



**Dispositivo portable para el monitoreo y posterior análisis con machine learning de la calidad  
del aire en la ciudad de Pasto**

Autores:

Juan Sebastián Torres Velásquez

Jaime Andrés Jurado Arévalo

PROHIBIDA SU COPIA

Corporación Universitaria Autónoma de Nariño

Facultad de Ingeniería

Ingeniería Electrónica

San Juan de Pasto

2023



**Dispositivo portable para el monitoreo y posterior análisis con machine learning de la  
calidad del aire en la ciudad de Pasto.**

Autores:

Juan Sebastián Torres Velásquez

Jaime Andrés Jurado Arévalo

Trabajo de grado para optar al título de ingeniero electrónico

Asesor Técnico

Luis Alberto Rosero Narváez

Asesor Metodológico

Cristina Meneses

Corporación Universitaria Autónoma de Nariño

Facultad de Ingeniería

Ingeniería Electrónica

San Juan de Pasto

2023



## Tabla de contenido

<b>1. Introducción</b>	<b>1</b>
<b>1. Planteamiento del problema</b>	<b>2</b>
2.1. Descripción del problema	2
2.2. Formulación del problema	3
<b>2. Justificación</b>	<b>4</b>
<b>3. Objetivos</b>	<b>6</b>
4.1. Objetivo General	6
4.2. Objetivos específicos	6
<b>5. Marco Referencial</b>	<b>7</b>
5.1. Marco contextual	7
5.2. Marco Teórico	7
5.2.1 Contaminación atmosférica:	8
5.2.2. Contaminantes atmosféricos y sus fuentes:	8
5.2.3. Impacto en la salud de la contaminación atmosférica:	9
5.2.4. Impacto en salud pública:	9
5.2.5. Partículas de material particulado PM:	10
5.2.6. Machine learning:	11
5.2.7. Inteligencia artificial IA:	12
5.2.8. Redes neuronales artificiales:	12
5.2.9 Proceso de predicción:	13
5.2.10. Sensores:	14
5.2.11. Sensor fotoeléctrico:	14
5.2.12. Sensores de temperatura:	15
5.2.13. Sensores de humedad:	15
5.2.14. Sensor de Distancia Infrarrojo:	16
5.2.15 Sensores láser:	17
5.2.16. Sensores electroquímicos:	17
5.2.17. Sensores químicos:	17
5.3. Marco Legal	18
5.4. Marco Tecnológico	19
<b>6. Diseño de aspectos metodológicos</b>	<b>21</b>
6.1. Línea de investigación	21
6.2. Enfoque	21
6.3. Tipo de investigación	21
6.4. Método	21
6.5. Variables	23
<b>7. Elementos de administración y control</b>	<b>25</b>
7.1. Recursos físicos y técnicos	25
7.2. Talento humano	26
7.3. Presupuesto	26



7.4. Cronograma de actividades	28
<b>8. RESULTADOS</b>	<b>33</b>
8.1 Hardware utilizado para el montaje del dispositivo portable.	33
8.2 Conexiones realizadas para el montaje del prototipo.	38
8.3 Metodología toma de datos	42
8.4 Análisis de resultados	43
8.4.1 Red neuronal	43
8.4.2 Análisis predictivo	55
8.4.3 Análisis de pronóstico horas pico.	56
8.4.4 Comparación análisis de horas pico y horas no pico	63
8.4.5 Análisis de resultados por día.	69
8.4.6 Análisis por mes	72
8.4.7 Análisis relación día/mes/semestre	76
<b>9. CONCLUSIONES</b>	<b>84</b>
<b>10. Recomendaciones</b>	<b>87</b>
<b>11. ANEXOS</b>	<b>89</b>
ANEXO A. CÓDIGO ARDUINO UTILIZADO EN EL DISPOSITIVO	89
ANEXO B. CÓDIGO PYTHON RED NEURONAL	92
ANEXO C. Datos recolectados	93
ANEXO D. COMUNA 1 CIUDAD DE PASTO	94
ANEXO E. Información ST PASTO	95
<b>12. REFERENCIAS</b>	<b>96</b>



## Lista de figuras

Figura 1. Cronograma de actividades	28
Figura 2. Diagrama del código de Arduino	33
Figura 3. Dispositivo arduino uno	35
Figura 4. Sensor ZPHS01B	36
Figura 5. Modulo de arduino para tarjeta micro SD	36
Figura 6. Modulo cargador Bateria Litio Tp4056 Tipo C	37
Figura 7. Bateria de litio 18650	37
Figura 8. Conexiones realizadas para el montaje del prototipo.	38
Figura 9. Conexión con el módulo SD CARD y la placa Arduino.	39
Figura 10. Conexión completa del dispositivo para monitorear la calidad del aire	39
Figura 11. Diagrama de bloques, funcionamiento del dispositivo.	40
Figura 12. Dimensiones del dispositivo para monitorear la calidad del aire	40
Figura 13. Diagrama construcción de la red neuronal.	49
Figura 14. Tabla de índice de la calidad del aire.	50
Figura 15. Pronóstico para el año 2024 y 2028 CO <sub>2</sub> en hora pico.	52
Figura 16. Pronóstico para el año 2024 y 2028 CO en hora pico.	53
Figura 17. Pronóstico para el año 2024 y 2028 O <sub>3</sub> en hora pico.	54
Figura 18. Pronóstico para el año 2024 y 2028 NO <sub>2</sub> en hora pico.	55
Figura 19. Pronóstico para el año 2024 y 2028 PM <sub>2.5</sub> en hora pico.	56
Figura 20. Pronóstico para el año 2024 y 2028 PM <sub>10</sub> en hora pico.	57
Figura 21. Comparación de CO <sub>2</sub> en horas pico y no pico para el año 2024 y 2028.	58
Figura 22. Comparación pronóstico de CO en horas pico y no pico para el año 2024 y 2028.	59
Figura 23. Comparación pronóstico de O <sub>3</sub> en horas pico y no pico para el año 2024 y 2028.	60
Figura 24. Comparación pronóstico de NO <sub>2</sub> en horas pico y no pico para el año 2024 y 2028.	61
Figura 25. Comparación pronóstico de PM <sub>2.5</sub> en horas pico y no pico para el año 2024 y 2028	62
Figura 26. Comparación pronóstico de PM <sub>10</sub> en horas pico y no pico para el año 2024 y 2028.	63
Figura 27. Comparación pronóstico de PM <sub>2.5</sub> en horas pico y no pico para un día del siguiente año	64
Figura 28. Comparación pronóstico de PM <sub>10</sub> en horas pico y no pico para un día del siguiente año	65
Figura 29. Comparación pronóstico de PM <sub>10</sub> y PM <sub>2.5</sub> en horas pico para un mes en el 2024 y 2028	67
Figura 30. Comparación pronóstico de PM <sub>10</sub> y PM <sub>2.5</sub> en horas No pico para un mes en el 2024 y 2028	68
Figura 31. Relación entre día, mes y semestre para CO y CO <sub>2</sub> en hora pico 2024	70
Figura 32. Relación entre día, mes y semestre para O <sub>3</sub> y NO <sub>2</sub> en hora pico 2024	70
Figura 33. Relación entre día, mes y semestre para PM <sub>2.5</sub> y PM <sub>10</sub> en hora pico 2024	71
Figura 34. Relación entre día, mes y semestre para CO <sub>2</sub> y CO en hora no pico 2024	72
Figura 35. Relación entre día, mes y semestre para O <sub>3</sub> y NO <sub>2</sub> en hora no pico 2024	72
Figura 36. Relación entre día, mes y semestre para PM <sub>2.5</sub> y PM <sub>10</sub> en hora no pico 2024	73
Figura 37. Relación entre día, mes y semestre para CO <sub>2</sub> y CO en hora pico 2028	74



Figura 38. Relación entre día, mes y semestre para O3 y NO2 en hora pico 2028	74
Figura 39. Relación entre día, mes y semestre para PM2.5 y PM10 en hora pico 2028	75
Figura 40. Relación entre día, mes y semestre para CO2 y CO en no hora pico 2028	76
Figura 41. Relación entre día, mes y semestre para O3 y NO2 en hora no pico 2028	76
Figura 42. Relación entre día, mes y semestre para PM2.5 y PM10 en hora no pico 2028	77

PROHIBIDA SU COPIA



## Lista de tablas

Tabla 1. Presupuesto general	26
Tabla 2. Presupuesto técnico	27
Tabla 3. Costos de ejecución	27
Tabla 4. Cronograma de actividades	29
Tabla 5. Comparación entre valores reales y pronóstico para un día del año 2024	69
Tabla 6. Pronóstico para un día del año 2028	69
Tabla 7. Comparación del pronóstico respecto a los valores reales en hora pico y no pico	72
Tabla 8. Resultados del pronóstico de un mes del 2028 en hora pico y no pico	73

PROHIBIDA SU COPIA

## 1. Introducción

La calidad del aire en la ciudad de Pasto es un tema de suma relevancia, ya que tiene un impacto directo en la salud pública. La contaminación atmosférica es un factor crítico que está estrechamente relacionado con el desarrollo de enfermedades respiratorias, así como con un mayor riesgo de padecer infecciones respiratorias, enfermedades cardíacas, accidentes cerebrovasculares y cáncer de pulmón (*Calidad Del Aire OMS*, n.d.). Este contexto nos motiva a emprender una investigación exhaustiva sobre la contaminación del aire en distintos puntos de la ciudad.

En este proyecto, llevaremos a cabo una evaluación completa de los diversos contaminantes atmosféricos y su impacto en la salud de la población. Además, seleccionaremos y emplearemos sensores y dispositivos adecuados para construir un dispositivo portátil que permita medir variables clave, como el material particulado (PM<sub>2.5</sub>, PM<sub>10</sub>) y los gases contaminantes (CO<sub>2</sub>, O<sub>3</sub>, CO, NO<sub>2</sub>), cumpliendo con los estándares establecidos por el Ministerio de Ambiente de Colombia para garantizar una adecuada calidad del aire ambiente (Ministerio de Ambiente y Desarrollo Sostenible, 2019).

En este estudio, no solo nos limitaremos a recopilar datos, sino que también explicaremos de manera detallada el funcionamiento de cómo el dispositivo recopila información de las variables contaminantes. Esto incluirá una descripción de los sensores y la metodología utilizada para obtener las mediciones.

Además, profundizaremos en el proceso mediante el cual la red neuronal empleada realiza las predicciones. Explicaremos cómo esta red se entrena utilizando los datos recopilados y cómo utiliza esta información para generar un pronóstico de la calidad del aire en la ciudad de Pasto.





## 1. Planteamiento del problema

### 2.1. Descripción del problema

En un contexto de crecimiento constante de la población y el aumento correspondiente en el consumo y la emisión de gases y partículas contaminantes, se hace evidente la necesidad de monitorear y comprender la calidad del aire y el ambiente. Esto es esencial para tomar medidas tanto preventivas como correctivas que mejoren la salud y el bienestar de la población. Actualmente, existe un equipo de medición activo ubicado en la Universidad Mariana, conocido como SVCA (sistema de vigilancia de calidad del aire) encargado de analizar los datos de calidad del aire. Sin embargo, surge un problema: este equipo se encuentra en un punto que no representa las áreas más contaminadas de la ciudad, lo que afecta la representatividad de los datos. A pesar de que las condiciones meteorológicas en Pasto, con ráfagas de viento rápidas y espontáneas, evitan la acumulación de material particulado durante largos períodos (Benavides, 2019), es necesario realizar mediciones en áreas más afectadas por la contaminación, como las zonas de tráfico vehicular en las horas pico (6-8 AM, 12-1 PM y 6-8 PM) debido a que los vehículos genera una tasa elevada de desechos en el medio ambiente, que perjudica la salud humana (*Vista De Contaminación Ambiental Producida Por El Tránsito Vehicular Y Sus Efectos En La Salud Humana: Revisión De Literatura*, n.d.). Esto permitirá comprender la calidad del aire a la que están expuestos los habitantes.

En este contexto, es fundamental abordar el problema de la representatividad de los datos de calidad del aire en Pasto y proponer soluciones que contribuyan a una gestión más



efectiva de la contaminación atmosférica en la ciudad. Para ello, es necesario examinar en detalle la situación actual y desarrollar una metodología de muestreo adecuada que permita obtener una mayor cantidad de datos de la calidad del aire en diferentes áreas de Pasto. Además, se debe considerar la normativa internacional, en particular, los estándares de calidad del aire establecidos por la Organización Mundial de la Salud (OMS), que establecen límites máximos de  $75 \mu\text{g}/\text{m}^3$  y  $37.5 \mu\text{g}/\text{m}^3$  para PM10 y PM2.5, respectivamente, durante un período de 24 horas (Organización Mundial de la Salud, s.f.).

## **2.2. Formulación del problema**

¿De qué manera un dispositivo portable de medición podría realizar un pronóstico de la calidad del aire mediante Machine Learning en la ciudad de Pasto?

## 2. Justificación

El conocimiento de los niveles de contaminación del aire reviste una gran importancia, dado que constituye un factor determinante en el desarrollo de diversas enfermedades respiratorias. Por este motivo, es esencial concienciar a la población acerca de los niveles de contaminación del aire en la ciudad, con el fin de promover el cuidado del medio ambiente. La comprensión de la contaminación atmosférica nos permite prevenir y corregir problemas futuros a través de la implementación de medidas y el análisis estadístico, lo que nos llevará a encontrar soluciones para controlar los contaminantes atmosféricos. Para poder medir los niveles de contaminación del aire se necesita tener un dispositivo portable para poder ser trasladado a diferentes puntos de la ciudad que represente una mayor contaminación, con el fin de obtener mayor información de la calidad del aire actual. Según Corponariño el último informe sobre el estado de la calidad de aire se hizo en el año 2017 indicando una clasificación buena (Corporación Autónoma Regional de Nariño, 2017). Los datos recopilados por el dispositivo pueden utilizarse para realizar pronósticos futuros mediante el empleo de técnicas de Machine Learning. Para ello, es necesario recolectar una gran cantidad de datos que el sistema pueda analizar y utilizar para generar pronósticos automáticos, prescindiendo de la intervención humana. El uso de Machine Learning es crucial, ya que nos permite desarrollar un sistema capaz de aprender de manera autónoma y obtener resultados precisos. Las redes neuronales, en particular, han demostrado ser eficaces y versátiles en la aproximación de funciones en diversos tipos de datos, especialmente cuando se trata de patrones complejos entre las fuentes de emisión y las concentraciones de contaminantes atmosféricos (Correa, 2021). Estos pronósticos serían de gran importancia



para las entidades locales, como la Corporación Autónoma Regional de Nariño (Corponariño), la Secretaría de Gestión Ambiental de la Alcaldía de Pasto y la Secretaría de Ambiente y Desarrollo de la Gobernación de Nariño. Con base en los resultados obtenidos de estos pronósticos, estas entidades podrían tomar medidas efectivas para proteger a la población y el medio ambiente.

PROHIBIDA SU COPIA



### 3. Objetivos

#### 4.1. Objetivo General

Diseñar y construir un dispositivo portable para el monitoreo de la calidad del aire en la ciudad de Pasto.

#### 4.2. Objetivos específicos

- Investigar e identificar los estándares y las variables de la calidad del aire.
- Diseñar y construir un prototipo del dispositivo portable para la captura de datos y posterior análisis.
- Implementar el dispositivo para realizar las mediciones de la calidad del aire.
- Aplicar Machine Learning para que realice un pronóstico de la calidad del aire con los datos obtenidos por el dispositivo.
- Generar un análisis predictivo a partir de inteligencia artificial
- Comparar los resultados obtenidos del pronóstico en horas de alto flujo vehicular y horas de poco flujo vehicular.



## 5. Marco Referencial

### 5.1. Marco contextual

El proyecto se basa en un dispositivo portable para la medición y recolección de datos de las variables de material particulado ( $PM_{2.5}$ ,  $PM_{10}$ ) y de gases contaminantes ( $CO_2$ ,  $O_3$ ,  $CO$ ,  $NO_2$ ) para medir la calidad del aire en la ciudad de Pasto, principalmente en la comuna 1 (barrio centro, San Agustín, Parque Nariño) debido a que es una zona ubicada en el centro de la ciudad donde puede presentarse una mayor contaminación.

### 5.2. Marco Teórico

En Colombia, el monitoreo y control de la contaminación del aire cobra cada día más relevancia, pues según datos de la Organización Mundial de la Salud, una de cada ocho muertes en el mundo se debe a la contaminación del aire. Según el último informe sobre el estado de la calidad del aire elaborado por el Instituto (IDEAM), el contaminante con mayor potencial de afectar el territorio nacional es el material particulado menor a 2.5 micras ( $PM_{2.5}$ ), el cual está conformado por partículas muy diminutas, es generado principalmente por vehículos pesados que utilizan diésel como combustible y pueden transportar materiales muy peligrosos para el organismo como metales pesados, aleaciones, materia orgánica y virus, afectando así las vías respiratorias (Instituto de Hidrología, Meteorología y Estudios Ambientales, s.f.).

