pin AREF define una referencia de voltaje externa para las entradas analógicas, y los pines RX y TX (0 y 1, respectivamente) son usados para la comunicación serial, facilitando la depuración y carga de programas a través del puerto USB (Arduino, n.d.; Monk, 2021).




Figura 10: Placa de Arduino.

Fuente: (Arduino.cc)

¿Qué es una Red Neuronal?

Una red neuronal es un modelo computacional inspirado en la estructura y funcionamiento del cerebro humano, compuesto por neuronas interconectadas. Estas neuronas se agrupan en capas: una capa de entrada, una o varias capas ocultas, y una capa de salida. Cada conexión entre neuronas tiene un peso que se ajusta durante el proceso de aprendizaje, permitiendo a la red reconocer patrones y hacer predicciones (Haykin, 2009).

¿Para qué se utilizan las redes neuronales?

Las redes neuronales se utilizan en diversas aplicaciones, como:

Reconocimiento de patrones: En tareas de visión por computadora y procesamiento de imágenes, como la identificación de rostros o la detección de objetos (LeCun et al., 2015).

Procesamiento del lenguaje natural: En aplicaciones como traducción automática, análisis de sentimientos y chatbots (Manning et al., 2014).

Predicción y clasificación: En finanzas para análisis de riesgo, en medicina para diagnósticos, y en marketing para segmentación de clientes (Kelleher et al., 2015).

Juegos y simulaciones: Las redes neuronales han sido utilizadas en la creación de agentes de inteligencia artificial que pueden jugar videojuegos (Silver et al., 2016).

¿Cómo funcionan las redes neuronales?

Las redes neuronales funcionan mediante el proceso de alimentación hacia adelante y retropropagación.

Alimentación hacia adelante: La información se introduce a través de la capa de entrada y se propaga hacia adelante a través de las capas ocultas hasta la capa de salida. Cada neurona en una capa toma la suma ponderada de las salidas de las neuronas de la capa anterior, aplica una función de activación y envía el resultado a la siguiente capa (Goodfellow et al., 2016).

Retropropagación: Durante el entrenamiento, se calcula el error en la salida y se propaga hacia atrás a través de la red para ajustar los pesos de las conexiones, minimizando el error utilizando algoritmos como el descenso de gradiente (Rumelhart et al., 1986).

Arquitectura de una Red Neuronal Simple

Una red neuronal simple, conocida como red de una sola capa (Single Layer Perceptron), consta de una capa de entrada y una capa de salida donde cada neurona en la capa de entrada está conectada a todas las neuronas de la capa de salida (figura 11). Este tipo de red puede resolver problemas linealmente separables, pero tiene limitaciones para tareas más complejas (Rojas, 1996).

Arquitectura de una Red Neuronal Profunda

Las redes neuronales profundas (Deep Neural Networks, DNN) incluyen múltiples capas ocultas entre la capa de entrada y la capa de salida. Esta profundidad permite a la red aprender representaciones más complejas y abstractas de los datos, siendo más efectiva en tareas como la clasificación de imágenes o el reconocimiento de voz (LeCun et al., 2015).




Figura 11: Arquitectura de una Red Neuronal. AWS.

Fuente: <https://openwebinars.net/blog/que-son-las-redes-neuronales-y-sus-aplicaciones/>

Tipos de redes neuronales

Existen varios tipos de redes neuronales, entre las cuales se incluyen:

Redes Neuronales Convolucionales (CNN): Especialmente diseñadas para procesar datos con estructura de cuadrícula, como imágenes. Utilizan capas convolucionales que extraen características espaciales (LeCun et al., 1998).

Redes Neuronales Recurrentes (RNN): Se utilizan para procesar secuencias de datos, como texto o series temporales. Tienen conexiones que permiten que la información persista a lo largo del tiempo (Hochreiter & Schmidhuber, 1997).

Redes Generativas Antagónicas (GAN): Compuestas por dos redes que compiten entre sí, una generadora y una discriminadora, y se utilizan para generar datos nuevos a partir de ejemplos (Goodfellow et al., 2014).

4.6 Sensores implementados:

4.6.1 Gravity CO2 Sensor V2.0

El Gravity CO2 Sensor V2.0 ver figura 12 ,es un sensor de dióxido de carbono que utiliza la tecnología de espectroscopía de infrarrojos no dispersivos (NDIR). Este sensor tiene un rango de medición de 0 a 5000 partes por millón (ppm) y una precisión de ± 50 ppm. Su tiempo de respuesta es rápido, con un tiempo de estabilización de aproximadamente 10 segundos. Este sensor es ideal para aplicaciones en interiores, como el monitoreo de la calidad del aire en invernaderos, aulas y espacios cerrados donde se desea medir los niveles de CO2.

La conectividad del Gravity CO2 Sensor V2.0 incluye salidas analógicas y digitales, lo que facilita su integración en sistemas de control y monitoreo. Con un costo relativamente bajo, es una opción accesible para proyectos educativos y de investigación (DFRobot, n.d.).



Figura 12:: Sensor Gravity CO2 Sensor V2.0 SEN0159 (Sensor de Bajo Costo)

Fuente: (DFRobot, n.d.).

4.6.2 Dwyer CDT-2N44 Wall Mount Carbon Dioxide Temperature Transmitter

El **Dwyer CDT-2N44** ver figura 13, es un transmisor de temperatura y dióxido de carbono montado en la pared que utiliza tecnología NDIR para medir niveles de CO₂. Su rango de medición es de 0 a 2000 ppm, con una precisión de ± 50 ppm. Este sensor está diseñado para su uso en sistemas de calefacción, ventilación y aire acondicionado (HVAC), así como en aplicaciones industriales donde se requiere un monitoreo preciso de los niveles de CO₂.

El Dwyer CDT-2N44 ofrece una respuesta rápida, con un tiempo de respuesta de aproximadamente 2 segundos, y cuenta con opciones de conectividad de salida de 4-20 mA y RS-485. Su robustez y precisión lo hacen adecuado para entornos exigentes, justificando su costo más alto en comparación con otros sensores (Dwyer Instruments, n.d.).



Figura 13: Dwyer CDT-2N44 Wall Mount Carbon Dioxide Temperature Transmitter (Sensor de Alto Costo)

Fuente: propia

Tabla de comparación de los sensores:

Tabla 1.
comparación de los sensores

Característica	Gravity CO2 Sensor V2.0	Dwyer CDT-2N44
Rango de Medición	0-5000 ppm	0-2000 ppm 0-5000 ppm
Precisión	±50 ppm	±50 ppm

Costo (aproximado)	Bajo (alrededor de \$30)	Alto (alrededor de \$300)
Tipo de Sensor	NDIR (Infrarrojo No Dispersivo)	NDIR
Tiempo de Respuesta	Rápido (alrededor de 10 segundos)	Rápido (alrededor de 2 segundos)
Conectividad	Analógico y digital	Salida 4-20 mA y RS-485
Condiciones de Operación	0-50°C, 0-95% HR	0-50°C, 0-95% HR
Aplicaciones Comunes	Monitoreo de calidad del aire, invernaderos	Sistemas de HVAC, monitoreo ambiental

Fuente: propia

5. Metodología

5.1 Tipo de proyecto

Desarrollo del apartado:

Investigación aplicada: Este proyecto se enfoca en resolver un problema práctico (alto costo de sensores de CO₂) mediante la creación de un dispositivo más accesible, combinando hardware económico con técnicas de inteligencia artificial.

Nivel descriptivo y experimental: El diseño se centra en caracterizar las capacidades de sensores económicos y mejorarlas a través de algoritmos de calibración basados en redes neuronales.

Estructura sugerida para este punto:

Tipo de investigación: Aplicada.

Enfoque: Experimental y descriptivo.

Campo: tecnología electrónica aplicada al monitoreo ambiental.