### **5.2.1 Contaminación atmosférica:**

La Organización Mundial de la Salud considera que la contaminación del aire es una prioridad de salud mundial. En un informe reciente, se estimó que la contaminación ambiental por material particulado causó el 1,4% de todas las muertes en el mundo. La contaminación del aire interior tendrá un mayor impacto, especialmente en los países en desarrollo. En definitiva, una gran parte de la población está expuesta a contaminantes atmosféricos que pueden tener efectos negativos en su salud. Las emisiones del aire asociadas con el cambio climático puede exacerbar los efectos de la contaminación en la atmósfera en la salud de los ciudadanos, no solo indirectamente debido al efecto sobre el clima sino inmediatamente por los efectos directos de los contaminantes sobre la salud (Ballester, s.f.).

### **5.2.2. Contaminantes atmosféricos y sus fuentes:**

Los contaminantes atmosféricos, habitualmente medidos en atmósferas urbanas, proceden de fuentes móviles (tráfico rodado) y fuentes fijas de combustión (uso industrial y residencial, climatización y tratamiento de residuos). Se hace una distinción entre contaminantes primarios y secundarios. Los primeros son los que provienen directamente de la fuente de emisión. Los contaminantes secundarios ocurren como resultado de cambios químicos y físicos y reacciones que sufrieron los principales contaminantes en la atmósfera, distinguiendo, sobre todo, la contaminación fotoquímica y ácida (Ballester, s.f.).

### **5.2.3. Impacto en la salud de la contaminación atmosférica:**

Los efectos sobre la salud son causados por la contaminación del aire. Es necesario darse cuenta de que todavía hay incertidumbre sobre los mecanismos fisiopatológicos de los contaminantes del aire. Sin embargo, se sabe que los efectos de la exposición a la contaminación del aire son muchos y de diversa gravedad, siendo los más perjudiciales para los sistemas respiratorio y circulatorio (Ballester, s.f.).

### **5.2.4. Impacto en salud pública:**

Desde una perspectiva de salud pública, es importante señalar que aunque la magnitud de los efectos sobre la salud es pequeña, la proporción de la contaminación del aire es significativa si toda la población está expuesta. Un estudio realizado en Francia, Suiza y Austria indica que el 6% de la tasa de mortalidad y una gran cantidad de nuevas enfermedades respiratorias en estos países se pueden atribuir a la contaminación del aire. La mitad de este efecto se debe a la contaminación emitida por los automóviles. Además de los efectos descritos anteriormente, es importante considerar el impacto potencial de la exposición a la contaminación del aire durante el embarazo y la niñez, como se muestra en varios estudios. Una revisión reciente del tema encontró hallazgos que relacionan la exposición a la contaminación del aire en bebés con bajo peso al nacer y el retraso del crecimiento intrauterino, así como los efectos de la exposición a la contaminación del aire y un impacto temprano en la salud de los niños, incluido el aumento de la mortalidad. Conjuntamente con la Cumbre Interministerial de Budapest en junio de 2004, se presentó un informe sobre la evaluación de la carga para la salud de los niños expuestos a determinados entornos en Europa. Resultados similares indican que en los niños europeos de 0 a 4 años,



entre el 1,8% y el 6,4% de todas las muertes son atribuibles a la contaminación del aire exterior y el 4,6% a la exposición a la contaminación del aire interior en edificios. La existencia de situaciones de mala calidad del aire o posible deterioro puede perjudicar significativamente la salud de los niños y las generaciones futuras (Ballester, s.f).

#### 5.2.5. Partículas de material particulado PM:

Las partículas finas se pueden definir como partículas de polvo, ceniza, hollín, partículas metálicas, cemento o polen dispersas en la atmósfera, cuyo diámetro oscila entre 2,5 y 10 metros (1 micrómetro corresponde a una milésima de milímetro). Está compuesto principalmente por compuestos inorgánicos como silicatos y aluminatos, metales pesados, entre otros, y materia orgánica ligada a moléculas de carbono (hollín). Se distinguen por un pH básico debido a la combustión incontrolada de materiales.

- **PM<sub>10</sub>**: PM<sub>10</sub> se puede definir como partículas de polvo, ceniza, hollín, metal, cemento o polen dispersas en la atmósfera con un diámetro de 2,5 a 10 micrómetros.
- **PM<sub>2,5</sub>**: se puede definir como partículas sólidas o líquidas dispersas en la atmósfera y tienen un diámetro de 2,5 micrómetros o menos.
- **Partículas O<sub>3</sub>**: el ozono es un poderoso oxidante formado a través de una serie de reacciones fotoquímicas complejas que incluyen la luz solar, el dióxido de nitrógeno (NO<sub>2</sub>) y compuestos orgánicos volátiles. Por tanto, es un contaminante secundario formado a partir de contaminantes primarios cuando se dan las condiciones atmosféricas adecuadas.

- **El  $O_3$ :** el ozono es un poderoso oxidante formado a través de una serie de reacciones fotoquímicas complejas que incluyen radiación solar, dióxido de nitrógeno ( $NO_2$ ) y compuestos orgánicos volátiles.
- **Partículas  $NO_2$ :** es un compuesto químico gaseoso de color marrón amarillento formado por la unión de un átomo de nitrógeno y dos átomos de oxígeno. Es un gas tóxico e irritante. El  $NO_2$  junto al NO-óxido nitroso son conocidos como  $NO_2$  y son algunos de los principales contaminantes en zonas urbanas. En la naturaleza, es creado por incendios forestales o erupciones volcánicas. También se produce de forma natural mediante la descomposición de nitratos orgánicos. La masa total que ocurre en la naturaleza es infinitamente menor que la masa producida por la influencia humana.
- **Monóxido de carbono:** el CO es un gas venenoso, inodoro, incoloro e insípido, parcialmente soluble en agua, alcohol y benceno, debido a la combustión incompleta del carbono oxidado (Camilo, s.f.)

#### 5.2.6. Machine learning:

Es una rama de la inteligencia artificial que se encarga de crear algoritmos que son capaces de aprender sin tener que programarlos explícitamente. Los desarrolladores no tendrán que sentarse a programar durante horas mirando todos los escenarios posibles y todas las excepciones posibles. Basta con darle al algoritmo una enorme cantidad de datos para que el algoritmo aprenda y sepa qué hacer en cada uno de estos casos. Fases de desarrollo. Etapa de entrenamiento: en este punto hay una gran cantidad de datos, parte de los cuales se descomponen para entrenar al algoritmo y darle toda esta información hasta que encuentre los



patrones necesarios y luego pueda hacer predicciones. Etapa de prueba: el resto de los datos se utilizarán para las pruebas. De esta forma, podemos cuestionar el algoritmo y evaluar si las respuestas son verdaderas o falsas, y si está aprendiendo. Si encontramos que los datos no coinciden, necesitaremos agregar más datos o cambiar el método que estamos usando. Pero si observamos que hay un 80% a 90% de respuestas correctas, podemos decir que hay un buen nivel de aprendizaje y podemos usar este algoritmo (Serrano & Judith, 2018).

#### **5.2.7. Inteligencia artificial IA:**

La inteligencia artificial es la capacidad de las máquinas para usar algoritmos, comprender los datos y usar lo que aprenden para tomar decisiones como lo hacen los humanos. Sin embargo, a diferencia de los humanos, las máquinas basadas en IA no necesitan descansar y pueden analizar grandes cantidades de información simultáneamente. Además, la tasa de error es considerablemente menor en las máquinas que realizan las mismas labores que sus contrapartes humanas (Rouhiainen, 2018, 17).

#### **5.2.8. Redes neuronales artificiales:**

Las ANN se basa en una analogía existente en el comportamiento y función del cerebro humano, específicamente el sistema nervioso, el cual está formado por redes neuronales biológicas con bajo poder de procesamiento, pero todas con capacidades cognitivas, cuyo conocimiento se basa en su conexión. Las ANN es un método de resolución de problemas, solo o en combinación con otros procedimientos, para tareas de clasificación, identificación, diagnóstico, optimización o predicción donde el balance de

datos/conocimiento se inclina hacia los datos, además, puede haber la necesidad de aprendizaje en tiempo de ejecución y de cierta tolerancia a fallos. En estos casos, las ANN se adaptan dinámicamente, ajustando constantemente el "peso" de las conexiones entre ellas. Es importante enfatizar que la propiedad más importante de una red neuronal artificial es su Inteligencia de aprendizaje de un conjunto de modelos de aprendizaje, es decir, pueden encontrar uno que se ajuste a los datos. El Desarrollo de aprendizaje, también conocido como formación en red, puede ser supervisado o no supervisado (Salas, s.f.).

#### **5.2.9 Proceso de predicción:**

Los sistemas de predicción están diseñados por medio de inteligencia artificial gracias al aprendizaje automático llamado machine learning. Estos sistemas de aprendizaje automático pueden hacer predicciones como la falla en algún equipo tecnológico, la predicción del tráfico urbano, predecir las ventas de los años siguientes analizando el comportamiento actual de los clientes, pronósticos meteorológicos, entre otras aplicaciones. El aprendizaje automático permite que las máquinas hagan predicciones precisas. Para ello, el aprendizaje automático utiliza diversas técnicas, como el modelado estadístico, Redes neuronales (ANN), máquinas de vectores de soporte (SVM) o herramientas de agregación (clusters) para ser capaz de predecir situaciones a partir de la experiencia adquirida (Camilo, s.f.). Se realizó la investigación de diferentes clases de sensores, para permitir la selección de los tipos de sensores que nos pueden ser útiles para la construcción del dispositivo.

#### **5.2.10. Sensores:**

Los sensores son los dispositivos que recopilan información, es decir, proporcionar señales de entrada al bloque de control para que pueda determinar el orden de salida. Esta disposición de salida se convierte en una señal eléctrica que se envía a un actuador que convierte la energía eléctrica en otra forma de energía. La unidad de control consta de un microprocesador, que es un conjunto de dispositivos semiconductores encapsulados en un solo chip, que en base a ellos, evalúa datos y señales externas, para generar un conjunto de datos y señales para su transmisión al exterior. Esta tarea se llama procesamiento de datos, y para “saber” qué hacer con ellos, necesitas un programa que siempre te diga cómo, cuándo y dónde actuar. Un programa consiste en una serie de comandos o instrucciones escritos en un lenguaje comprensible por máquina (un lenguaje de programación) y registrados de forma segura contra cualquier posible borrado del mismo (Guarella et al., 2011)..

#### **5.2.11. Sensor fotoeléctrico:**

Una LDR (Light Dependent Resistor) o fotorresistencia es un componente electrónico que cambia su resistencia dependiendo de la luz que llega a la superficie del dispositivo. Cuanto más intensa es la luz, menos resistencia tiene, y cuanto menos luz cae sobre ella, mayor es la resistencia. A pesar de ser un componente electrónico bastante simple, la fotorresistencia o LDR tiene muchas aplicaciones. Porque se pueden utilizar para iluminación, interruptores de luz, sirenas, cámaras fotográficas, entre otras aplicaciones. También en el rango infrarrojo, se utilizan en el control de máquinas y procesos de detección y conteo de objetos (Ruiz et al., 2010).

### **5.2.12. Sensores de temperatura:**

El sensor analógico LM335 es un sensor de temperatura calibrado a  $1^{\circ}\text{C}$  y tiene un rango de  $-40^{\circ}$  a  $100^{\circ}\text{C}$ . Viene en una variedad de paquetes, pero el más común es el TO-92, dos de los cuales lo alimentan y el tercero nos da un valor de voltaje proporcional a la temperatura medida por el dispositivo. Funciona como un diodo Zener y su voltaje de ruptura es proporcional a la temperatura. El LM335 cambia el voltaje en  $10\text{ mV}$  por cada grado Celsius, muestra una lectura de 0 voltios a  $0^{\circ}\text{K}$  ( $-273^{\circ}\text{C}$ ) y puede suministrar  $400\mu\text{A}$  y  $5\text{ mA}$ . Sensor digital LM77: es un sensor de temperatura digital con un bus de  $12\text{C}$ . La interrupción de salida se activa cuando la temperatura excede el valor programado y también tiene una alarma crítica que activa la salida cuando la temperatura excede el límite programable crítico. La salida INT puede operar en modo comparador o modo evento, mientras que la salida opera solo en modo comparador. Tiene dos pines (AO, A1) para la selección de direcciones. Su funcionamiento típico es de  $-10^{\circ}\text{C}$  a  $64^{\circ}\text{C}$  con una desviación de  $1,5^{\circ}\text{C}$  y una temperatura crítica de  $80^{\circ}\text{C}$ , aunque su rango máximo de funcionamiento es de  $-55^{\circ}\text{C}$  a  $125^{\circ}\text{C}$  con una desviación de  $3^{\circ}\text{C}$ . El voltaje de funcionamiento es de  $3\text{V}$  a  $5,5\text{ V}$ , la corriente es de  $250\mu\text{A}$  a  $500\mu\text{A}$  y proporciona información de 9 bits más el signo. Las aplicaciones más comunes son componentes de protección para ordenadores personales, equipos electrónicos de oficina, automóviles, etc (Ruiz et al., 2010, 45).

### **5.2.13. Sensores de humedad:**

El sensor de humedad HCH 1000 es un sensor capacitivo diseñado para medir la humedad relativa basado en el principio de que la capacitancia de un capacitor cambia a

medida que cambia la constante dieléctrica del capacitor. Para convertir los cambios de capacitancia en variables eléctricas, puede usar un puente de Wheatstone de capacitor, un circuito resonante o un oscilador estable que cambie su frecuencia de acuerdo con los cambios en el contenido de humedad del capacitor. Debido a que descubrimos que está hecho de un semiconductor, es muy inmune a los cambios de temperatura y responde muy rápido. Entre sus aplicaciones tenemos estaciones meteorológicas, automoción, médicas, deshumidificadores, etc. Sensor de humedad y temperatura SHT71: este sensor SHT71 es uno de los sensores más versátiles y extendidos del mercado para medir la humedad y la temperatura. La unidad está alojada en un pequeño paquete de 4 pines y es digital, mostrando lecturas de 8, 12 ó 14 dígitos, cada una calibrada individualmente. Entre sus características está el uso de una fuente de alimentación de 2,4 V a 5,5 V, un consumo de energía típico de 30 uW y un rango de temperatura de funcionamiento de -40 °C a 123,8 °C. Se utilizan más comúnmente en estaciones meteorológicas, humidificadores y dispositivos médicos (Ruiz et al., 2010).

#### **5.2.14. Sensor de Distancia Infrarrojo:**

Los sensores de distancia infrarrojos miden la distancia utilizando un haz de ondas electromagnéticas cuya longitud de onda corresponde al espectro infrarrojo. El principio de funcionamiento es similar al ultrasonido, excepto que en lugar de enviar rayos ultrasónicos y esperar a que reboten, emiten rayos infrarrojos y esperan a que reboten. Los sensores infrarrojos, por otro lado, se pueden dividir en sensores activos, que consisten en un LED infrarrojo como transmisor y un fototransistor como receptor, y sensores pasivos, que

consisten solo en fototransistores y están diseñados para recibir la radiación emitida por otros (González & Javier, 2015).

#### **5.2.15 Sensores láser:**

Un sensor láser consta de un transmisor y un receptor. Los láseres calculan distancias emitiendo pulsos de radiación láser invisible. Cuando este pulso descubre un objeto en su vía, se refleja. El reflejo vuelve al dispositivo, que lo registra mediante un receptor de luz láser. La diferencia de tiempo entre los rayos emitidos y reflejados se puede utilizar para calcular la distancia al objeto. Los láseres funcionan según el mismo principio que los sensores ultrasónicos o los sensores infrarrojos. La principal diferencia entre los láseres y estos sistemas es el tipo de radiación utilizada. Este sensor utiliza una longitud de onda específica de radiación y un sistema de lentes (que en última instancia forma el rayo láser) para dirigir con precisión esa radiación (González & Javier, 2015).

#### **5.2.16. Sensores electroquímicos:**

Los sensores electroquímicos se dividen en potenciómetros, voltímetros y conductímetros. El mecanismo de acción depende principalmente de los principios físicos que los rigen según su clasificación y muestran algunas similitudes en las señales de medición.

#### **5.2.17. Sensores químicos:**

Es un dispositivo que proporciona una respuesta en tiempo real cuando se recibe un estímulo químico. En general, permite la conversión directa de la concentración de entidades químicas en fase gaseosa o líquida en señales físicas (García, 2008).



### 5.3. Marco Legal

**Resolución 2254 de 2017.** "Por la cual se adopta la norma de calidad del aire ambiente y se dictan otras disposiciones."La resolución es importante porque establece la norma de calidad del aire y adopta disposiciones para la gestión del recurso del aire a nivel nacional para garantizar una buena calidad de aire y disminuir las enfermedades a causa de los contaminantes en el ambiente, igualmente se establecen los niveles máximos permisibles de contaminantes desde el año 2018. Se establecen los estándares de contaminantes para el año 2030 y los niveles de emergencia de contaminantes (Ministerio de Ambiente y Desarrollo Sostenible, 2017).

**Resolución 650 de 2010.** "Por la cual se adopta el Protocolo para el Monitoreo y Seguimiento de la Calidad del Aire" establece las directrices, metodologías y procedimientos necesarios para llevar a cabo las actividades de monitoreo y seguimiento de la calidad del aire en el territorio nacional (Ministerio de ambiente, vivienda y desarrollo territorial, 2010).

**Resolución 2154 de 2010.** "Por la cual se ajusta el Protocolo para el Monitoreo y Seguimiento de la Calidad del Aire adoptado a través de la Resolución 650 de 2010 y se adoptan otras disposiciones" (Ministerio de Ambiente y Desarrollo Sostenible, 2010).

**Artículo 8 del Decreto-ley 2811 de 1974.** "Por el cual se dicta el Código Nacional de Recursos Naturales Renovables y de Protección al Medio Ambiente" (Decreto, 18 de diciembre de 1974.).

#### 5.4. Marco Tecnológico

**El sensor de polvo láser PM<sub>2.5</sub>:** es un sensor de concentración de partículas universal digital que puede obtener la cantidad de partículas suspendidas en el aire en el rango de 0,3 a 10 micras, es decir, la concentración de partículas y salida con interfaz digital. También puede generar datos de calidad para cada partícula. El sensor se puede integrar en varios instrumentos ambientales, partículas transportadas en el aire para proporcionar datos de concentración adecuados y precisos (*Gravity: Laser PM2.5 Air Quality Sensor For Arduino*, s.f.).

**Sensor todo en uno de calidad del aire ZPHS 01B:** “este módulo de calidad del aire, 15 integra sensor de polvo láser, sensor de dióxido de carbono infrarrojo, sensor de formaldehído electroquímico, sensor de ozono electroquímico, sensor de monóxido de carbono electroquímico, sensor de COV, sensor de NO<sub>2</sub> y sensor de temperatura y humedad. Puede medir con precisión la concentración de varios gases en el aire, con la interfaz de comunicación UART (nivel TTL)” (*ZPHS01B Multi-In-One Air Quality Monitoring Sensor Module--Winsen*, s.f.)

**Python:** Python es un lenguaje de programación creado por Guido van Rossum a principios de la década de 1990, y su nombre se inspiró en el grupo de dibujos animados británico "Monty Python". Es un lenguaje similar a Perl, pero con una sintaxis muy concisa que facilita la lectura del código. Es un lenguaje interpretado o de secuencias de comandos que está tipado dinámicamente, fuertemente tipado, multiplataforma y orientado a objetos.



Python es un lenguaje que todo el mundo debería conocer. Su sintaxis es limpia y concisa; la escritura dinámica, la administración de la memoria, la amplia gama de bibliotecas disponibles, el poder del lenguaje y más hacen que el desarrollo de aplicaciones en Python sea fácil, rápido y lo que es más importante, divertido (Duque, 2011).

**Arduino:** Arduino es una plataforma de creación de prototipos electrónicos de código abierto basada en hardware y software flexible y fácil de usar. Arduino puede detectar el entorno al recibir información de varios sensores y puede afectar el entorno mediante el control de luces, motores y otros artefactos. El microcontrolador de la placa se programa utilizando el lenguaje de programación Arduino. Las placas se pueden ensamblar a mano o se pueden pedir completamente ensamblados; el software está disponible como descarga gratuita. Los modelos de referencia de hardware (archivos CAD) están disponibles bajo una licencia de código abierto para que pueda adaptarse libremente a sus necesidades (Herrador, 2009). Arduino es compatible con varios módulos como por ejemplo un módulo SD CARD, que se conecta directamente a la placa de Arduino para almacenar información mediante una memoria SD, utilizando esto se podrá guardar gran cantidad de datos útiles para el proyecto en el que se esté trabajando (Fernández, 2018).

## 6. Diseño de aspectos metodológicos

### 6.1. Línea de investigación

**Diseño y modelado de sistemas y equipos electrónicos:** Con la sublínea de investigación- Prototipos de máquinas y herramientas para instrumentación electrónica. Se escoge esta línea de investigación porque se va a construir un dispositivo electrónico donde tiene un enfoque hacia la instrumentación electrónica con la utilización de sensores, para medir datos y generar un análisis con Machine Learning.

### 6.2. Enfoque

Este proyecto tiene un enfoque cuantitativo. Porque se aspira realizar mediciones y recolección de datos acerca de las variables de la calidad del aire. Posteriormente se desarrollará un análisis de datos con métodos estadísticos tradicionales.

### 6.3. Tipo de investigación

Este proyecto está enfocado en el tipo de investigación experimental y de campo porque permite investigar y recolectar datos de mediciones acerca del material particulado presente en el sitio donde existe la problemática. En este proyecto se utilizará un sensor capaz de recolectar datos, además de utilizar procesos estadísticos en el algoritmo de predicción para el análisis de datos.

### 6.4. Método

**Etapas 1 - investigar e identificar los estándares y las variables de la calidad del aire:** en esta etapa se lleva a cabo toda la investigación sobre la información acerca de los estándares de la calidad del aire e identificación de las variables a medir. Se investigan los riesgos que existen en la salud de las personas al estar expuestas a un aire contaminado con

material particulado, además de esto se recopila información de los sensores disponibles en el mercado esto con el fin de ordenar las ideas acerca del funcionamiento de cada sensor.

Posteriormente se realiza una investigación de los diferentes software para utilizar Machine Learning para desarrollar métodos estadísticos y un buen pronóstico con inteligencia artificial.

**Etapa 2 - Diseñar y construir un prototipo del dispositivo portable para la captura de datos y posterior análisis:** en esta etapa consultaremos y seleccionaremos los materiales necesarios para diseñar el prototipo, además se desarrollará un esquema del circuito para que sirva de guía en el momento de construcción y evitar cualquier margen de error, posteriormente se elabora el circuito del prototipo y se trabaja en todos sus acabados para realizar las respectivas pruebas de su correcto funcionamiento.

**Etapa 3 - Implementar el dispositivo para realizar las mediciones de la calidad del aire:** en esta fase del proyecto consiste en la recolección y toma de datos por el cual están localizados en la zona afectada por la problemática. Cabe resaltar que los datos serán tomados en diferentes puntos para garantizar un resultado con mayor eficiencia y realista acerca de la contaminación del aire.

**Etapa 4 - aplicar Machine Learning para que realice un pronóstico de la calidad del aire con los datos obtenidos por el dispositivo:** en esta etapa se basa en la parte de programación del algoritmo capaz de aprender utilizando Machine Learning, se entrenará con los datos obtenidos durante el trabajo de campo, para que tenga la capacidad de aprender y hacer un análisis de estos y realizar un pronóstico acertado a futuro.

**Etapa 5 - Comparación de los resultados obtenidos con los métodos tradicionales (métodos estadísticos):** por último los resultados obtenidos se comparan con los resultados de alto flujo vehicular con los resultados de poco flujo vehicular.

### 6.5. Variables

**Material particulado  $PM_{2,5}$ :** El material particulado varían en tamaño, en este caso son partículas finas menos de 2,5 micras. es un grupo de partículas sólidas y líquidas (excluyendo el 18 agua purificada) directamente al aire, como hollín de diésel, polvo de carreteras, polvo agrícola y partículas de procesos de fabricación, así como de actividades naturales como emisiones volcánicas y partículas transportadas por el viento (ARCINIEGAS, 2012).

**Material particulado  $PM_{10}$ :** Las partículas  $PM_{10}$  son partículas con un diámetro menor a 10 micras puesto que pueden contener contaminantes como ciertos tipos de hidrocarburos y metales pesados como Plomo, Zinc, Manganeso, Cobre y Cromo que, dependiendo de su concentración, tiempo de exposición y toxicidad, pueden ser fatales o causar serios problemas de salud a corto o largo plazo, y cabe señalar que no solo afectan el cuerpo humano es perjudicial para la salud de todos los seres vivos (Trujillo et al., 2020).

**Dióxido de carbono  $CO_2$ :** El dióxido de carbono ( $CO_2$ ) es un gas incoloro a presión y temperatura normales. Compuesto por un átomo de carbono y dos átomos de oxígeno, está presente en la atmósfera, la biosfera, la hidrosfera y la litosfera y es parte importante del ciclo de vida de la Tierra, pero su aumento constante provoca graves problemas como lo son la

contaminación y el calentamiento global (Sancarranco, 2022). Las principales Emisiones de  $\text{CO}_2$  son por extracción, transporte y producción de materiales de construcción. Se encontró que todas las etapas de extracción, molienda y transporte eran iguales, siendo la final y el acabado de cemento la etapa que produjo la mayor cantidad de  $\text{CO}_2$  (Burgos, 2022).

**Ozono( $\text{O}_3$ ):** El ozono es considerado uno de los gases más importantes para la vida en la Tierra. La superficie de la tierra es la forma molecular del oxígeno, que consta de tres átomos ( $\text{O}_3$ ) es un gas a presión y temperatura normales incoloro, olor acre y puede ser tóxico si se inhala en cantidades altas. La fuente de ozono en cada capa de la atmósfera es muy diferente, En la estratosfera es el resultado de la fotólisis del oxígeno, mientras que en la estratosfera La troposfera es el resultado de la reacción de los productos de la combustión, Aunque naturalmente hay una pequeña producción. En la troposfera, el ozono es un contaminante atmosférico peligroso que puede causar Daños crecientes a personas, animales, vegetación y materiales Concentración de ozono superficial que provoca reacciones fotoquímicas de smog se produce debido al aumento de la contaminación del aire. Generalmente hablando, temperatura y calefacción urbana a largo plazo. La concentración de ozono aumenta debido al calor acelerando Reacciones químicas en la atmósfera. El valor de concentración más alto del ozono en entornos urbanos se produce principalmente por radiación. Energía solar y gases de efecto invernadero (Solis, 2018).

**Monóxido de carbono (CO):** El monóxido de carbono también denominado óxido de carbono (II), gas carbonoso y anhídrido carbonoso (los dos últimos cada vez más en desuso) cuya fórmula química es  $\text{CO}$ , es un gas inodoro, incoloro, inflamable y altamente tóxico.

Puede causar la muerte cuando se respira en niveles elevados. Se produce por la combustión incompleta de sustancias como gas, gasolina, keroseno, carbón, petróleo, tabaco o madera. Las chimeneas, las calderas, los calentadores de agua o calefones y los aparatos domésticos que queman combustible, como las estufas u hornallas de la cocina o los calentadores a kerosina, también pueden producirlo si no están funcionando bien. Los vehículos detenidos con el motor encendido también lo despiden. También se puede encontrar en las atmósferas de las estrellas de carbono"(Gil & Alvarez, 2012)

**Dióxido de nitrógeno (NO<sub>2</sub>):** Se producen quemando combustible en vehículos, centrales eléctricas e industrias. En la naturaleza, ocurren durante los incendios forestales, los rayos y la descomposición de las plantas. Estos gases también contribuyen a la formación de ozono a nivel del suelo (ozono troposférico). Los óxidos de nitrógeno también hacen que los niños sean vulnerables a las infecciones respiratorias en invierno (Menéndez et al., s.f.).

## **7. Elementos de administración y control**

### **7.1. Recursos físicos y técnicos**

Los recursos físicos son las instalaciones, equipos y herramientas que utilizaremos para el desarrollo del proyecto. Como recursos físicos tenemos:

- Laboratorio de electrónica
- Computador
- Sensores de la calidad del aire
- Placa Arduino y extensiones



- Batería
- Varios (Cables, caja, etc.)

Los recursos técnicos son herramientas o equipos auxiliares que nos ayudaran para la construcción del proyecto. Como recursos técnicos tenemos:

- Equipos y herramientas del laboratorio de electrónica: osciloscopio, multímetro, cautín, etc.
- Teléfono móvil
- Software

## 7.2. Talento humano

Como grupo de profesionales e investigadores encargados de llevar a cabo con el desarrollo del proyecto tenemos:

- Asesor técnico: Luis Rosero
- Asesor metodológico: Jorge Andrés Segovia
- Personal encargado del laboratorio
- Investigadores: Jaime Andrés Jurado Arévalo, Juan Sebastian Torres Velasquez

## 7.3. Presupuesto

**Tabla 1**

*Presupuesto general*

<b>Item</b>	<b>Nombre</b>	<b>Valor</b>
1	Costos técnicos	655000
2	Costos de ejecución	81000
<b>Valor total</b>		<b>736000</b>

*Nota.* Fuente: autoría propia

**Tabla 2.** *Presupuesto técnico*

<b>Ítem</b>	<b>Elemento</b>	<b>Unidad</b>	<b>Valor de la unidad</b>	<b>Valor total</b>
1	Sensor ZPHS01B	1	490000	490000
2	Arduino	1	70000	70000
3	Bateria de alimentacion	1	40000	40000
4	Adaptador SD de Arduino	1	5000	5000
5	Gastos varios (cables, accesorios, caja, etc)	1	50000	50000
<b>Valor total</b>				<b>655000</b>

*Nota.* Fuente: autoría propia

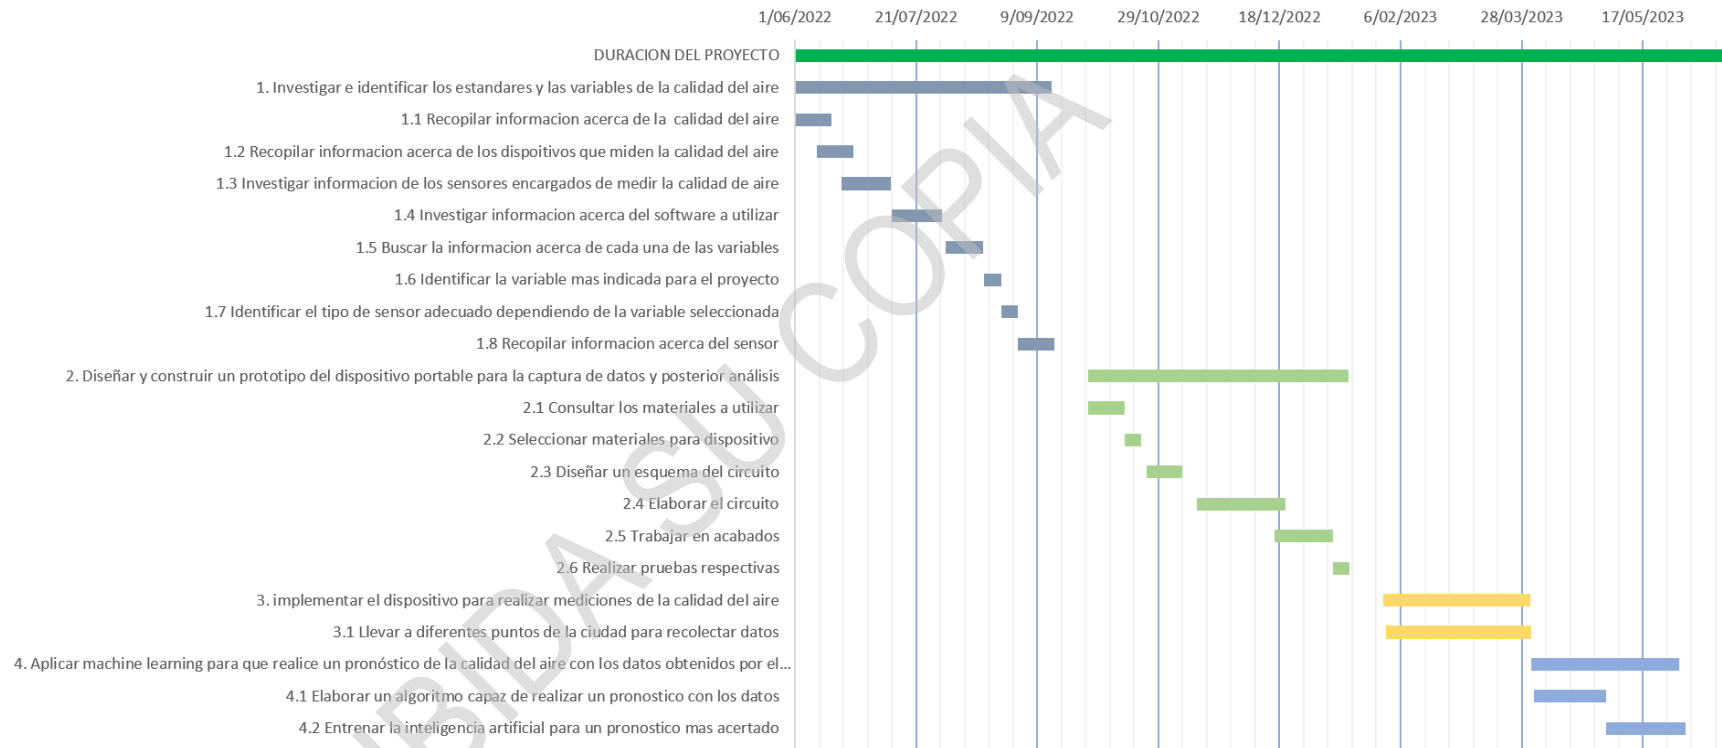
**Tabla 3.** *Costos de ejecución*

<b>Ítem</b>	<b>Descripción</b>	<b>Estudiante</b>	<b>AUNAR</b>	<b>Valor total</b>
1	Materiales	\$20000	\$0	\$20000
2	Servicios de envío	\$35000	\$0	\$35000
3	Gastos recolección de datos	\$26000	\$0	\$26000
4	Procesamiento de datos	\$0	\$0	\$0
5	Análisis de datos	\$0	\$0	\$0
<b>Total</b>				<b>\$81000</b>