Alcance: Desarrollo y prueba de un prototipo funcional.

5.2 Método

Propuesta:

1. Definición del enfoque metodológico:

Desarrollo del prototipo: ensamblar un sistema de hardware que combine sensores económicos, una plataforma de control (Arduino UNO) y un sistema de procesamiento inteligente.

Calibración experimental: utilizar sensores de referencia para entrenar y ajustar los sensores económicos mediante redes neuronales.

Validación de resultados: comparar datos entre los sensores económicos y los de referencia en pruebas controladas.

2. Etapas del método:

Investigación inicial: Revisión del estado del arte sobre tecnologías de monitoreo de gases.

Diseño del sistema: Elección de componentes, diseño del circuito y configuración del software.

Diseño de experimental:

Con este diseño se buscó crear una cápsula en la que se pudieran realizar pruebas experimentales, permitiendo la integración de tres sensores de bajo costo, un sensor de alto costo, y una entrada para el gas. La cápsula incluye un espacio donde se introduce el CO₂ para llevar a cabo las mediciones. El diseño fue realizado con Fusion, un programa especializado en el diseño 3D de objetos. A continuación se observa la piezas con sus respectivas medidas en las figura 14 con vista isométrica, figura 15 vista frontal, figura 16 vista lateral, figura 17 vista trasera y figura 18 vista superior.




Figura 14: Vista Isométrica del dispositivo de pruebas
Fuente: propia




Figura 15: vista frontal
Fuente: propia




Figura 16: Vista Lateral
Fuente: propia




Figura 17: vista trasera

Fuente: propia




Figura 18: vista superior

Fuente: propia

Durante la fabricación de la pieza, se presentaron problemas de medición incorrectos en el sensor real. Por lo tanto, se rediseñó la pieza con las medidas correctas. Una vez rediseñada, la pieza se imprimió nuevamente, y esta vez quedó mucho mejor. Se realizaron ajustes finales con herramientas giratorias de mano (motortool). Además, se roscó la perforación donde irá el racor.

Una posible razón para no haber diseñado el sistema en forma cilíndrica fue la necesidad de optimizar el espacio interno para acomodar los sensores y la dosificación de los gases fuera más reducida con la finalidad de ahorrar gastos excesivos en este y el ingreso fuera de manera más eficiente. Un diseño rectangular o prismático puede facilitar la disposición y fijación de los sensores, además de permitir un mejor acceso para realizar ajustes o mantenimiento. También

podría haber consideraciones de manufacturabilidad, donde una forma más sencilla podría ser más fácil de imprimir o fabricar con las herramientas disponibles.

Validación experimental: Ejecutar pruebas en cápsulas controladas con CO₂ para comparar la precisión de las mediciones.

Diagrama de Flujo:

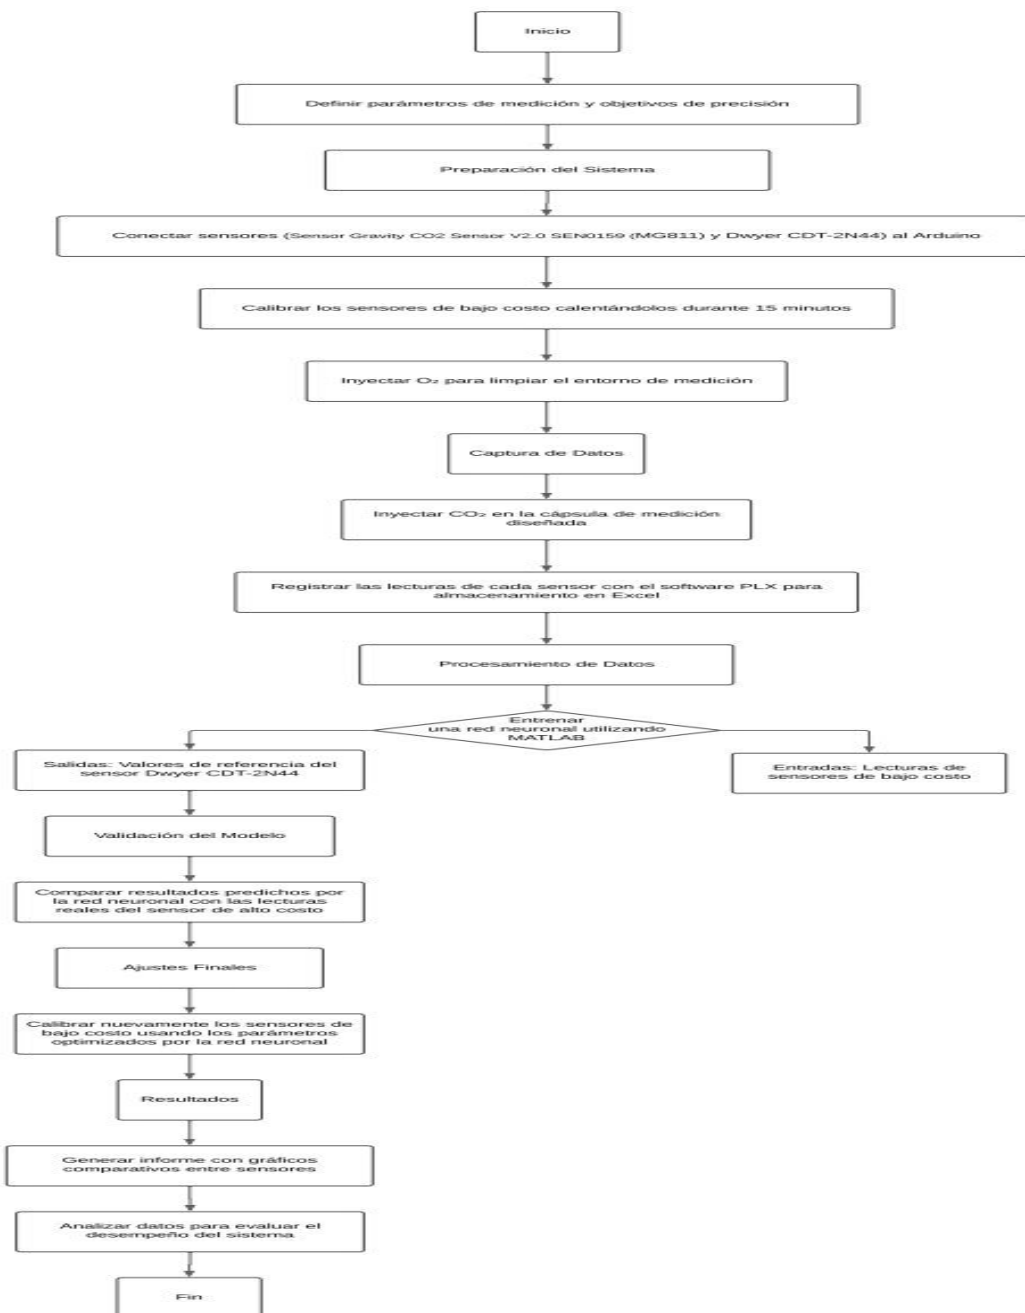


imagen 19: Diagrama de flujo

Fuente: propia

Procedimiento realizado:**1. Calibración de los sensores.**

Los sensores se calientan por 15 min con un voltaje de 6V-0.2A cada uno para que puedan llegar a su punto óptimo de funcionamiento como se logra ver en la figura 20.



Figura 20: elementos para prueba de calibración
Fuente:propia

2. Inyección de gas O₂.

la figura 21 nos muestra cómo se inyecta el O₂ para optimizar y limpiar el medio en el que se realizará las prueba de la siguiente manera.




Figura 21: inyección de O₂
Fuente:propia

3. Inyección de CO₂.

Figura 21 nos muestra como aplicar el gas CO₂ en la caja diseñada para realizar las mediciones del debido gas con antorcha del bloque de soldadura.



Figura 22: inyección CO₂ con antorcha
Fuente:propia

Figura 23 se aplica el gas CO₂ en la caja diseñada para realizar las mediciones del debido gas con la pipeta para llenar el sistema de almacenamiento.




Figura 23: inyección CO₂ con pipeta
Fuente: propia

4. Lectura de datos y toma de datos (Mediante la herramienta PLX).

En este punto adquirimos los datos de los sensores a través de la conexión de los sensores que están conectados al Arduino UNO el cual es el encargado de transmitir los datos por medio del puerto serial, mediante la herramienta PLX se registran los datos y se almacena en una tabla de Excel cada segundo por sensor. Tomando en cuenta el código implementado en el Arduino como muestra la figura 24.

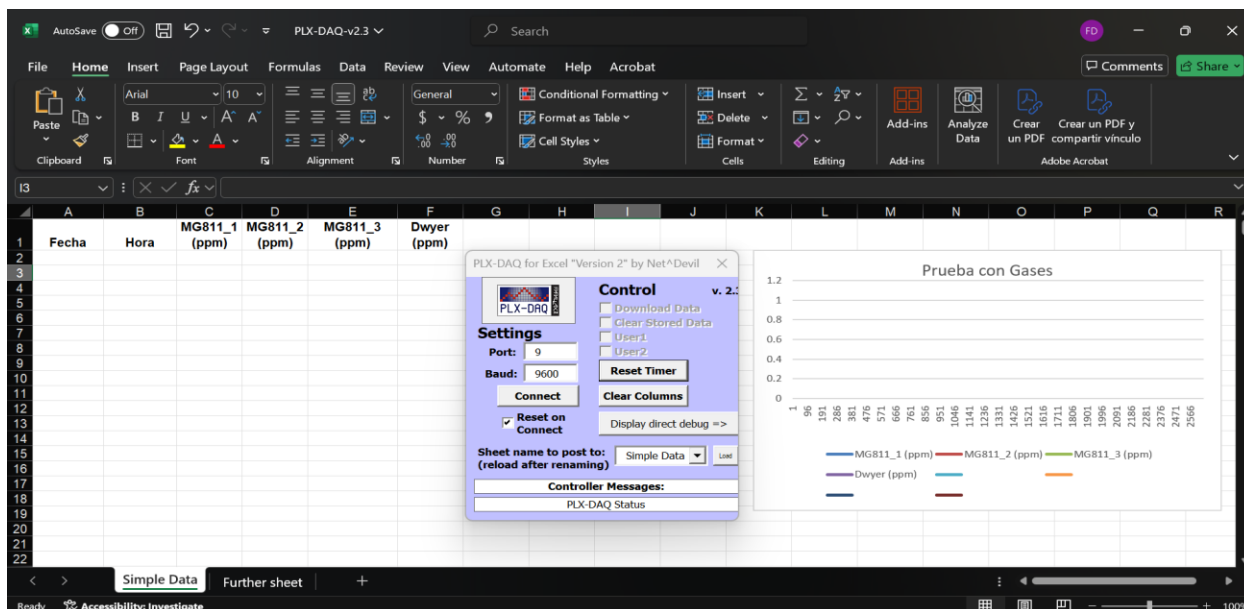


Figura 24: interfaz de PLX
Fuente: propia

5.3. Instrumentos de Recolección de información:

Materiales Utilizados:

Sensores:

Sensor Gravity CO2 Sensor V2.0 SEN0159 ver figura 25 (Sensor de Bajo Costo)



Figura 25: sensor electroquímico
Fuente:propia

Dwyer CDT-2N44 Wall Mount Carbon Dioxide Temperature Transmitter ver figura 26
(Sensor de Alto Costo)



Figura 26: sensor alto costo
Fuente:propia

Arduino UNO (véase figura 10)

Protoboard ver figura 27




Figura 27: protoboard
Fuente:propia

Cables jumper (véase figura 28)



Figura 28: cables jumper
Fuente:propia

5.4.1 Fuentes primarias:

Mediciones directas de CO₂ obtenidas de los sensores económicos y de referencia durante las pruebas experimentales.

Análisis de precisión a partir de redes neuronales entrenadas con datos de pruebas controladas.

5.4.2 Fuentes secundarias:

Artículos científicos, manuales técnicos de sensores, y estudios relacionados con el uso de redes neuronales para calibración.

Normativas locales e internacionales sobre calidad del aire (por ejemplo, límites permisibles de CO₂).

6. Resultados del proyecto

Se inyecta CO₂ y se puede observar las respuestas generadas por los sensores a la reacción del gas, que envían los datos desde el Arduino al PLX, generando una respuesta como se observa en la Figura 29.

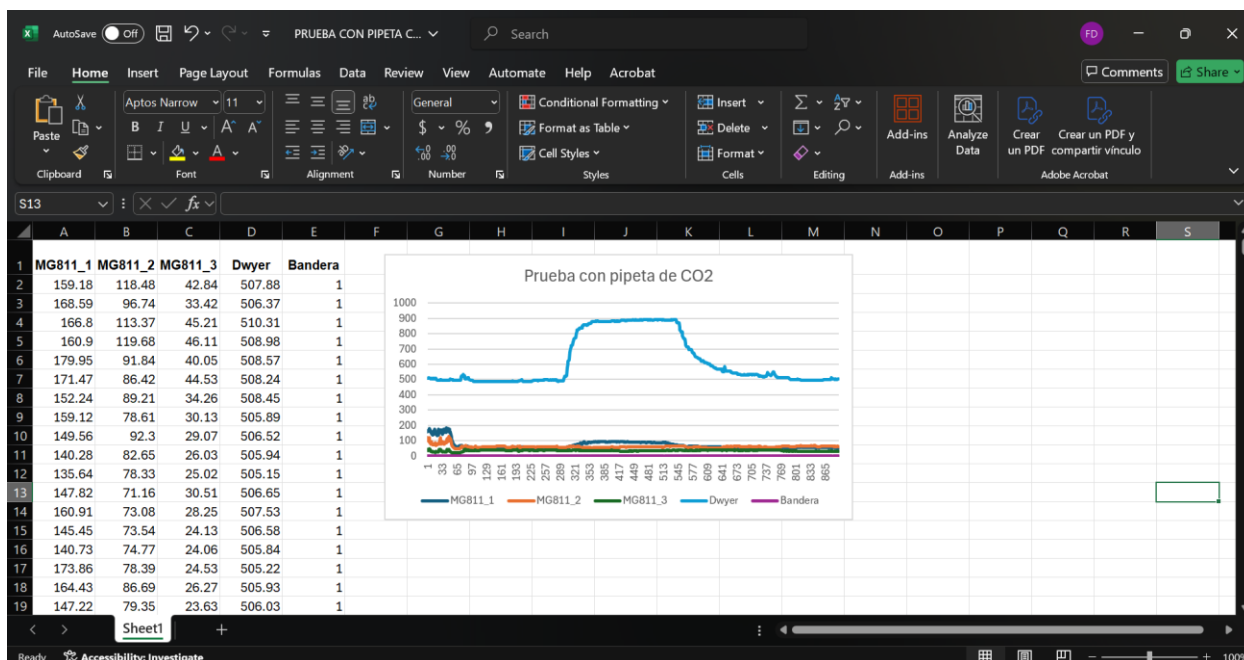


Figura 29: Programa PLX (Prueba con pipeta de CO₂)

Fuente: propia

Se inyecta O₂ y se puede observar las respuestas generadas por los sensores a la reacción del gas, que envían los datos desde el Arduino al PLX, generando una respuesta como se observa en la Figura 30.