*Nota.* Fuente: autoría propia

### 7.4. Cronograma de actividades

Figura 1. Cronograma de actividades



Nota. Cronograma de las actividades a desarrollar en el proyecto. Fuente: autoría propia

**Tabla 4.***Cronograma de actividades*

ACTIVIDAD	FECHA INICIO	DURACIÓN DÍAS	FECHA FIN
DURACIÓN DEL PROYECTO	1/06/2022	384,5	20/06/2023
<b>1. Investigar e identificar los estándares y las variables de la calidad del aire</b>	<b>1/06/2022</b>	<b>106,00</b>	<b>15/09/2022</b>
1.1 Recopilar información acerca de la calidad del aire	1/06/2022	15,00	16/06/2022
1.2 Recopilar información acerca de los dispositivos que miden la calidad del aire	10/06/2022	15,00	25/06/2022
1.3 Investigar información de los sensores encargados de medir la calidad de aire	20/06/2022	20,50	10/07/2022
1.4 Investigar información acerca del software a utilizar	11/07/2022	20,50	31/07/2022



1.5 Buscar la información acerca de cada una de las variables	2/08/2022	15,50	17/08/2022
1.6 Identificar la variable más indicada para el proyecto	18/08/2022	7,00	24/08/20 22
1.7 Identificar el tipo de sensor adecuado dependiendo de la variable seleccionada	25/08/2022	7,00	31/08/2022
1.8 Recopilar información acerca del sensor	1/09/2022	15,00	15/09/2022
<b>2. Diseñar y construir un prototipo del dispositivo portable para la captura de datos y posterior análisis</b>	<b>30/09/2022</b>	<b>107,63</b>	<b>15/01/2023</b>
2.1 Consultar los materiales a utilizar	30/09/2022	15,00	15/10/2022
2.2 Seleccionar materiales para dispositivo	15/10/2022	7,00	22/10/2022
2.3 Diseñar un esquema del circuito	24/10/2022	15,00	8/11/2022
2.4 Elaborar el circuito	14/11/2022	36,50	20/12/2022



2.5 Trabajar en acabados	16/12/2022	24,00	8/01/2023
2.6 Realizar pruebas respectivas	9/01/2023	7,00	15/01/2023
<b>3. implementar el dispositivo para realizar mediciones de la calidad del aire</b>	<b>30/01/2023</b>	<b>60,63</b>	<b>31/03/2023</b>
3.1 Llevar a diferentes puntos de la ciudad para recolectar datos	31/01/2023	60,00	31/03/2023
<b>4. Aplicar machine learning para que realice un pronóstico de la calidad del aire con los datos obtenidos por el dispositivo</b>	<b>1/04/2023</b>	<b>61,00</b>	<b>1/06/2023</b>
4.1 Elaborar un algoritmo capaz de realizar un pronóstico con los datos	2/04/2023	30,00	2/05/2023
4.2 Entrenar la inteligencia artificial para un pronóstico más acertado	2/05/2023	32,50	3/06/2023



<b>5. Comparar los resultados obtenidos del pronóstico en horas de alto flujo vehicular y horas de poco flujo vehicular.</b>	<b>5/06/2023</b>	<b>15,00</b>	<b>20/06/2023</b>
5.1 comprobar y realizar conclusiones con los resultados obtenidos	5/06/2023	15,00	20/06/2023

*Nota.* Fuente: autoría propia

PROHIBIDA SU COPIA

## 8. RESULTADOS

Para el desarrollo del trabajo de grado se creó un prototipo para el monitoreo de la calidad del aire, es un prototipo enfocado principalmente en la captura de datos en diferentes puntos de la ciudad para garantizar un pronóstico más acertado.

Luego de evaluar diversas alternativas en la implementación del dispositivo, Las herramientas utilizadas y el precio determinó que se puede realizar un dispositivo de monitoreo de la calidad del aire con los siguientes elementos:

### 8.1 Hardware utilizado para el montaje del dispositivo portable.

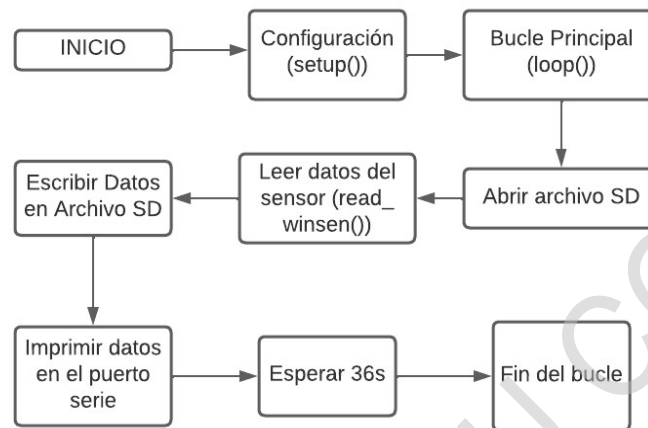
#### *Arduino uno*

La placa Arduino desempeña un papel fundamental en nuestro proyecto al ejecutar el código previamente programado que contiene todas las instrucciones necesarias para establecer una comunicación efectiva con el módulo de sensores. Este módulo se encarga de medir las variables relacionadas con la calidad del aire. Una vez que se establece la comunicación, realizamos pruebas para verificar que todo funcione.



**Figura 2**

*Diagrama del código de Arduino*



*Nota.* Bloques del código. Fuente: autoría propia

### **Explicación de los bloques:**

#### ***Bloque 1: Inicio***

Este es el punto de inicio del programa Arduino.

#### ***Bloque 2: Configuración (setup())***

En esta sección, se realizan las configuraciones iniciales, como la inicialización de la comunicación serial, la inicialización de la tarjeta SD y la inicialización de la comunicación con el sensor Winsen.

#### ***Bloque 3: Bucle Principal (loop())***

Aquí es donde ocurre la mayoría de la actividad del programa. Se ejecuta de forma continua. En este bucle, se realiza una secuencia de acciones que incluyen la apertura de un archivo, la lectura de datos del sensor Winsen con sus respectivas unidades de medición, la escritura de datos en el archivo SD, la impresión de datos en el puerto serie y la espera de aproximadamente 36 segundos antes de volver a comenzar.

#### ***Bloque 4: Abrir Archivo SD***

Aquí se abre el archivo "Datos.txt" en modo escritura para prepararlo para recibir datos. Si se puede abrir con éxito, se procede a escribir en él.

#### ***Bloque 5: Leer Datos del Sensor (read\_winsen())***

Se llama a la función "read\_winsen()" para enviar comandos al sensor Winsen, leer su respuesta y procesar los datos del sensor.

#### ***Bloque 6: Escribir Datos en Archivo SD***

Se escriben los datos leídos del sensor en el archivo abierto en el paso anterior. Los datos incluyen un sello de tiempo y lecturas de varios sensores. El Arduino se encarga de abrir, escribir y cerrar el archivo en la tarjeta SD.

#### ***Bloque 7: Imprimir Datos en el Puerto Serie***

Los mismos datos que se escriben en el archivo SD se imprimen en el puerto serie para su visualización en la consola de Arduino.

#### ***Bloque 8: Esperar 36 segundos***

Se utiliza un bucle para esperar un tiempo antes de volver a iniciar el ciclo. Esto asegura que las lecturas y escrituras se realicen aproximadamente cada 36 segundos.

#### ***Bloque 9: Fin del Bucle***

El programa vuelve al bucle principal después de esperar, y el ciclo continúa.

### Figura 3

*Dispositivo arduino uno*




*Nota.* Fuente: autoría propia

### *Sensor ZPHS01B*

El módulo de sensores utilizado fue el ZPHS01 de la marca Winson, el cual dispone de los sensores necesarios en un espacio compacto para el desarrollo del proyecto, ya que nos permite tomar datos de material particulado PM2.5 y PM10, además de O<sub>3</sub>, CO, CO<sub>2</sub> y NO<sub>2</sub>.

### Figura 4

*Sensor ZPHS01B*




*Nota.* Módulo compacto con diferentes sensores, para el monitoreo de la calidad del aire.

Fuente: autoría propia

### ***Módulo SD CARD para Arduino***

Para guardar todos los datos del sensor disponemos de un adaptador de micro sd, con una capacidad de 16gb para almacenar los suficientes datos, para más adelante con estos datos poder entrenar nuestra red neuronal y obtener resultados sobre la calidad del aire.

**Figura 5.** *Modulo de arduino para tarjeta micro SD*



*Nota.* Fuente: autoría propia.

### ***Modulo cargador Bateria Litio Tp4056 Tipo C***

Este módulo lo utilizamos para recargar las baterías utilizadas para alimentar el dispositivo.

**Figura 6**

Modulo cargador Bateria Litio Tp4056 Tipo C



*Nota.* Fuente: autoría propia

### ***Batería de litio 18650***

Utilizamos como alimentación dos baterías en serie de este tipo, ya que nos proporciona una gran capacidad de mAh con el voltaje adecuado para que el dispositivo funcione por un tiempo aproximado de 6 horas.

### **Figura 7**

Batería de litio 18650




*Nota.* Fuente: autoría propia

### **8.2 Conexiones realizadas para el montaje del prototipo.**

Para permitir la comunicación con el módulo de sensores y la placa de Arduino se realiza la siguiente conexión, el formato de comunicación del módulo de sensores es de tipo UART (receptor/transmisor asíncrono universal)

### Figura 8

Conexiones realizadas para el montaje del prototipo.



*Nota.* Diseñado en fritzing. Fuente: autoría propia.

Pin TX: Pin de transmisión de datos


Pin RX: Pin de recepción de datos

Pin 5V: Pin para la alimentación de 5v del dispositivo

Pin GND: Pin de la tierra del dispositivo

**Figura 9**

*Conexión con el módulo SD CARD y la placa Arduino.*




*Nota.* Diseñado en fritzing. Fuente: autoría propia

La conexión completa del dispositivo portable con todos los módulos implementados quedaría de esta manera:

**Figura 10**

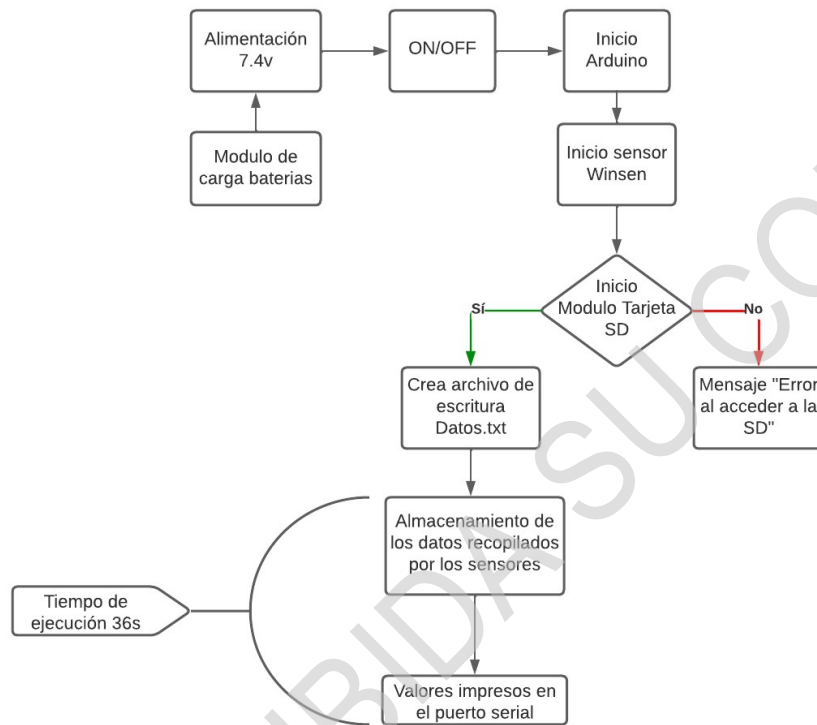
*Conexión completa del dispositivo para monitorear la calidad del aire*



*Nota.* Para la estructura también se utilizó un switch de encendido y apagado. Fuente: autoría propia.

**Figura 11**

Diagrama de bloques, funcionamiento del dispositivo.



Nota. Fuente: autoría propia.

**Figura 12**

Dimensiones del dispositivo para monitorear la calidad del aire



Nota. Fuente: autoría propia.



### 8.3 Metodología toma de datos

Después de instalar los componentes, se puede probar su funcionamiento. Antes de la primera prueba, debemos observar que todos los componentes estén bien conectados, sensor, baterías, cableado, microcontrolador, módulo SD.

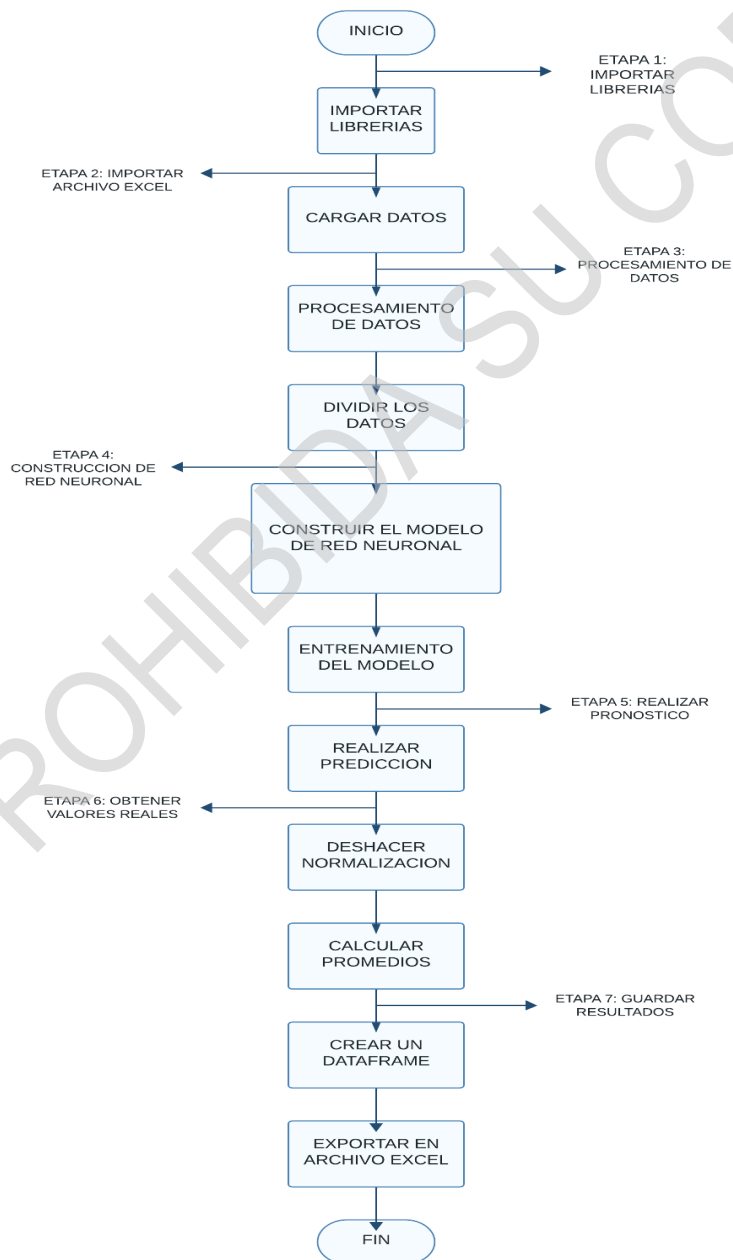
Como parte de este estudio, se llevó a cabo una metodología experimental la cual ha llevado a cabo una recopilación exhaustiva de datos (ver anexo C) para monitorear las variables relacionadas con la calidad del aire para formar una base de datos para análisis posteriores basados en técnicas de aprendizaje automático como machine learning. La ubicación elegida para la recolección de datos fue la comuna 1 del municipio de Pasto en Colombia que corresponde al centro de la ciudad donde transita más cantidad de vehículos (ver Anexo D). El proceso de recopilación de datos duró unos cinco meses en total y se dividió en dos fases distintas. En una primera etapa las mediciones se realizaron en horas pico, específicamente a partir de las 12:00 horas. hasta las 13.00 horas, que corresponde al horario de mayor actividad de la ciudad y tráfico de vehículos. La segunda fase se centra en las horas de menor actividad, donde las mediciones comienzan entre las 16:00 y las 17:00 para capturar las condiciones ambientales cuando hay menos congestión. Esta estrategia de muestreo permite la recopilación de datos representativos y completos, lo cual es esencial para el desarrollo de modelos de aprendizaje automático que pueden ayudar a comprender y otorgar un pronóstico más acertado en la ciudad de Pasto.