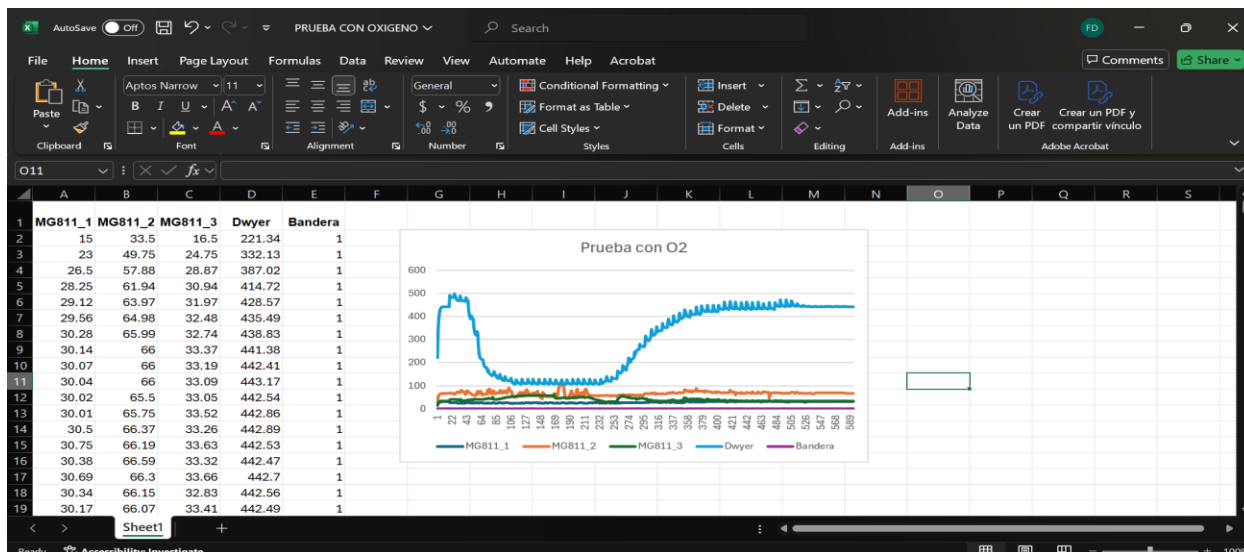


Figura 30: Programa PLX (Prueba con O2)

Fuente: propia

Se inyecta CO₂ y se puede observar las respuestas generadas por los sensores a la reacción del gas, que envían los datos desde el Arduino al PLX pero a diferencia de la pipeta ver figura 31, este da una respuesta más rápida debido a que a emisión del gas de la antorcha es mayor cantidad, y de esta manera genera una respuesta como se observa en la imagen 27.

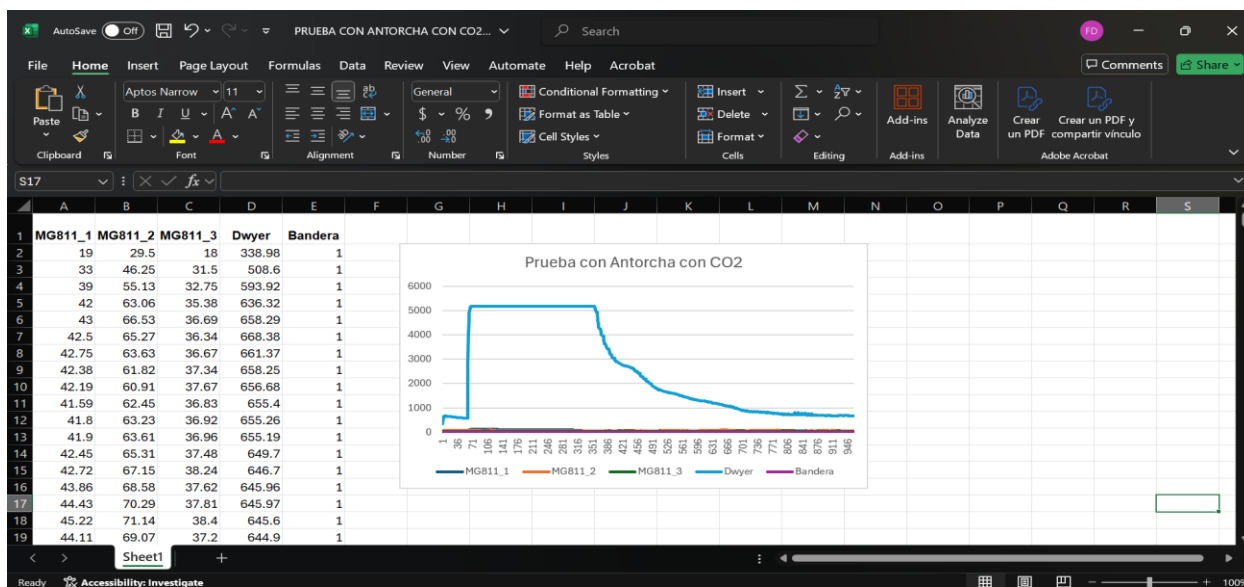


Figura 31: Programa PLX (Prueba con Antorcha con CO2)

Fuente: propia

Análisis del Rendimiento del Entrenamiento

La figura 33 presenta el MSE (Error Medio Cuadrático) en función del número de épocas:

- Eje X: Representa el número de épocas o iteraciones del entrenamiento.
- Eje Y: Muestra el valor del MSE, una métrica para evaluar el rendimiento del modelo.
- Curvas:
 - Rojo: MSE para el conjunto de entrenamiento.
 - Verde: MSE para el conjunto de validación.
 - Azul: MSE para el conjunto de prueba.
- El punto de mejor validación se muestra como un marcador, indicando el momento donde el modelo logró su mejor capacidad de generalización.

Interpretación del Gráfico (Figura)

1. La curva muestra una disminución inicial rápida del error, indicando que la red está aprendiendo de manera efectiva.
2. El mejor rendimiento de validación se alcanzó en la época 34, con un MSE de 363.1461 y la raíz cuadrada de 363.1461 es la desviación promedio de los datos de 19ppm.
3. La similitud entre las curvas de validación y prueba sugiere que el modelo generaliza bien y no está sobre ajustado.

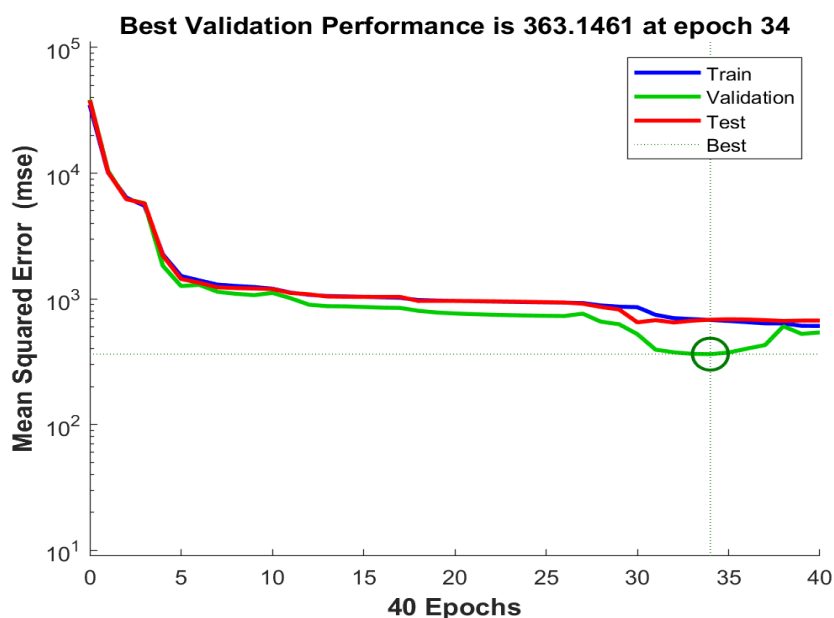


Figura 32: Red Neuronal con datos de la pipeta con CO₂.

Fuente: propia

Tendencia de los datos

La figura 34 muestra la tendencia de los datos de entrenamiento, como regresión lineal. En total se obtuvieron 854 datos de los cuales el 70% se emplearon en el entrenamiento, el 15% en prueba y 15 restante en validación.

1. Training (Entrenamiento)

La gráfica del entrenamiento evalúa cómo se ajusta la red neuronal a los datos utilizados para entrenarla. El coeficiente de correlación obtenido es $R = 0.98667$, lo que indica una relación fuerte entre las predicciones y los valores reales. Esto muestra que la red está aprendiendo de manera efectiva.

2. Validation (Validación)

En el conjunto de validación, el coeficiente de correlación es $R = 0.99374$. Este conjunto se utiliza para evaluar la capacidad de generalización de la red neuronal. El alto valor de R indica que la red predice de manera precisa datos no usados durante el entrenamiento.

3. Test (Prueba)

La gráfica del conjunto de prueba tiene un coeficiente de correlación de $R = 0.98746$. Este conjunto evalúa el rendimiento de la red con datos completamente nuevos. El buen valor de R sugiere que la red tiene un buen desempeño al generalizar a nuevos datos.

4. All (Todos los Datos)

El coeficiente de correlación global para todos los datos (entrenamiento, validación y prueba) es $R = 0.98796$. Esto confirma que la red tiene un buen ajuste global y que las salidas predichas están altamente correlacionadas con los valores reales.

Interpretación General

En Figura 33, Las líneas de regresión ajustadas en las gráficas están muy cercanas a la línea ideal $Y = T$, lo que indica que las salidas predichas por la red están muy cerca de los valores reales. Los valores de R cercanos a 1 en todos los conjuntos de datos sugieren que la red está bien entrenada y no presenta problemas significativos de sobreajuste o subajuste siendo capaz de predecir con precisión datos nuevos.

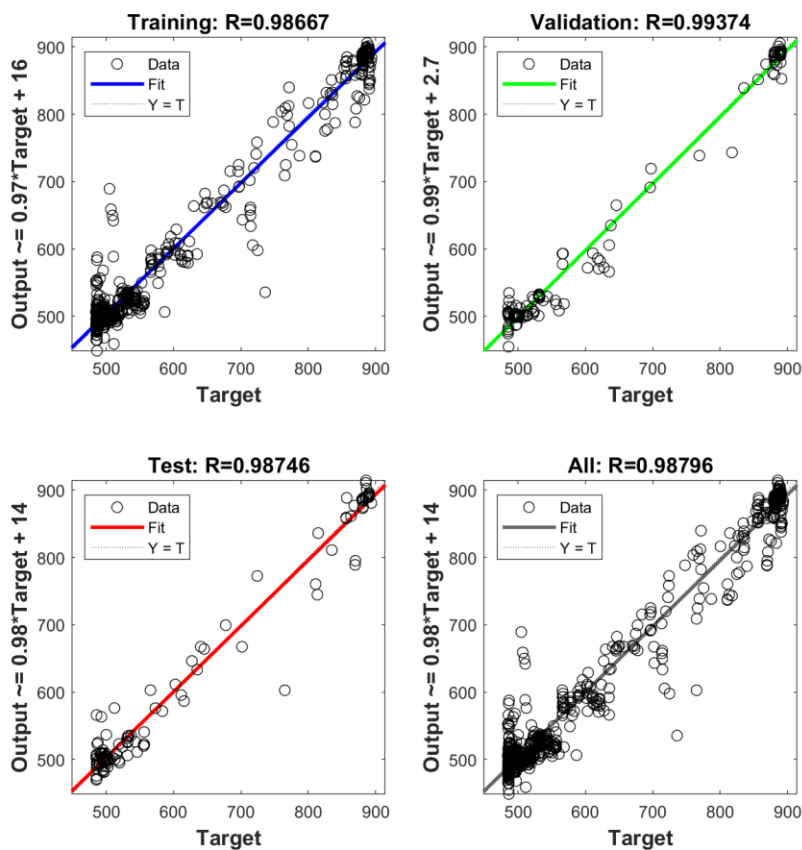


Figura 33: Tendencia de los datos en la Red Neuronal con datos de la pipeta con CO₂.

Fuente: propia

Tabla 2.
Obtención de resultados

Salida RED	Salida Alto costo filtrada
630.94	670.17
661.26	669.24
637.42	668.40
640.21	664.15
660.43	665.87
656.32	662.42
660.1	659.93

Fuente: propia

Los resultados obtenidos evidencian que la salida generada por la red neuronal se aproxima de manera significativa a los valores registrados por el sensor de alto costo. Este comportamiento confirma que el modelo desarrollado a través de redes neuronales proporciona una respuesta precisa y confiable, lo que demuestra su capacidad para adaptarse a las características y limitaciones del sistema de sensores de bajo costo. Por lo tanto, se valida que esta solución resulta adecuada para suplir la funcionalidad requerida, ofreciendo una alternativa eficiente y más económica sin comprometer la calidad de los datos obtenidos.

Características encontradas:

1. Rango de Medición:

- El **Gravity CO2 Sensor V2.0** es ideal para aplicaciones con niveles de CO2 relativamente bajos, como invernaderos o aulas (Gravity, n.d.).
- El **Dwyer CDT-2N44** es adecuado para entornos industriales y sistemas HVAC donde se espera un rango de CO2 más alto (Dwyer Instruments, n.d.).

2. Precisión:

- Todos los sensores tienen una precisión similar; sin embargo, el **Dwyer CDT-2N44** es más adecuado para aplicaciones que requieren mediciones precisas (Dwyer Instruments, n.d.).

3. Costo:

- El costo varía significativamente entre los sensores. El **Gravity** es la opción más económica, mientras que el **Dwyer CDT-2N44** es más adecuado para aplicaciones industriales donde la precisión justifica el costo (Gravity, n.d.; Dwyer Instruments, n.d.).

4. Tipo de Sensor:

- El **Gravity** y el **Dwyer** utilizan tecnología NDIR, proporcionando estabilidad y menor interferencia.

5. Tiempo de Respuesta:

- El **Dwyer CDT-2N44** tiene el mejor tiempo de respuesta, ideal para aplicaciones dinámicas (Dwyer Instruments, n.d.).

6. Conectividad:

- El **Dwyer CDT-2N44** ofrece opciones de conectividad más robustas, lo que permite una fácil integración en sistemas más grandes (Dwyer Instruments, n.d.).

7. Condiciones de Operación:

- Todos los sensores operan en condiciones similares, pero el **Dwyer** tiene un rango más amplio, adecuado para entornos industriales extremos (Dwyer Instruments, n.d.).

Aplicaciones

- **Gravity CO2 Sensor V2.0:** Perfecto para proyectos educativos y monitoreo de CO2 en interiores (Gravity, n.d.).
- **Dwyer CDT-2N44:** Ideal para aplicaciones industriales y sistemas de HVAC (Dwyer Instruments, n.d.).

8. Conclusiones

- El proyecto demuestra que es posible emular el desempeño de sensores de CO₂ de alto costo utilizando sensores económicos combinados con técnicas avanzadas como redes neuronales. Esto democratiza el acceso a tecnologías de monitoreo ambiental, especialmente en regiones con recursos limitados.
- Tras el entrenamiento de redes neuronales, los sensores económicos alcanzaron niveles de precisión comparables a los sensores de referencia, mostrando que los algoritmos de inteligencia artificial son herramientas efectivas para la calibración y mejora de dispositivos económicos.
- Este proyecto puede extenderse a la detección de otros gases contaminantes y la optimización de los modelos neuronales para ampliar su aplicabilidad en diferentes entornos industriales, educativos y comunitarios.
- La elección de componentes como el Arduino UNO y sensores económicos sugiere que el prototipo puede ser replicado fácilmente por investigadores o instituciones educativas, lo que amplifica su impacto.