## 8.4 Análisis de resultados

### 8.4.1 Red neuronal

Figura 13

Diagrama construcción de la red neuronal.



Nota. Fuente: Autoría propia.

### ***Etapa 1: Importar librerías***

Se implementó un código en lenguaje python para una red neuronal que utiliza la biblioteca Keras para predecir variables relacionadas con la calidad del aire conseguidas por el dispositivo, se importan las bibliotecas necesarias, incluyendo Pandas para manejar datos especialmente en nuestro proyecto se utilizara para el procesamiento de datos y normalización de los datos, NumPy para operaciones matemáticas ya que la red neuronal utiliza operaciones con matrices, gradientes, derivadas, funciones, promedios etc, Scikit-Learn para dividir datos y normalizarlos, Matplotlib para visualización, y Keras para construir el modelo de la red neuronal “model = Sequential()” crea un modelo de red neuronal secuencial utilizando la biblioteca Keras.

### ***Etapa 2: importar archivo excel***

Se requiere la lectura de datos de un archivo de Excel denominado 'BASE\_DATOS\_pic\_nopic.xlsx', el cual almacena información completa sobre las mediciones de calidad del aire realizadas por el dispositivo. Estos datos están divididos en dos categorías: 'PICO' y 'NO PICO', que se corresponden con las mediciones tomadas durante las horas pico y no pico, respectivamente. La información relevante se encuentra organizada en una hoja específica llamada 'PICO'.

### ***Etapa 3 procesamiento de datos:***

La primera etapa de nuestro proceso implica la separación de las columnas de entrada y salida de un DataFrame. En esta fase, se seleccionan las columnas del DataFrame que

permite crear, modificar y analizar datos de manera eficiente. Algunas de las características llamado 'data' que servirán como variables de entrada (X), también conocidas como características o atributos. Las variables de entrada son fundamentales ya que representan los datos que se utilizan para realizar predicciones. Estas características constituyen la base de entrada para nuestro modelo y se utilizan para pronosticar las variables de salida. Las variables de entrada pueden abarcar una amplia gama de datos, como la concentración de CO<sub>2</sub>, la temperatura, y las concentraciones de varios contaminantes atmosféricos, tales como monóxido de carbono (CO), ozono (O<sub>3</sub>), dióxido de nitrógeno (NO<sub>2</sub>), partículas finas (PM<sub>2.5</sub>), partículas más grandes (PM<sub>10</sub>), entre otros. Estas variables de entrada son esenciales para que el modelo pueda identificar patrones y relaciones en los datos, lo que a su vez permite hacer predicciones acerca de las variables de salida. Son la información que se proporciona al modelo para permitirle realizar predicciones precisas.

Por otro lado, las variables de salida (Y) son aquellas que se intentan predecir mediante el modelo. Representan las respuestas que el modelo genera en función de las características de entrada. En nuestro proyecto, relacionado con la calidad del aire, las variables de salida podrían incluir las mismas variables que las de entrada, como por ejemplo CO<sub>2</sub>, CO, O<sub>3</sub>, NO<sub>2</sub>, PM<sub>2.5</sub> y PM<sub>10</sub>. En este contexto, el modelo podría estar tratando de predecir los niveles futuros de estas sustancias en función de los datos de entrada y el conocimiento adquirido durante el proceso de entrenamiento. Las variables de salida son el objetivo principal del modelo, y se espera que el modelo haga predicciones precisas acerca de ellas.

El proceso de entrenamiento se concentra en ajustar el modelo para que pueda realizar predicciones lo más precisas posibles en comparación con los valores reales de las variables de salida. En resumen, las variables de entrada ( $X$ ) suministran información al modelo, mientras que las variables de salida ( $Y$ ) representan lo que el modelo busca predecir.

En la siguiente etapa del procesamiento de datos, abordamos la normalización de los mismos. La normalización de datos representa un paso fundamental en el procesamiento de datos en el ámbito del aprendizaje automático y la ciencia de datos. Este proceso es esencial, ya que permite corregir las diferencias en las escalas de las características de entrada. Cuando las variables de entrada presentan valores que varían en amplios rangos, pueden surgir problemas durante el proceso de entrenamiento del modelo. La normalización juega un papel crítico al asegurarse de que todas las características compartan una escala similar. Esto permite que el modelo aprenda de manera más eficiente. Cuando los datos están en un rango más estrecho, los gradientes durante el proceso de optimización son más consistentes, lo que a su vez conduce a una convergencia más rápida del modelo. Además, la normalización reduce el impacto negativo de los valores atípicos, ya que todos los datos se encuentran en una escala común. Una ventaja adicional de la normalización es que hace que los coeficientes y los pesos de las características en el modelo sean más interpretables. En nuestro proyecto, hemos optado por implementar una técnica de normalización conocida como 'z-score normalization'. Esta técnica implica establecer una media de cero y una desviación estándar de uno para los datos. Esto ofrece diversos beneficios. Al normalizar los datos para que tengan una media de cero, los datos se centran alrededor de cero en una escala lineal. Esto elimina



cualquier sesgo sistemático en los datos y garantiza un trato equitativo de los valores positivos y negativos. La normalización para que la desviación estándar sea uno asegura que los datos se escalan de manera que su dispersión sea la misma en todas las direcciones. Para llevar a cabo esta normalización, empleamos la biblioteca Scikit-Learn y utilizamos el 'StandardScaler' para normalizar tanto los datos de entrada ( $X$ ) como los de salida ( $y$ ). Este proceso desempeña un papel crucial en la preparación de los datos para el posterior entrenamiento del modelo.

La última fase del procesamiento de datos involucra la división de los datos en tres conjuntos distintos: entrenamiento, validación y prueba. Para llevar a cabo esta división, empleamos la función 'train\_test\_split' de Scikit-Learn, la cual se aplica en dos etapas.

En la primera división, los conjuntos  $X_{\text{normalized}}$  e  $y_{\text{normalized}}$  se separan en dos subconjuntos: uno destinado al entrenamiento y otro que denominamos  $X_{\text{temp}}$  e  $y_{\text{temp}}$ . La proporción de esta división se controla mediante el argumento 'test\_size', que está configurado en 0.3. Esto implica que el 30% de los datos se asigna al conjunto de prueba, mientras que el 70% restante se reserva para el conjunto de entrenamiento. Es importante destacar que el valor de 'random\_state' se establece en 42 para asegurar que la división sea reproducible, es decir, que los mismos datos se dividirán de la misma manera si se ejecuta el proceso varias veces.

En la segunda etapa de la división, el conjunto  $X_{temp}$  e  $y_{temp}$  se separa nuevamente en dos conjuntos adicionales: uno de validación y otro de prueba, que almacenamos en  $X_{val}$  e  $y_{val}$ , y  $X_{test}$  e  $y_{test}$ , respectivamente. La proporción de esta segunda división también se regula mediante 'test\_size', configurado en 0.5, de modo que los datos se dividen de manera equitativa entre los conjuntos de validación y prueba. El resultado final es que los datos se organizan de la siguiente manera:

Conjunto de entrenamiento ( $X_{train}$ ,  $y_{train}$ ): Utilizado para entrenar el modelo.

Conjunto de validación ( $X_{val}$ ,  $y_{val}$ ): Utilizado para ajustar hiperparámetros y evaluar el rendimiento durante el entrenamiento.

Conjunto de prueba ( $X_{test}$ ,  $y_{test}$ ): Utilizado para evaluar el rendimiento final del modelo después del entrenamiento.

#### ***Etapa 4 construcción de red neuronal:***

La elección de la arquitectura de la red que hemos decidido implementar es una red neuronal secuencial. Esta elección se basa en la idoneidad de esta arquitectura para numerosas tareas de predicción, especialmente cuando se manejan datos tabulares o características estructuradas. En nuestro código, utilizamos 'model = Sequential()' para crear el modelo de red neuronal, aprovechando la API secuencial de Keras. La estructura secuencial es apropiada para aquellas situaciones en las que las capas de la red se apilan de manera lineal una encima de la otra, sin derivaciones o conexiones complejas. Esto significa que la información fluye de manera lineal a través de las capas, desde la entrada hasta la salida. A pesar de que existen otros tipos de arquitecturas de redes neuronales, como las redes

recurrentes, ideales para problemas donde la secuencia y el orden de los datos son fundamentales, o las redes convolucionales, eficaces en la extracción de características espaciales de imágenes, nuestra elección de una red neuronal secuencial se basa en la naturaleza de los datos que alimentarán a nuestra red.

En nuestro caso, los datos no requieren un orden específico ni la extracción de características complejas, y tampoco implican la generación de texto o videos. Por lo tanto, la arquitectura secuencial se ajusta de manera óptima a nuestra necesidad, permitiendo que la información fluya de manera directa y lineal a través de la red para llevar a cabo las tareas de predicción requeridas.

En el siguiente paso, procedemos a agregar la primera capa oculta a nuestra red neuronal. En esta capa, especificamos que será una capa densa con la función '**Dense**', lo que significa que todas las neuronas en esta capa están conectadas de manera completa con todas las neuronas de la capa anterior. Esta conectividad total permite que la información fluya de manera altamente eficiente, ya que todas las neuronas se comunican entre sí.

Hemos decidido configurar cada capa con 64 neuronas. Esta elección se basa en pruebas experimentales, en las cuales se evaluaron diferentes números de neuronas.

Concluimos que 64 neuronas proporcionan el funcionamiento más óptimo para nuestra red.

Este número de neuronas ha demostrado ser efectivo en nuestro contexto, permitiendo a la red aprender de manera eficaz y realizar las tareas requeridas con precisión.

`input_dim=X_normalized.shape[1]` especifica que esta es la primera capa de la red. Esta capa se utiliza para recibir las características de entrada y es seguida por la capa oculta.



Además, es esencial definir la función de activación de nuestra red neuronal. En este caso, hemos optado por implementar la función de activación ReLU (Rectified Linear Unit). Esta elección se basa en una diferencia clave con respecto a las funciones de activación sigmoid y tanh. Las funciones sigmoid y tanh tienden a tener problemas de saturación en los valores de salida, lo que puede ralentizar el proceso de entrenamiento y dificultar la convergencia del algoritmo de gradiente descendente.

En contraste, la función de activación ReLU se caracteriza por un proceso de entrenamiento más rápido y es mucho más probable que alcance la convergencia del algoritmo de gradiente descendente de manera eficaz. La utilización de ReLU como función de activación en nuestra red es una elección sólida que contribuye a un entrenamiento más eficiente y a un mejor rendimiento de la red en general.

`model.add(Dense(y_normalized.shape[1]))` se refiere a la capa de salida de la red neuronal, esta línea de código agrega una capa de salida a la red neuronal que tiene un número de neuronas igual al número de variables objetivo en el problema de regresión, `'y_normalized.shape[1]'` devuelve el número de variables objetivo en el problema, y se utiliza como el número de neuronas en la capa de salida de la red, de modo que la red pueda generar predicciones separadas para cada una de esas variables objetivo.

La función de pérdida, en este caso, se establece es `'mean_squared_error'`, que es la función de pérdida de error cuadrático medio. Establecimos esta función de pérdida por que se utiliza en problemas de regresión es decir problemas donde el objetivo es predecir un valor numérico (en este caso, la calidad del aire). El error cuadrático medio mide la discrepancia

cuadrada entre las predicciones del modelo y los valores reales. El objetivo del entrenamiento es minimizar esta pérdida, es decir, hacer que las predicciones se acerquen lo más posible a los valores reales.

Es necesario escoger un optimizador para el algoritmo que se utilizará para ajustar los pesos de la red durante el entrenamiento con el objetivo de minimizar la función de pérdida. En este caso, se utiliza el optimizador 'adam' el cual reduce la tasa de aprendizaje cuando se acerca a una solución óptima y la aumenta cuando se aleja. Esto ayuda a que el entrenamiento sea más rápido y estable, La tasa de aprendizaje es un valor que controla cuánto se ajustan los pesos en cada actualización.

El último paso en esta etapa implica entrenar el modelo. Para llevar a cabo este proceso, utilizamos el método de Keras llamado '**model.fit**'. Este método se emplea para iniciar el entrenamiento de una red neuronal. Durante este proceso, es necesario especificar los conjuntos de entrenamiento: '**X\_train**', que contiene las características de entrada utilizadas para realizar predicciones, y '**Y\_train**', que contiene las etiquetas o valores objetivos que se intentan predecir.

Además de definir los conjuntos de entrenamiento, es importante especificar el número de épocas, es decir, el número de iteraciones durante el proceso de entrenamiento. En este caso, hemos realizado 500 épocas de entrenamiento. Esta elección se basa en un equilibrio encontrado durante las pruebas. Un número mayor de épocas puede mejorar el rendimiento, pero también conlleva una convergencia más lenta y posiblemente sobreajuste del modelo. Por otro lado, un número menor de épocas puede llevar a un aumento del error cuadrático medio y a una diferencia considerable entre los valores reales y las predicciones.



Por lo tanto, 500 épocas representan un punto óptimo que equilibra eficiencia y precisión en nuestro proceso de entrenamiento. Durante el entrenamiento, es importante evaluar el rendimiento del modelo en un conjunto de datos independiente que no se utilizó para el entrenamiento. Esto se hace para asegurarse de que el modelo no solo aprenda los datos de entrenamiento, sino que también generalice bien a datos no vistos. 'X\_val' es el conjunto de datos de validación que contiene las características de entrada para la validación, 'Y\_val' es el conjunto de datos de validación que contiene las etiquetas o valores objetivo correspondientes para la validación.

#### ***Etapa 5 realizar pronóstico:***

La etapa de predicciones es fundamental en cualquier proyecto de aprendizaje automático, ya que define el valor práctico de un modelo entrenado. Para llevar a cabo esta etapa, utilizamos la función '**model.predict**', que nos permite obtener predicciones a partir de un modelo de red neuronal en un conjunto de datos de entrada.

El proceso es el siguiente: se suministra a la función '**model.predict**' un conjunto de datos de entrada, típicamente en forma de un arreglo NumPy (en este caso, llamado '**X\_test**'). El modelo, previamente entrenado y ajustado, luego procesa estos datos de entrada. Es importante destacar que **model.predict** no modifica los pesos del modelo; en cambio, utiliza los pesos que han sido aprendidos y ajustados durante el proceso de entrenamiento.

Dentro del modelo de red neuronal, se llevan a cabo cálculos fundamentales. Estas operaciones son realizadas por el modelo de aprendizaje automático en función de los pesos y

las conexiones de las capas neuronales. El resultado es un conjunto de predicciones que se almacenan en un arreglo NumPy llamado 'y\_pred\_normalized'. Este arreglo contiene las predicciones del modelo para el conjunto de datos de entrada, que pueden ser interpretadas y utilizadas para tomar decisiones informadas en función de las necesidades del proyecto.

Es decir que en un escenario que no utilicemos **'model.predict'** la red neuronal procesa datos de entrada y llega a su capa de salida, esta capa de salida produce una salida que generalmente es un tensor. Un tensor es simplemente una estructura de datos multidimensional que puede contener valores numéricos es decir que no se obtendrá una salida con resultados útiles o interpretables, `model.predict` toma ese tensor y produce las predicciones finales basadas en ese tensor y los datos de entrada.

#### ***Etapa 6 obtener valores reales:***

Es esencial tener en cuenta que las predicciones generadas por el modelo pueden estar en la misma escala que los datos de entrenamiento, especialmente si se ha realizado una normalización previa. En caso de que sea necesario, es fundamental desnormalizar las predicciones para obtener valores en la escala original de los datos. Para lograr esto, hemos implementado una línea de código que hace uso de la función `'scaler_y.inverse_transform'`. Esta función se utiliza para revertir la normalización aplicada previamente, permitiendo que las predicciones estén en la escala original de los datos. Este proceso es esencial para que las predicciones sean comprensibles y útiles en el contexto del problema original. Facilita la comparación y evaluación del rendimiento del modelo de una manera que sea significativa



para el usuario, Este aspecto es de particular importancia en problemas de regresión, donde el objetivo es predecir valores numéricos. En tales casos, es esencial que las predicciones sean interpretables en la escala correcta, lo que facilita la toma de decisiones informadas y la comprensión de los resultados en el contexto del problema que se aborda.

Finalmente, en esta etapa, es necesario abordar un cambio importante relacionado con los datos. Después de aplicar la desnormalización, las salidas se presentan en forma de un arreglo NumPy, que es una estructura matricial que se utiliza debido a la naturaleza matricial con la que trabaja la red neuronal.

Para resolver este problema y facilitar el manejo de los datos, hemos implementado una sección de código específica. Comenzamos creando listas para las variables objetivo y un diccionario vacío. Luego, iniciamos un bucle 'for' que recorre cada variable objetivo en la lista.

Dentro del bucle, calculamos el promedio de los valores reales utilizando la función '**np.mean**', lo que nos proporciona el valor promedio de los datos reales para la variable objetivo. De manera similar, calculamos el promedio de las predicciones generadas por el modelo.

Después de ejecutar este bloque de código, el diccionario '**averages**' contendrá los promedios de las variables objetivo tanto para los valores reales como para las predicciones del modelo. Estos promedios resultan útiles para evaluar el rendimiento del modelo y para comprender cómo se compara con los datos reales en términos de tendencia central.

### ***Etapa 7 guardar resultados:***

Utilizando la biblioteca pandas en Python utilizaremos **'pd.DataFrame'** esto con el fin de convertir el diccionario **'averages'** en un objeto DataFrame, Un DataFrame es una estructura de datos bidimensional que se asemeja a una tabla de una base de datos, donde puedes organizar datos de manera tabular.

Por último lo que consta del proyecto es crear una base de datos en un archivo excel en donde de manera organizada podamos exportar los resultados que obtuvimos, para esto se realiza un bloque de código que se encarga de esta función, con **'file\_path'** esta variable almacena la ruta del archivo Excel en la que se guardarán los promedios de las variables objetivo, además utilizamos un condicional **'if'** para verificar si el archivo existe o no en la ruta especificada Si el archivo ya existe, se ejecuta el bloque de código dentro del primer conjunto de instrucciones si el archivo existe se utiliza **'pd.read\_excel'** para cargar su contenido en un DataFrame llamado **'existing\_data'**. Esto asegura que los datos existentes no se sobrescriben y se mantengan para su referencia.

### **8.4.2 Análisis predictivo**

Para llevar a cabo el análisis predictivo, consideramos una variable externa vinculada al aumento anual de vehículos en la ciudad de Pasto. Obtuvimos esta información de la Secretaría de Tránsito y Movilidad, con detalles disponibles en los anexos. Calculamos un porcentaje de crecimiento anual del 1.0194% utilizando los datos de vehículos de 2021 y 2022. Este porcentaje de la variable externa se empleó debido a su impacto en la calidad del

aire en la ciudad. Utilizamos el porcentaje de crecimiento para entrenar la red neuronal con los datos capturados por el dispositivo.

### Figura 14

Tabla de índice de la calidad del aire.

Índice de Calidad del Aire			Puntos de corte del ICA						
ICA	Color	Categoría	PM <sub>10</sub> µg/m <sup>3</sup> 24 horas	PM <sub>2.5</sub> µg/m <sup>3</sup> 24 horas	CO µg/m <sup>3</sup> 8 horas	SO <sub>2</sub> µg/m <sup>3</sup> 1 hora	NO <sub>2</sub> µg/m <sup>3</sup> 1 hora	O <sub>3</sub> µg/m <sup>3</sup> 8 horas	O <sub>3</sub> µg/m <sup>3</sup> 1 hora <sup>(1)</sup>
0-50	Verde	Buena	0 – 54	0 – 12	0 – 5094	0 – 93	0 – 100	0 – 106	.....
51-100	Amarillo	Aceptable	55 – 154	13 – 37	5095 – 10819	94 – 197	101 – 189	107 – 138	.....
101 - 150	Naranja	Dañina a la salud de Grupos Sensibles	155 – 254	38 – 55	10820 – 14254	198 - 486	190 – 677	139 - 167	245 – 323
151 - 200	Rojo	Dañina a la salud	255 – 354	56 – 150	14255 – 17688	487 – 797	678 - 1221	168 - 207	324 – 401
201 - 300	Púrpura	Muy dañina a la salud	355 – 424	151 – 250	17689 – 34862	798 – 1583	1222 – 2349	208 - 393	402 – 794
301 - 500	Marrón	Peligrosa	425 - 604	251 – 500	34863 - 57703	1584 - 2629	2350 - 3853	394 <sup>(2)</sup>	795 – 1185

Nota. Tabla indicadora de índices de la calidad del aire de acuerdo a la resolución 2254 de 2017. Fuente: Resolución 2254 de 2017 ministerio de ambiente y desarrollo sostenible.

#### 8.4.3 Análisis de pronóstico horas pico.

La figura número 15 visualiza claramente la disparidad entre el valor real y un pronóstico correspondiente al primer semestre del año 2024, en relación a la variable CO<sub>2</sub>. En el valor real, el cual fue tomado por el dispositivo tenemos 1021 ppm, para el pronóstico del 2024 la red neuronal obtuvo como resultado 1017 ppm. Posteriormente la gráfica de color verde se puede observar el aumento de CO<sub>2</sub> para el año 2028 con un valor de 1105,17 ppm

Esto representa un incremento de alrededor de 8%, cabe resaltar que estos resultados fueron tomados en hora pico.

Para comparar el valor real de 1021 ppm con el valor pronosticado de 1017 ppm podemos usar la siguiente fórmula.

***Fórmula para calcular el porcentaje de error***

$$\text{Porcentaje de error} = \frac{(\text{valor real} - \text{valor pronóstico})}{\text{valor real}} \times 100 \quad (1)$$

El porcentaje de error es de 0.392% al ser un error bajo nos indica que el pronóstico se acerca bastante al valor real tomado por el dispositivo.

En cuanto al crecimiento de CO<sub>2</sub> del año 2024 al 2028 utilizamos la tasa de crecimiento anual del 1.0194% . La red neuronal obtiene un resultado de CO<sub>2</sub> para el año 2028 en horas pico de aproximadamente 1105 ppm.

Para calcular el porcentaje de crecimiento de CO<sub>2</sub> del año 2024 al 2028 usamos la siguiente fórmula:

$$\text{Porcentaje de crecimiento} = \frac{(\text{valor final} - \text{valor inicial})}{\text{valor inicial}} \times 100 \quad (2)$$

valor final= 1105,17 ppm

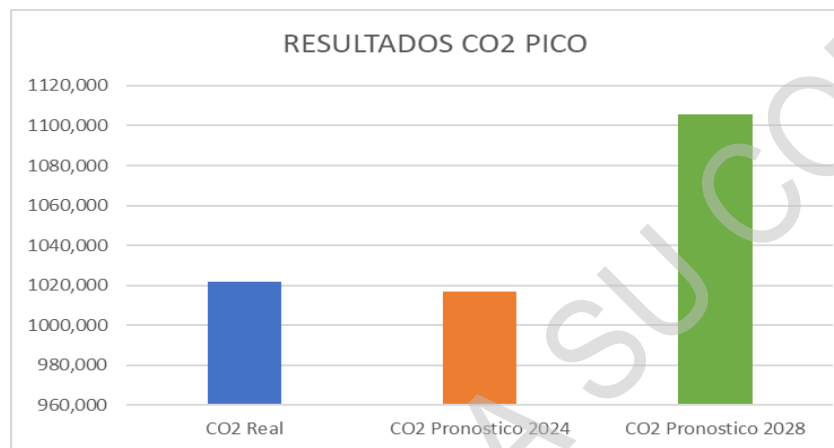
valor inicial= 1017 ppm



Tenemos un crecimiento del 8.66% . Con respecto a los niveles de CO<sub>2</sub> para el año 2028 tendríamos una calidad aceptable.

### Figura 15

*Pronóstico para el año 2024 y 2028 CO<sub>2</sub> en hora pico.*

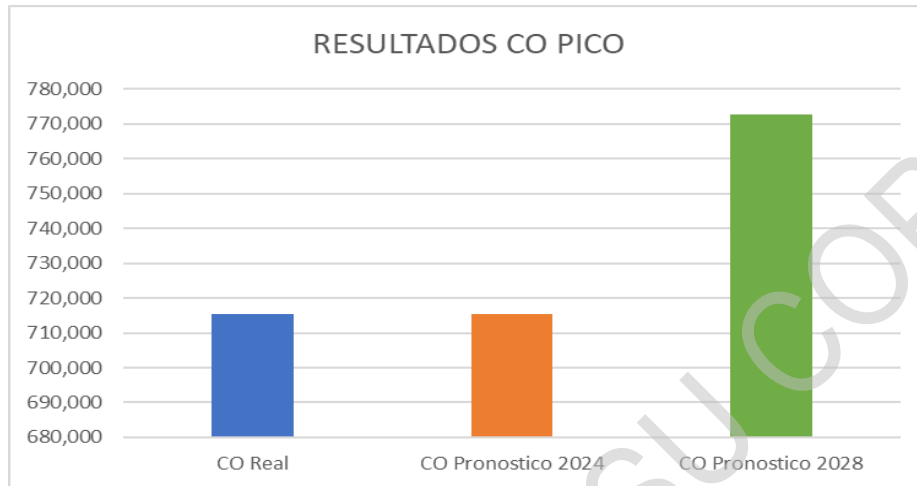


*Nota.* Pronóstico para el año 2024 y 2028 CO<sub>2</sub>. Fuente: autoría propia

En la figura número 16 se visualiza un valor semejante entre el valor real y un pronóstico correspondiente al primer semestre del año 2024, en relación a la variable CO. En el valor real, el cual fue tomado por el dispositivo tenemos 715,451  $\mu\text{g}/\text{m}^3$ , para el pronóstico del 2024 la red neuronal obtuvo como resultado 715,318  $\mu\text{g}/\text{m}^3$ . Posteriormente la grafica de color verde se puede observar el aumento de CO para el año 2028 donde destaca un valor de 772,666  $\mu\text{g}/\text{m}^3$  representa un aumento del 8% , cabe resaltar que estos resultados son en hora pico.

**Figura 16**

*Pronóstico para el año 2024 y 2028 CO en hora pico.*



*Nota.* Fuente: autoría propia

Utilizando la fórmula 1 para conocer el error entre el valor real y el valor del pronóstico tenemos un porcentaje de error de 0.018% , con la fórmula 2 se obtiene un crecimiento para el año 2028 de 8.017% con esto valores podemos calcular el índice de calidad del aire con respecto a la tabla de la figura 14.

El índice de calidad del aire se calcula con la siguiente fórmula:

$$ICA_p = \frac{I_{alto} - I_{bajo}}{PC_{alto} - PC_{bajo}} \times (C_p - PC_{bajo}) + I_{bajo} \quad (3)$$

En donde:

$ICA_p$  = índice de calidad del aire para el contaminante p

$C_p$  = Concentración medida para el contaminante p

$PC_{Alto}$  = Punto de corte mayor o igual a  $C_p$

$PC_{Bajo}$  = Punto de corte menor o igual a  $C_p$

$I_{Alto}$  = Valor del ICA correspondiente al  $PC_{Alto}$

$I_{Bajo}$  = Valor del ICA correspondiente al  $PC_{Bajo}$

Para el año 2028 tenemos un nivel de CO de aproximadamente 772  $\mu\text{g}/\text{m}^3$

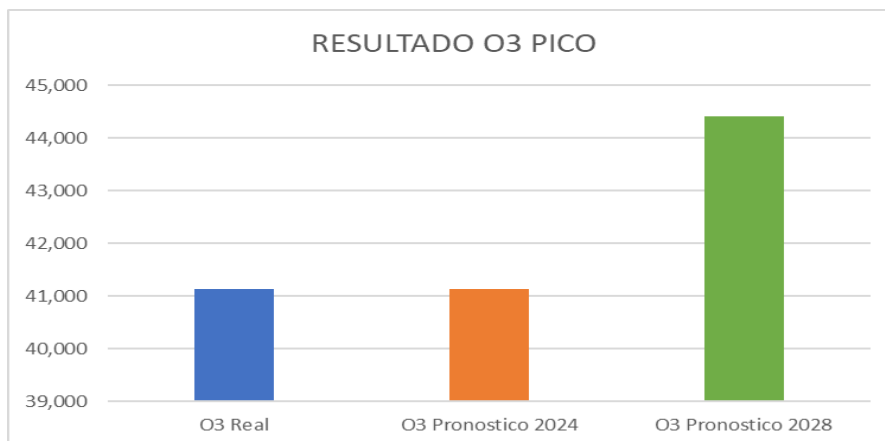
Reemplazando los valores en la fórmula 3 tenemos un ICA de 7.57 $\mu\text{g}/\text{m}^3$ , este valor según la tabla de la figura 14 corresponde a una categoría buena.

La figura 17 muestra un valor similar entre el dato real y la predicción para el primer semestre de 2024 respecto a la variable O3. El valor real, obtenido por el dispositivo, fue de 41,127  $\mu\text{g}/\text{m}^3$ , mientras que el pronóstico de 2024 arrojó 41,125  $\mu\text{g}/\text{m}^3$ . Luego, la gráfica verde revela un aumento significativo de O3 para 2028, con un valor destacado de 44,408  $\mu\text{g}/\text{m}^3$ . Un crecimiento cercano al 8%. No obstante, según la resolución 2254 de 2017, la calidad del aire sigue siendo óptima en términos de niveles de CO. Cabe resaltar que estos resultados corresponden a horas pico.

Remplazando valores en la ecuación 3 nos da como resultado un índice de la calidad del aire con respecto al O3 de 20.94 $\mu\text{g}/\text{m}^3$  que corresponde a una categoría buena.

**Figura 17**

Pronóstico para el año 2024 y 2028 O3 en hora pico.



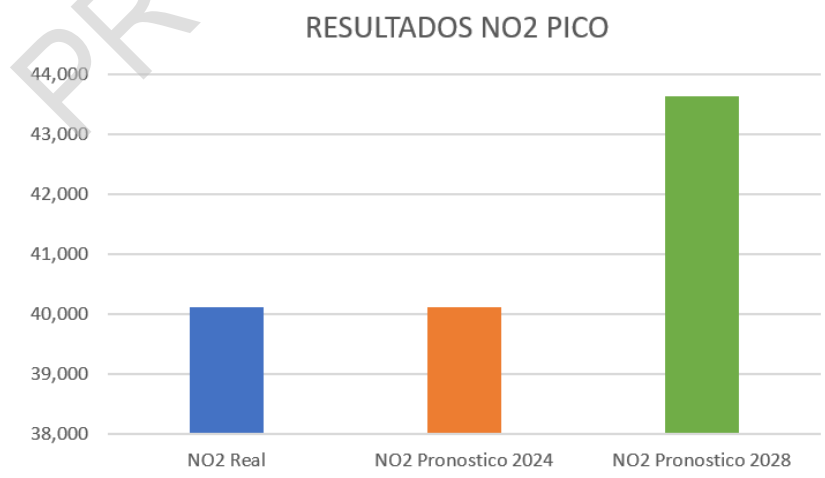
*Nota.* Fuente: autoría propia

En la figura número 18 se observa un valor muy semejante entre el valor real que corresponde al primer semestre del año 2023 obtenidos por el dispositivo y un pronóstico correspondiente al primer semestre del año 2024, en relación a la variable NO<sub>2</sub>. En el valor real es 40,487  $\mu\text{g}/\text{m}^3$ , para el pronóstico del 2024 la red neuronal obtuvo como resultado 40,466  $\mu\text{g}/\text{m}^3$ . Posteriormente la gráfica de color verde se puede observar un aumento significativo de NO<sub>2</sub> para el año 2028 donde destaca un valor de 43,808  $\mu\text{g}/\text{m}^3$ . Un incremento aproximado del 8%, sin embargo, de acuerdo a la resolución 2254 de 2017 aun la calidad del aire es óptima para los niveles de NO<sub>2</sub>.

Remplazando valores en la ecuación 3 nos da como resultado un índice de la calidad del aire con respecto al NO<sub>2</sub> de 21.904  $\mu\text{g}/\text{m}^3$  que corresponde a una categoría buena.

### Figura 18

Pronóstico para el año 2024 y 2028 NO<sub>2</sub> en hora pico.