8. Recomendaciones

- Las calibraciones frecuentes necesarias para los sensores económicos y su dependencia de algoritmos robustos pueden ser un reto para usuarios con conocimientos técnicos limitados.
- Incorporar modelos más avanzados de aprendizaje automático, como redes neuronales profundas, podría mejorar la precisión y adaptabilidad a diferentes gases y condiciones ambientales.
- Se debe calibrar bien los sensores electroquímicos, llevándolos primero a la temperatura estándar, y alimentarlos con un voltaje preciso de 5V para mejores resultados.
- Al reducir los costos asociados con la adquisición de sensores de alta gama, el proyecto abre oportunidades para el monitoreo ambiental en sectores de bajo presupuesto, como pequeñas empresas, comunidades rurales y proyectos de investigación emergentes.

9. Referencias bibliográficas

- Atkins, P., & de Paula, J. (2018). *Atkins' physical chemistry*. Oxford University Press. (<https://tech.chemistrydocs.com/Books/Physical/Atkins-Physical-Chemistry-9e-by-Peter-Atkins-and-Julio-de-Paula.pdf>)
- Aggarwal, C. C. (2018). *Neural networks and deep learning: A textbook*. Springer. (https://www.academia.edu/42981452/Neural_Networks_and_Deep_Learning_Charu_C_Aggarwal?auto=download)
- Bates, S. (2020). *Fundamentals of gas properties and behavior*. Springer.(http://students.aiu.edu/submissions/profiles/resources/onlineBook/Y8M8y6_Methods%20in%20Behavioral%20Research.pdf)
- Bertolini, M., Bottani, E., & Vignali, G. (2021). *Innovative food processing technologies*. Academic Press. (https://www.researchgate.net/publication/326165484_Augmented_reality_technology_in_the_manufacturing_industry_A_review_of_the_last_decade)
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer. (https://www.academia.edu/17851990/Bishop_Pattern_Recognition_and_Machine_Learning)
- Bowling, D., Cook, C., & Ehleringer, J. (2001). Technique to measure CO₂ mixing ratio in small flasks with a bellows/IRGA system. *Agricultural and Forest Meteorology*, 109(1), 61-65. (<https://www.ehleringer.net/uploads/3/1/8/3/31835701/266.pdf>)
- Bonne, J.-L., Donnat, L., Albora, G., et al. (2024). A UAV-based CO₂ and CH₄ emissions quantification system. *Atmospheric Measurement Techniques*, 17, 4471-4491. <https://doi.org/10.5194/amt-17-4471-2024>
- Chollet, F. (2018). *Deep learning with Python*. Manning Publications. (<https://tanthiamhuat.files.wordpress.com/2018/03/deeplearningwithpython.pdf>)
- Dióxido de carbono | Signos vitales – Climate Change: Vital Signs of the Planet. (n.d.). Climate Change. Retrieved October 29, 2024, from <https://climate.nasa.gov/en-espanol/signos-vitales/dioxido-de-carbono/?intent=111>
- González Rivero, R. A. (2022). Calibración de sensores de bajo costo para el monitoreo ambiental de CO₂, NO₂ y SO₂ en una zona rural de la ciudad de Cienfuegos [Tesis de maestría, Universidad Central “Marta Abreu” de Las Villas]. Repositorio de ResearchGate. <https://www.researchgate.net/publication/365409379>
- González, F., López, M., & Suárez, L. (2020). *Gestión de la calidad en la industria alimentaria*. Editorial Díaz de Santos. (<https://clea.edu.mx/biblioteca/files/original/64db843c11c52aaf913a5322feafd3d8.pdf>)
- González, P., & Torres, L. (2021). *Fundamentos de seguridad industrial y ambiental*. Editorial Reverte. (<https://repositorio.uti.edu.ec/bitstream/123456789/2224/1/Libro%20Seguridad%20Industrial.pdf>)
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. ([http://alvarestech.com/temp/deep/Deep%20Learning%20by%20Ian%20Goodfellow,%20Yoshua%20Bengio,%20Aaron%20Courville%20\(z-lib.org\).pdf](http://alvarestech.com/temp/deep/Deep%20Learning%20by%20Ian%20Goodfellow,%20Yoshua%20Bengio,%20Aaron%20Courville%20(z-lib.org).pdf))

- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Courville, A. (2014). Generative adversarial nets. In *Advances in Neural Information Processing Systems* (pp. 27-36). (https://www.researchgate.net/publication/263012109_Generative_Adversarial_Networks)
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson Education. (<https://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf>)
- Gases and kinetic molecular theory | Chemistry library. (n.d.). Khan Academy. Retrieved May 20, 2024, from <https://www.khanacademy.org/science/chemistry/gases-and-kinetic-molecular-theory>
- *Sensor Market Size, Share | Industry Research Report, 2019-2025*. (n.d.). Grand View Research. Retrieved May 20, 2024, from <https://www.grandviewresearch.com/industry-analysis/sensor-market>
- ¿Qué son los detectores de gas y cómo se utilizan en diversas industrias? (n.d.). MRU Instruments. Retrieved May 20, 2024, from <https://mru-instruments.com/es/what-are-gas-detectors-and-how-are-they-used-in-various-industries/>
- *What are the WHO Air quality guidelines?* (2021, September 22). World Health Organization (WHO). Retrieved May 20, 2024, from <https://www.who.int/news-room/feature-stories/detail/what-are-the-who-air-quality-guidelines>
- *Air Quality | US EPA*. (n.d.). Environmental Protection Agency. Retrieved May 20, 2024, from <https://www.epa.gov/air-quality>
- *Índice de la calidad del aire (ICA) de Medellín y contaminación del aire en Colombia*. (n.d.). IQAir. Retrieved May 20, 2024, from <https://www.iqair.com/es/colombia/antioquia/medellin>
- *NIST Greenhouse Gas Measurement Program | NIST*. (2021, June 1). National Institute of Standards and Technology. Retrieved May 20, 2024, from <https://www.nist.gov/video/nist-greenhouse-gas-measurement-program>
- Hernández, P., & Ponce, J. (2020). *Sistemas de detección de gases en la industria*. Editorial Limusa.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. (<https://www.bioinf.jku.at/publications/older/2604.pdf>)
- Kelleher, J. D., Namee, B. M., & D'Arcy, A. (2015). *Fundamentals of machine learning for predictive data analytics: Algorithms, worked examples, and case studies*. MIT Press. (https://www.academia.edu/29701158/Fundamentals_of_machine_learning_for_predictive_data_analytics)