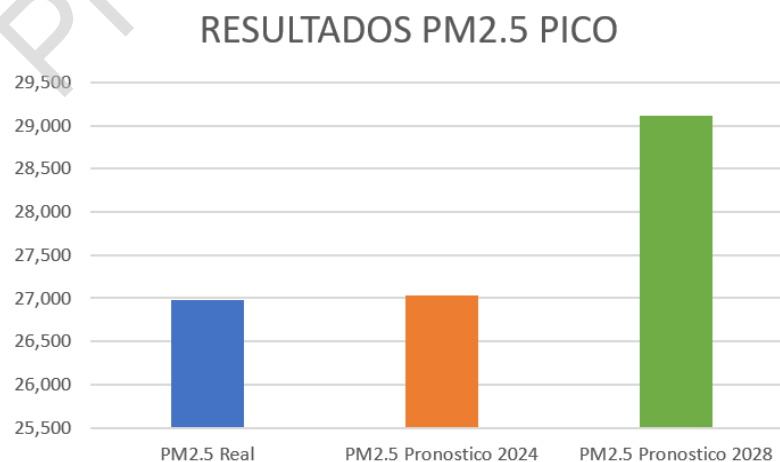
*Nota.* Fuente: autoría propia

La figura 19 es clave para el análisis de la calidad del aire, dada la importancia de la variable PM2.5. Se observa un valor similar con un leve aumento entre el dato real y la predicción para el primer semestre de 2024. El valor real, obtenido por el dispositivo, fue de 25,477  $\mu\text{g}/\text{m}^3$ , mientras que el pronóstico de la red neuronal para 2024 fue de 25,536  $\mu\text{g}/\text{m}^3$ . Posteriormente, en la gráfica verde se aprecia el incremento de PM2.5 para el año 2028, con un valor destacado de 27,505  $\mu\text{g}/\text{m}^3$ . Un crecimiento de alrededor del 12%. De acuerdo con la resolución 2254 de 2017, los niveles de PM2.5 no son los ideales, ya que indican condiciones aceptables pero no beneficiosas para la salud, con una tendencia al alza para 2028.

Remplazando valores en la ecuación 3 nos da como resultado un índice de la calidad del aire con respecto al PM2.5 de 80.61  $\mu\text{g}/\text{m}^3$  que corresponde a una categoría aceptable que la tabla de la figura 11 indica en color amarillo.

### Figura 19

Pronóstico para el año 2024 y 2028 PM2.5 en hora pico.



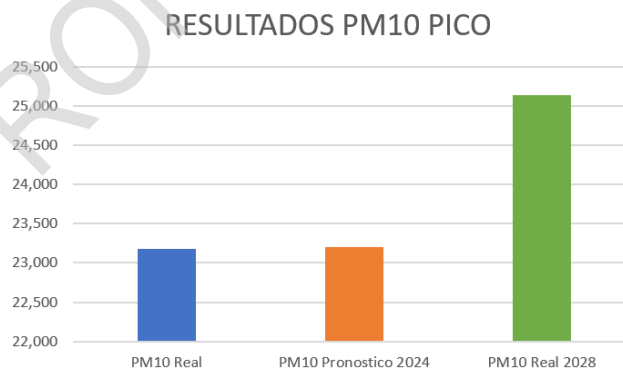
*Nota.* Fuente: autoría propia

La figura 20 también es significativa para la investigación, ya que muestra la variable PM10. Se observa un valor muy similar entre el dato real del primer semestre de 2023, obtenido por el dispositivo, y la predicción para el mismo periodo de 2024. El valor real fue de 26,657  $\mu\text{g}/\text{m}^3$ , mientras que el pronóstico de 2024 arrojó 26,696  $\mu\text{g}/\text{m}^3$ . Luego, la gráfica verde revela un aumento considerable de PM10 para 2028, con un valor destacado de 28,796  $\mu\text{g}/\text{m}^3$ . Un incremento aproximado del 7%. No obstante, según la resolución 2254 de 2017, la calidad del aire sigue siendo óptima en términos de niveles de PM10.

Remplazando valores en la ecuación 3 del ICA nos da como resultado una concentración de PM10 de 20.66 $\mu\text{g}/\text{m}^3$  que corresponde a una categoría buena.

### Figura 20

Pronóstico para el año 2024 y 2028 PM10 en hora pico.



*Nota.* Fuente: autoría propia

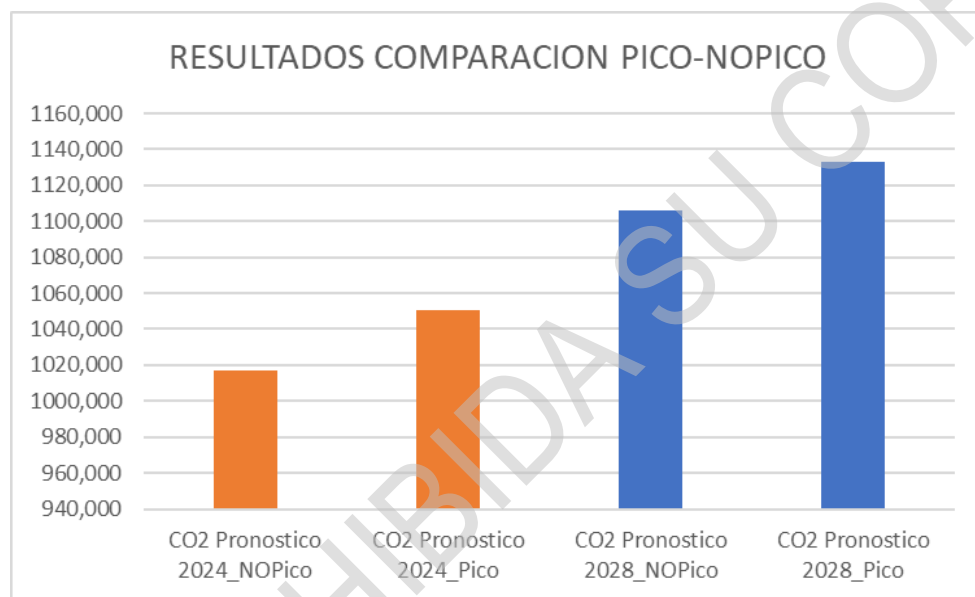
#### 8.4.4 Comparación análisis de horas pico y horas no pico

La Figura 21 permite realizar el siguiente análisis: se observa una tendencia de valores más altos en horas pico respecto a horas no pico, la cual se mantiene de 2024 a 2028.

Específicamente, para 2028 el pronóstico de CO<sub>2</sub> en hora pico (1133,042 ppm) es mayor al de hora no pico (1105,760 ppm). Esto indica que los niveles pronosticados de CO<sub>2</sub> son consistentemente superiores durante los periodos de mayor tráfico vehicular.

### Figura 21

Comparación de CO<sub>2</sub> en horas pico y no pico para el año 2024 y 2028.

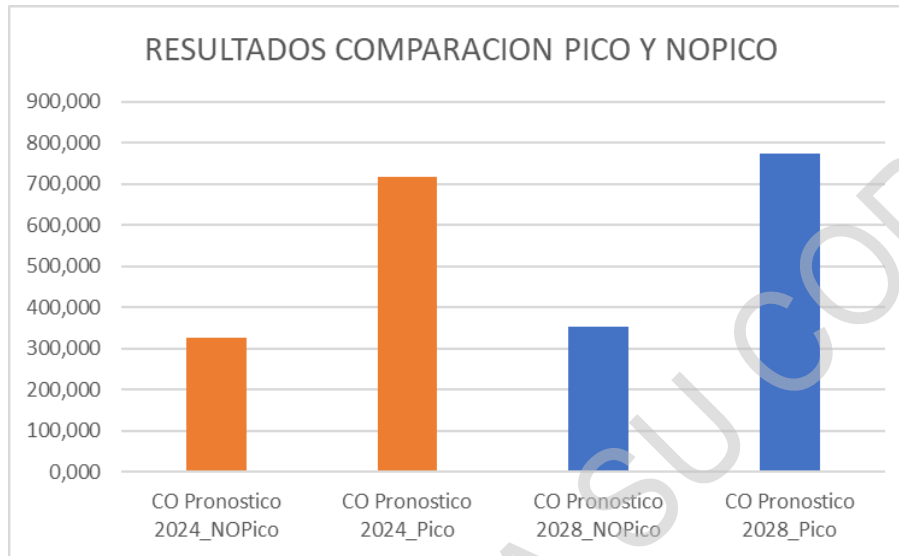


Nota. Fuente: autoría propia

La Figura 22 permite realizar el siguiente análisis: En hora pico de Febrero a Junio de 2024, el pronóstico para CO es 715,318  $\mu\text{g}/\text{m}^3$ . En contraste, en hora no pico para ese mismo periodo, el pronóstico es menor, de 326,424  $\mu\text{g}/\text{m}^3$ . Esta diferencia se mantiene para 2028, donde la predicción de CO en hora pico (772,666  $\mu\text{g}/\text{m}^3$ ) sigue siendo mayor que en hora no pico (351,837  $\mu\text{g}/\text{m}^3$ ). Los valores pronosticados de CO son consistentemente superiores durante las horas de mayor tráfico vehicular. Una posible explicación es la influencia de las emisiones por escape de los vehículos, que incrementan los niveles de CO.

**Figura 22**

Comparación pronóstico de CO en horas pico y no pico para el año 2024 y 2028.




*Nota.* Fuente: autoría propia

La Figura 23 permite realizar el siguiente análisis: En hora pico de febrero a junio de 2024, el pronóstico para O<sub>3</sub> es 41,125  $\mu\text{g}/\text{m}^3$ . En contraste, en hora no pico para ese mismo periodo, el pronóstico es menor, de 21,420  $\mu\text{g}/\text{m}^3$ . Esta diferencia se mantiene para 2028, donde la predicción de O<sub>3</sub> en hora pico (44,408  $\mu\text{g}/\text{m}^3$ ) sigue siendo mayor que en hora no pico (23,124  $\mu\text{g}/\text{m}^3$ ). Los valores pronosticados de O<sub>3</sub> son consistentemente superiores durante las horas de mayor tráfico vehicular (pico). Una posible explicación es la influencia de los óxidos de nitrógeno (NO<sub>x</sub>) emitidos por vehículos, que participan en reacciones de formación de O<sub>3</sub>.



**Figura 23**

Comparación pronóstico de O<sub>3</sub> en horas pico y no pico para el año 2024 y 2028.

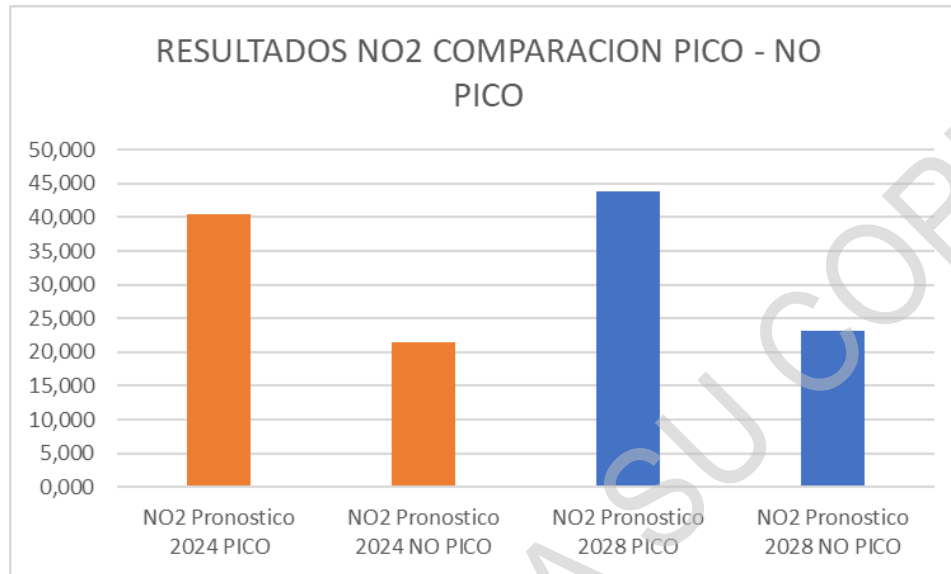


*Nota.* Fuente: autoría propia

La Figura 24 permite realizar el siguiente análisis: En hora pico de Febrero a Junio de 2024, el pronóstico para NO<sub>2</sub> es 40,466 µg/m<sup>3</sup>. En contraste, en hora no pico para ese mismo periodo, el pronóstico es menor, de 21,529 µg/m<sup>3</sup>. Esta diferencia se mantiene para 2028, donde la predicción de NO<sub>2</sub> en hora pico (40,113 µg/m<sup>3</sup>) sigue siendo mayor que en hora no pico (19,537 µg/m<sup>3</sup>). Los valores pronosticados de NO<sub>2</sub> son consistentemente superiores durante las horas de mayor tráfico vehicular (pico). Una posible razón es el aumento en las emisiones directas de NO<sub>2</sub> por los tubos de escape de los vehículos en hora pico.

**Figura 24**

Comparación pronóstico de NO<sub>2</sub> en horas pico y no pico para el año 2024 y 2028.

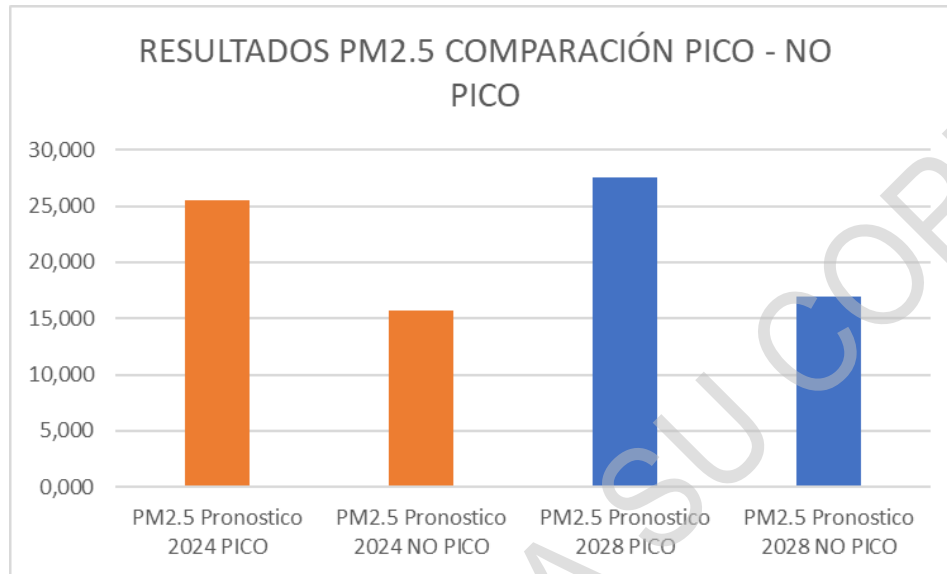


*Nota.* Fuente: autoría propia

La Figura 25 permite realizar el siguiente análisis: En hora pico de Febrero a Junio de 2024, el pronóstico para PM<sub>2.5</sub> es 25,536 µg/m<sup>3</sup>. En contraste, en hora no pico para ese mismo periodo, el pronóstico es menor, de 15,654 µg/m<sup>3</sup>. Esta diferencia se mantiene para 2028, donde la predicción de PM<sub>2.5</sub> en hora pico (27,036 µg/m<sup>3</sup>) sigue siendo mayor que en hora no pico (13,894 µg/m<sup>3</sup>). Los valores pronosticados de PM<sub>2.5</sub> son consistentemente superiores durante las horas de mayor tráfico vehicular. Una posible explicación son las emisiones directas de material particulado de los vehículos diésel.

**Figura 25**

Comparación pronóstico de PM2.5 en horas pico y no pico para el año 2024 y 2028




*Nota.* Fuente: autoría propia

La Figura 26 permite realizar el siguiente análisis: En hora pico de Febrero a Junio de 2024, el pronóstico para PM10 es 26,696 µg/m<sup>3</sup>. En contraste, en hora no pico para ese mismo periodo, el pronóstico es menor, de 16,282 µg/m<sup>3</sup>. Esta diferencia se mantiene para 2028, donde la predicción de PM10 en hora pico (28,796 µg/m<sup>3</sup>) sigue siendo mayor que en hora no pico (17,545 µg/m<sup>3</sup>). Los niveles pronosticados de PM10 son más elevados durante los periodos de mayor tráfico vehicular. Una posible razón es la resuspensión de polvo de las vías por el paso de los vehículos.

**Figura 26**

Comparación pronóstico de PM10 en horas pico y no pico para el año 2024 y 2028.