- Lazik, D., & Sood, P. (2016). Approach for self-calibrating CO₂ measurements with linear membrane-based gas sensors. *Sensors (Basel, Switzerland)*, 16. <https://doi.org/10.3390/s16060785>
- LeCun, Y., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. <https://doi.org/10.1109/5.726791>
- LeCun, Y., Bengio, Y., & Haffner, P. (2015). Deep learning. *Nature*, 521, 436-444. <https://doi.org/10.1038/nature14539>
- Levine, I. (2017). *Physical chemistry*. McGraw-Hill Education. (http://repo.upertis.ac.id/1874/1/alivechem.com_Physical_Chemistry-levine.pdf)
- Luna, A., Talavera, Á., & Cano, L. (2017). Uso de sensores electroquímicos de bajo costo para el monitoreo de la calidad del aire en el distrito de San Isidro - Lima, Perú. *Documento de Discusión CIUP DD1705*, Centro de Investigación de la Universidad del Pacífico. (<https://repositorio.up.edu.pe/bitstream/handle/11354/1845/DD1705.pdf?sequence=1&isAllowed=y>)
- Maffly, R. (1968). A conductometric method for measuring micromolar quantities of carbon dioxide. *Analytical Biochemistry*, 23(2), 252-262. (<https://www.sciencedirect.com/science/article/abs/pii/0003269768903576?via%3Dihub>)
- Manning, C. D., Raghavan, P., & Schütze, H. (2014). *Introduction to information retrieval*. MIT Press. (<https://nlp.stanford.edu/IR-book/pdf/irbookonlinereading.pdf>)
- Müller, M., Graf, P., & Meyer, J. (2020). Integration and calibration of non-dispersive infrared (NDIR) CO₂ low-cost sensors and their operation in a sensor network covering Switzerland. *Atmospheric Measurement Techniques*, 13, 3815–3834. <https://doi.org/10.5194/amt-13-3815-2020>
- Ortiz, F., & Molina, S. (2022). *Sensores y su aplicación en el control de gases industriales*. Reverte.
- Pachauri, R. K., Allen, M. R., & Barros, V. R. (2018). *Climate change 2018: Synthesis report*. IPCC. (https://www.ipcc.ch/site/assets/uploads/2018/05/SYR_AR5_FINAL_full_wcover.pdf)
- Rojas, R. (1996). *Neural networks: A systematic introduction*. Springer. (<https://freecomputerbooks.com/Neural-Networks-A-Systematic-Introduction.html>)
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533-536. <https://doi.org/10.1038/323533a0>
- Silbey, R. J., Alberty, R. A., & Bawendi, M. G. (2019). *Physical chemistry*. Wiley. (<http://ndl.ethernet.edu.et/bitstream/123456789/78711/1/Robert%20J.%20Silbey%2C%20Robert%20A.%20Alberty%2C%20Moungi%20G.%20Bawendi%20-%20Physical%20Chemistry-Wiley%20%282004%29.pdf>)
- Smith, R., & Smith, T. (2023). *Principles of environmental science*. McGraw-Hill Education (<https://www.mheducation.com/unitas/school/program/ap/cunningham-principles-of-environmental-science-1e/sample-chapter.pdf>).
- Staebell, C., Sun, K., Samra, J., et al. (2021). Spectral calibration of the MethaneAIR instrument. *Atmospheric Measurement Techniques*, 14, 3737-3753. <https://doi.org/10.5194/amt-14-3737-2021>

- Sun, X., Duan, M., Gao, Y., et al. (2020). In situ measurement of CO₂ and CH₄ from aircraft over northeast China. *Atmospheric Measurement Techniques*, 13, 3595-3607. <https://doi.org/10.5194/amt-13-3595-2020>
- Vafaei, M., Amini, A., & Siadatan, A. (2020). Breakthrough in CO₂ measurement with a chamberless NDIR optical gas sensor. *IEEE Transactions on Instrumentation and Measurement*, 69, 2258-2268. (<https://ieeexplore.ieee.org/document/8730374>)
- Wang, G., Yu, C., Guo, K., et al. (2024). Research of low-cost air quality monitoring models with different machine learning algorithms. *Atmospheric Measurement Techniques*, 17, 181-196. <https://doi.org/10.5194/amt-17-181-2024>
- Wilkinson, J., Bors, C., Burgis, F., Lorke, A., & Bodmer, P. (2018). Measuring CO₂ and CH₄ with a portable gas analyzer: Closed-loop operation, optimization and assessment. *PLoS ONE*, 13(9), e0203018. <https://doi.org/10.1371/journal.pone.0203018>.
- Dwyer Instruments. (n.d.). *Dwyer CDT-2N44 Carbon Dioxide Temperature Transmitter*. Retrieved October 31, 2024, from <https://assets.alliedelec.com/v1645096801/Datasheets/98c76318a4f273719f62c6b6c7bd92b2.pdf>
- Gravity. (n.d.). *Gravity CO₂ Sensor V2.0*. Retrieved October 31, 2024, from <https://www.dfrobot.com/product-1023.html>
- IPCC (2022). *Climate Change 2022: Mitigation of Climate Change*. Cambridge University <https://www.ipcc.ch/report/ar6/wg3/>
- Bedoya, V. R., Marquet, O., & Miralles-Guasch, C. (2016). Estimación de las emisiones de CO₂ desde la perspectiva de la demanda de transporte en Medellín. ResearchGate. https://www.researchgate.net/publication/309398812_Estimacion_de_las_emisiones_de_CO2_desde_la_perspectiva_de_la_demanda_de_transporte_en_Medellin

10. Anexos

Anexo a: Código para toma de Datos véase Figura 34

```

#include <Wire.h>
//#include <LiquidCrystal_I2C.h>

int Bandera=0;
const int analogPinMG811_1 = A4;
const int analogPinMG811_2 = A1;
const int analogPinMG811_3 = A2;
const int analogPinDwyer = A3;
const int test = 2;
float ppmDwyer;
float senal_filt1;
float senal_filtMG811_1;
float senal_filtMG811_2;
float senal_filtMG811_3;

const float Vc = 5.0;
const float V0_MG811 = 0.4;
const float sensitivity_MG811 = 0.02;
float factor = 0.5;
float factor3 = 0.5;
int senal=1;
void setup() {

  Serial.begin(9600);
  pinMode(test,INPUT);
  // Encabezados de columna para PLX DAQ
  Serial.println("LABEL, Fecha, Hora, Filtrado                               MG811_1, Filtrado
MG811_2, Filtrado MG811_3, Filtrado Dwyer, Bandera");
}

void loop() {
Bandera=digitalRead(test);

  // Leer y filtrar los valores de los sensores MG811

  int sensorValueMG811_1 = analogRead(analogPinMG811_1);
  float ppmMG811_1 = sensorValueMG811_1;

```

```

    senal_filtMG811_1 = (factor3 * ppmMG811_1) + ((1 - factor) *
senal_filtMG811_1);

    int sensorValueMG811_2 = analogRead(analogPinMG811_2);
    float ppmMG811_2 = sensorValueMG811_2;
    senal_filtMG811_2 = (factor3 * ppmMG811_2) + ((1 - factor) *
senal_filtMG811_2);

    int sensorValueMG811_3 = analogRead(analogPinMG811_3);
    float ppmMG811_3 = sensorValueMG811_3;
    senal_filtMG811_3 = (factor3 * ppmMG811_3) + ((1 - factor) *
senal_filtMG811_3);

    // Leer y filtrar el valor del sensor Dwyer CDT-2N44
    ppmDwyer = 0; // Reinicia para acumular la lectura promedio
    for (int k = 0; k < 20; k++) {
        float sensorValueDwyer = analogRead(analogPinDwyer);
        ppmDwyer += (sensorValueDwyer * 5 * 1.0153);
    }
    ppmDwyer /= 20; // Promedio de 20 lecturas
    senal_filt1 = (factor * ppmDwyer) + ((1 - factor) * senal_filt1);

    // Enviar datos en el formato de PLX DAQ
    Serial.print("DATA,DATE,TIME,");

    Serial.print(senal_filtMG811_1, 2);
    Serial.print(",");
    Serial.print(senal_filtMG811_2, 2);
    Serial.print(",");
    Serial.print(senal_filtMG811_3, 2);
    Serial.print(",");
    Serial.print(senal_filt1, 2);
    Serial.print(",");
    Serial.println(Bandera, 2);
    delay (1500);
}

```

Figura 34: Código para toma de Datos (Arduino)

Fuente: propia

Anexo a. Entrenamiento de la Red Neuronal. véase Figura 35

```

clear all
% Cargar los datos
data = readtable('PRUEBACONPIPETACO2.xlsx');
% Seleccionar las columnas deseadas
X_train1 = data(:, {'MG811_1', 'MG811_2', 'MG811_3'}); % Variables de entrada
y_train1 = data(:, {'Dwyer'}); % Variable de salida
% Convertir los datos a matrices y ajustar dimensiones
X_train = X_train1'; % Transponer para que cada columna sea una muestra
y_train = y_train1'; % Transponer para obtener un vector fila
% Definir la red neuronal
hiddenLayerSize = 8;
net = fitnet(hiddenLayerSize);
% Dividir los datos para entrenamiento, validación y prueba
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
% Entrenar la red
[net, tr] = train(net, X_train, y_train);
% Obtener los pesos y bias
wb = getwb(net);
[b, IW, LW] = separatewb(net, wb);
% Guardar los pesos y bias
save('weights_bias.mat', 'wb');

```

Figura 35: Código para entrenamiento de Red Neuronal (MATLAB)

Fuente:propia

Anexo b. Calibración de los sensores después de la aplicación de la red neuronal. véase Figura 36

```

1. float W1[8][3] = {
2.     {-2.07925, -2.28326, -3.45496},
3.     {0.669917, -2.01437, -1.75221},
4.     {4.864422, 2.634621, -3.78805},
5.     {0.071061, 0.001669, -6.7865},
6.     {-0.1609, -2.23664, -6.55124},
7.     {10.38317, -4.31791, 2.862341},
8.     {4.316952, 0.990421, -3.30551},
9.     {0.979297, 1.796688, -3.13882}
10.    };

```

```
11.     float b1[8] = {3.007017, -2.90068, 0.460836, 1.181559,
12.         1.569678, 4.525648, 6.42809, 3.507522};
13.     float w2[8] = {-0.05843, -0.10247, -0.9767, -0.31916,
14.         0.372957, 0.967932, -2.85023, 2.702622};
15.     float b2 = 0.8519;
16.
17.     float inputs[3];
18.     float hidden_layer[8];
19.     float output;
20.
21.     int analogPinMG811_1 = A1;
22.     int analogPinMG811_2 = A2;
23.     int analogPinMG811_3 = A4;
24.     int analogPinDwyer = A3;
25.
26.     float senal_filtMG811_1 = 0, senal_filtMG811_2 = 0,
27.     senal_filtMG811_3 = 0;
28.     float factor = 0.5;
29.     float factor3 = 0.5;
30.     float ppmDwyer = 0;
31.     float senal_filtDwyer = 0;
32.
33.     void setup() {
34.         Serial.begin(9600);
35.     }
36.
37.     void loop() {
38.         // Leer y filtrar los sensores económicos
39.         inputs[0] = analogRead(analogPinMG811_1);
40.         senal_filtMG811_1 = (factor3 * inputs[0]) + ((1 - factor3) *
41.             senal_filtMG811_1);
42.
43.         inputs[1] = analogRead(analogPinMG811_2);
44.         senal_filtMG811_2 = (factor3 * inputs[1]) + ((1 - factor3) *
45.             senal_filtMG811_2);
46.
47.         inputs[2] = analogRead(analogPinMG811_3);
48.         senal_filtMG811_3 = (factor3 * inputs[2]) + ((1 - factor3) *
49.             senal_filtMG811_3);
50.     }
```

```

45.     // Leer y filtrar el sensor de alto costo (Dwyer)
46.     ppmDwyer = 0;
47.     for (int k = 0; k < 20; k++) {
48.         float sensorValueDwyer = analogRead(analogPinDwyer);
49.         ppmDwyer += (sensorValueDwyer * 5 * 1.0153); // Ajusta
           esta fórmula según sea necesario
50.     }
51.     ppmDwyer /= 20;
52.     senal_filtDwyer = (factor * ppmDwyer) + ((1 - factor) *
           senal_filtDwyer);
53.
54.     // Capa oculta
55.     for (int i = 0; i < 8; i++) {
56.         hidden_layer[i] = b1[i];
57.         for (int j = 0; j < 3; j++) {
58.             hidden_layer[i] += W1[i][j] * inputs[j];
59.         }
60.         if (hidden_layer[i] < 0)
61.             hidden_layer[i] = 0;
62.     }
63.
64.     // Cálculo de salida
65.     output = b2;
66.     for (int i = 0; i < 8; i++) {
67.         output += W2[i] * hidden_layer[i]*-1;
68.     }
69.
70.     // Resultados
71.     Serial.print("Salida RED: ");
72.     Serial.print(output);
73.     Serial.print(" | Salida Alto costo filtrada: ");
74.     Serial.println(senal_filtDwyer);
75.
76.     delay(1000);
77. }

```

Figura 36: Código para entrenamiento de Red Neuronal (ARDUINO)

Fuente: propia

anexo c. Entrenamiento de Red Neuronal en Arduino. véase Figura 37

```
float w1[8][3] = {  
  
    {-2.07925, -2.28326, -3.45496},  
  
    {0.669917, -2.01437, -1.75221},  
  
    {4.864422, 2.634621, -3.78805},  
  
    {0.071061, 0.001669, -6.7865},  
  
    {-0.1609, -2.23664, -6.55124},  
  
    {10.38317, -4.31791, 2.862341},  
  
    {4.316952, 0.990421, -3.30551},  
  
    {0.979297, 1.796688, -3.13882}  
  
};  
  
float b1[8] = {3.007017, -2.90068, 0.460836, 1.181559, 1.569678, 4.525648,  
6.42809, 3.507522};  
  
float w2[8] = {-0.05843, -0.10247, -0.9767, -0.31916, 0.372957, 0.967932,  
-2.85023, 2.702622};  
  
float b2 = 0.8519;  
  
float inputs[3];  
  
float hidden_layer[8];  
  
float output;
```

```
int analogPinMG811_1 = A1;

int analogPinMG811_2 = A2;

int analogPinMG811_3 = A4;

int analogPinDwyer = A3;

float senal_filtMG811_1 = 0, senal_filtMG811_2 = 0, senal_filtMG811_3 = 0;

float factor = 0.5;

float factor3 = 0.5;

float ppmDwyer = 0;

float senal_filtDwyer = 0;

void setup() {

    Serial.begin(9600);

}

void loop() {

    // Leer y filtrar los sensores económicos

    inputs[0] = analogRead(analogPinMG811_1);

    senal_filtMG811_1 = (factor3 * inputs[0]) + ((1 - factor3) *
senal_filtMG811_1);

    inputs[1] = analogRead(analogPinMG811_2);
```

```
    senal_filtMG811_2 = (factor3 * inputs[1]) + ((1 - factor3) *
senal_filtMG811_2);

    inputs[2] = analogRead(analogPinMG811_3);

    senal_filtMG811_3 = (factor3 * inputs[2]) + ((1 - factor3) *
senal_filtMG811_3);

    // Leer y filtrar el sensor de alto costo (Dwyer)

    ppmDwyer = 0;

    for (int k = 0; k < 20; k++) {

        float sensorValueDwyer = analogRead(analogPinDwyer);

        ppmDwyer += (sensorValueDwyer * 5 * 1.0153); // Ajusta esta fórmula
según sea necesario

    }

    ppmDwyer /= 20;

    senal_filtDwyer = (factor * ppmDwyer) + ((1 - factor) *
senal_filtDwyer);

    // Capa oculta

    for (int i = 0; i < 8; i++) {

        hidden_layer[i] = b1[i];

        for (int j = 0; j < 3; j++) {

            hidden_layer[i] += W1[i][j] * inputs[j];

        }

        if (hidden_layer[i] < 0)
```

```
    hidden_layer[i] = 0;

}

// Cálculo de salida

output = b2;

for (int i = 0; i < 8; i++) {

    output += W2[i] * hidden_layer[i]*-1;

}

// Resultados

Serial.print("Salida RED: ");

Serial.print(output);

Serial.print(" | Salida Alto costo filtrada: ");

Serial.println(senal_filtDwyer);

delay(1000);

}
```

Figura 37: Código para entrenamiento de Red Neuronal (ARDUINO)
Fuente:propia