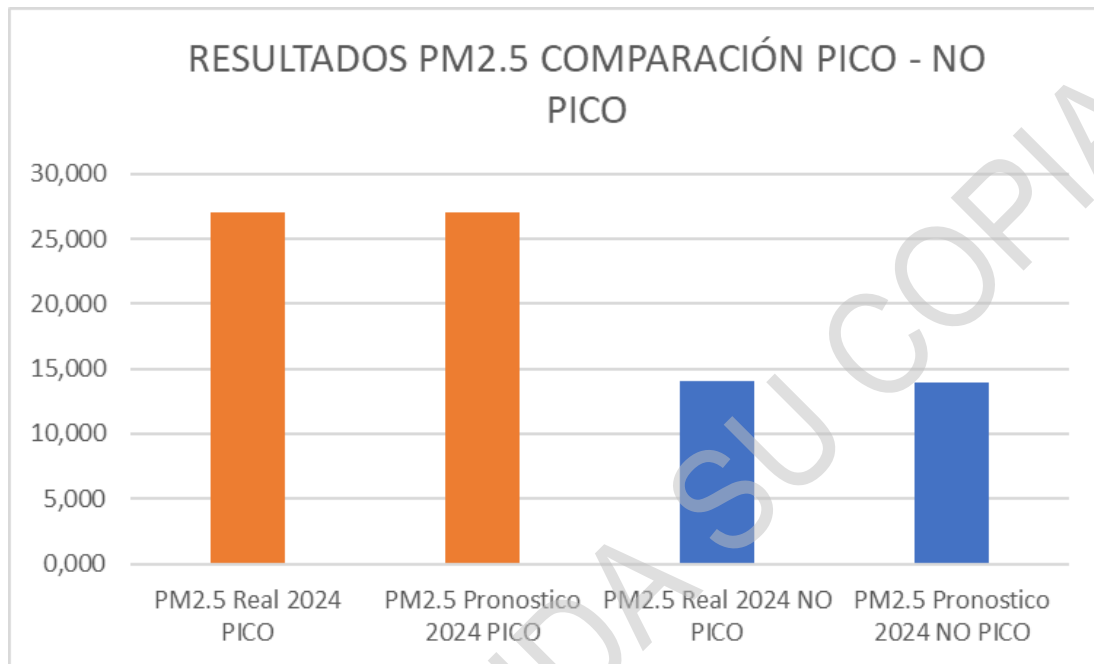
*Nota.* Fuente: autoría propia

#### 8.4.5 Análisis de resultados por día.

La Figura 27 presenta una comparación entre los valores reales de concentración de partículas PM2.5 capturados durante un día y los pronósticos correspondientes para ese mismo día. Se puede apreciar una notable similitud entre los valores, lo que sugiere que la contaminación para un día similar en el próximo año será bastante parecida, tanto en las horas de mayor flujo como en las de menor actividad. Esto es válido a pesar de que los niveles de contaminación durante las horas de menor tráfico vehicular son más bajos.

**Figura 27**

Comparación pronóstico de PM2.5 en horas pico y no pico para un día del siguiente año

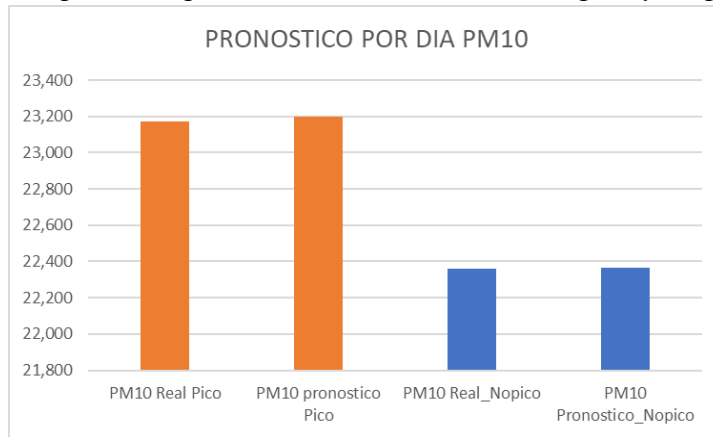


*Nota.* Fuente: autoría propia

Se observa una situación similar en relación a la variable PM10. La Figura 28 exhibe una comparación entre los valores reales de concentración de partículas PM10 registrados en un día y los pronósticos correspondientes para esa misma jornada. Se nota una marcada concordancia entre estos valores, lo que implica que la contaminación para un día similar en el próximo año será considerablemente similar, tanto en las horas de mayor flujo como en las de menor actividad. Esta observación se sostiene a pesar de que los niveles de contaminación durante las horas de menor tráfico vehicular son inferiores.

**Figura 28**

*Comparación pronóstico de PM10 en horas pico y no pico para un día del siguiente año.*



*Nota.* Fuente: autoría propia

**Tabla 5**

*Comparación entre valores reales y pronóstico para un día del año 2024*

HORA	CO2 ppm Real	CO2 ppm Pronóstico	CO µg/m3 Real	CO µg/m3 Pronóstico	O3 µg/m3 Real	O3 µg/m3 Pronóstico	NO2 µg/m3 Real	NO2 µg/m3 Pronóstico
PICO (2024)	452,682	450,123	694,551	698,012	38,640	39,029	40,261	40,113
NO PICO (2024)	433,449	435,536	296,374	296,271	20,008	20,102	19,554	19,537

*Nota.* Fuente: autoría propia

**Tabla 6**

*Pronóstico para un día del año 2028*

HORA	CO2 ppm Pronóstico	CO µg/m3 Pronóstico	O3 µg/m3 Pronóstico	NO2 µg/m3 Pronóstico
PICO (2028)	489,404	754,508	42,110	43,637
NO PICO (2028)	464,088	317,971	21,487	21,112

*Nota.* Fuente: autoría propia

En la tabla 5 se presenta una comparación entre valores reales y valores pronosticados de concentraciones de CO<sub>2</sub>, CO, O<sub>3</sub> y NO<sub>2</sub> para un día del año 2024, tanto en horas pico como en horas no pico. También se muestran valores pronosticados para estas mismas variables en 2028 como indica la tabla 6.

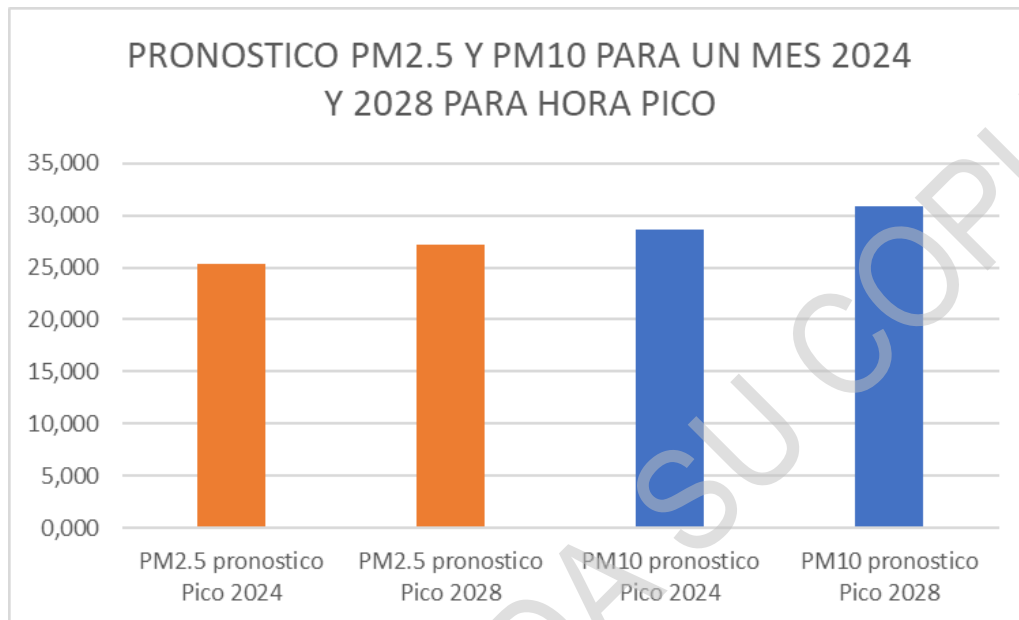
- En 2024, los valores pronosticados son muy similares a los valores reales, con diferencias menores al 5% en la mayoría de los casos. Esto sugiere que el modelo de pronóstico es preciso.
- Las mayores concentraciones para todos los contaminantes se presentan en las horas pico. Por ejemplo, el CO<sub>2</sub> en horas pico es aprox. 15-20% superior al de horas no pico.
- Por el contrario, O<sub>3</sub> y NO<sub>2</sub> aumentan levemente de 2024 a 2028, tanto en pico como no pico.

#### **8.4.6 Análisis por mes**

En el gráfico siguiente (Figura 29), se realiza una comparación entre las variables PM<sub>2,5</sub> y PM<sub>10</sub> para un pronóstico correspondiente a un mes en 2024, y otro pronóstico para un mes en 2028. En este análisis, se evidencia un aumento en los niveles de contaminación durante el mes de 2028 cabe resaltar que son niveles un poco más altos debido a que el pronóstico es realizado para horas pico en comparación con el mismo mes en 2024.

**Figura 29**

*Comparación pronóstico de PM10 y PM2.5 en horas pico para un mes en el 2024 y 2028*



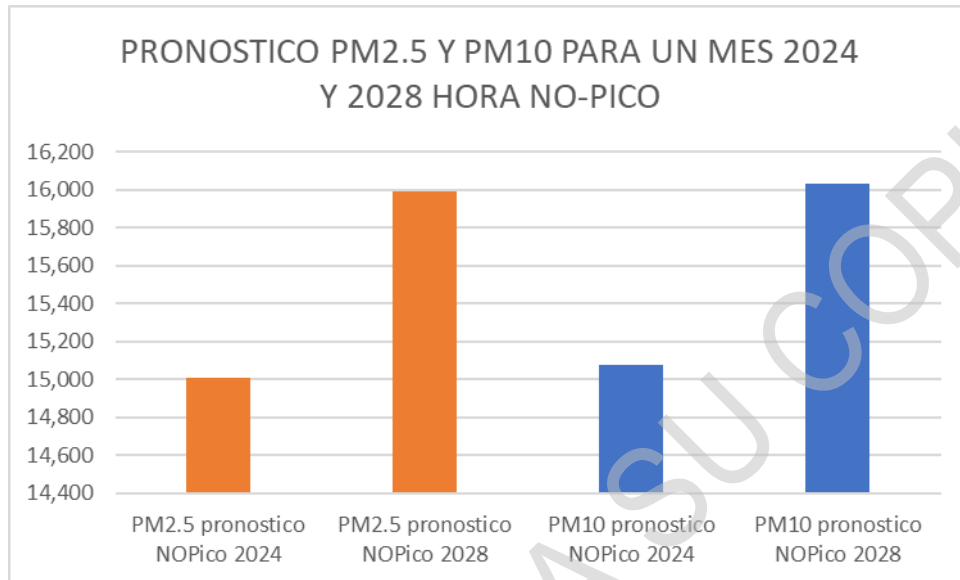
*Nota.* Fuente: autoría propia

En el gráfico siguiente (Figura 30), se realiza una comparación entre las variables PM2,5 y PM10 para un pronóstico correspondiente a un mes en 2024, y otro pronóstico para un mes en 2028 ambos pronósticos realizados en horas de poco flujo vehicular. En este análisis, se evidencia un aumento en los niveles de contaminación durante el mes de 2028 en comparación con el mismo mes en 2024.



**Figura 30**

*Comparación pronóstico de PM10 y PM2.5 en horas No pico para un mes en el 2024 y 2028*



*Nota.* Fuente: autoría propia

**Tabla 7**

*Comparación del pronóstico respecto a los valores reales en hora pico y no pico*

HORA	CO2 ppm Real	CO2 ppm Pronóstico	CO µg/m3 Real	CO µg/m3 Pronóstico	O3 µg/m3 Real	O3 µg/m3 Pronóstico	NO2 µg/m3 Real	NO2 µg/m3 Pronóstico
PICO (JUNIO 2024)	1196,541	1192,997	710,066	709,717	39,474	39,596	40,469	40,458
NO PICO (JUNIO 2024)	837,162	822,232	315,926	315,954	20,607	20,660	21,132	21,137

*Nota.* Fuente: autoría propia

**Tabla 8**

*Resultados del pronóstico de un mes del 2028 en hora pico y no pico*

HORA	CO2 ppm Pronóstico	CO µg/m3 Pronóstico	O3 µg/m3 Pronóstico	NO2 µg/m3 Pronóstico
PICO (JUNIO 2028)	1257,262	765,844	42,618	43,701
NO PICO (JUNIO 2028)	901,929	334,263	21,809	22,345

*Nota.* Fuente: autoría propia

La tabla 7 indica valores reales y valores pronosticados de concentraciones de CO<sub>2</sub>, CO, O<sub>3</sub> y NO<sub>2</sub> en promedio para un mes del año 2024 y valores solo pronosticados para un mes del año 2028 en la tabla 8.

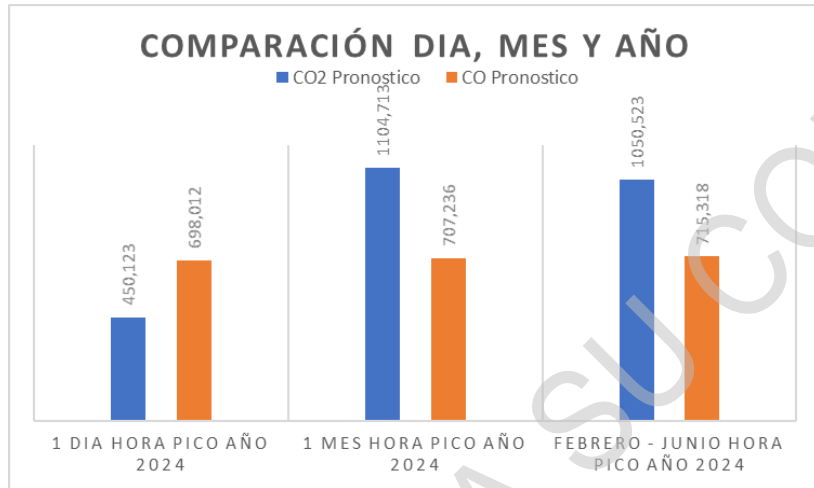
En 2024, los valores pronosticados son muy cercanos a los valores reales para todas las variables en las horas pico y no pico. Esto sugiere que el modelo de pronóstico es preciso. Se espera un aumento en las concentraciones pronosticadas de todas las variables contaminantes de 2024 a 2028, tanto en horas pico como no pico. Por ejemplo, el CO<sub>2</sub> en la hora pico aumenta de 1192 ppm en 2024 a 1257 ppm en 2028.

El incremento pronosticado podría deberse al aumento esperado en emisiones vehiculares debido a la tasa de crecimiento utilizada con respecto al parque vehicular.

**8.4.7 Análisis relación día/mes/semestre**

**Figura 31**


*Relación entre día, mes y semestre para CO y CO2 en hora pico 2024*



*Nota.* Fuente: autoría propia

**Figura 32**

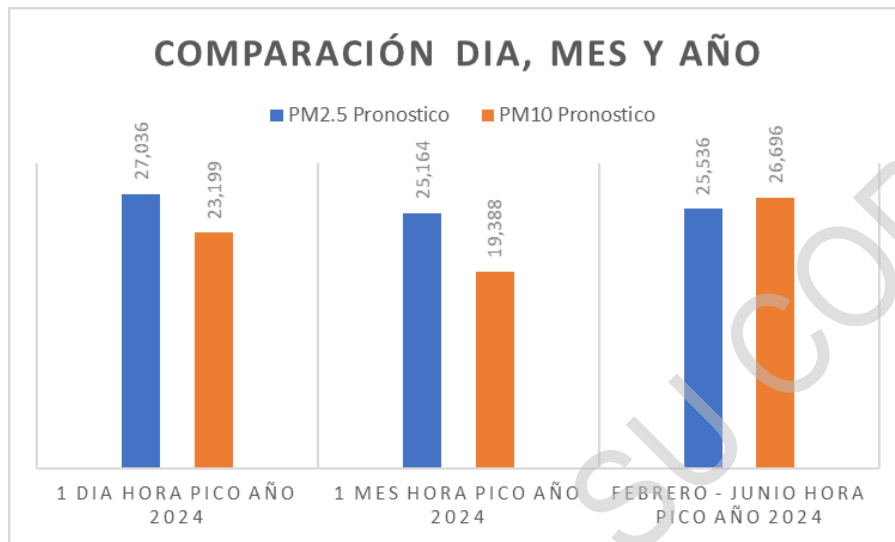
*Relación entre día, mes y semestre para O3 y NO2 en hora pico 2024*



*Nota.* Fuente: autoría propia

**Figura 33**

*Relación entre día, mes y semestre para PM2.5 y PM10 en hora pico 2024*



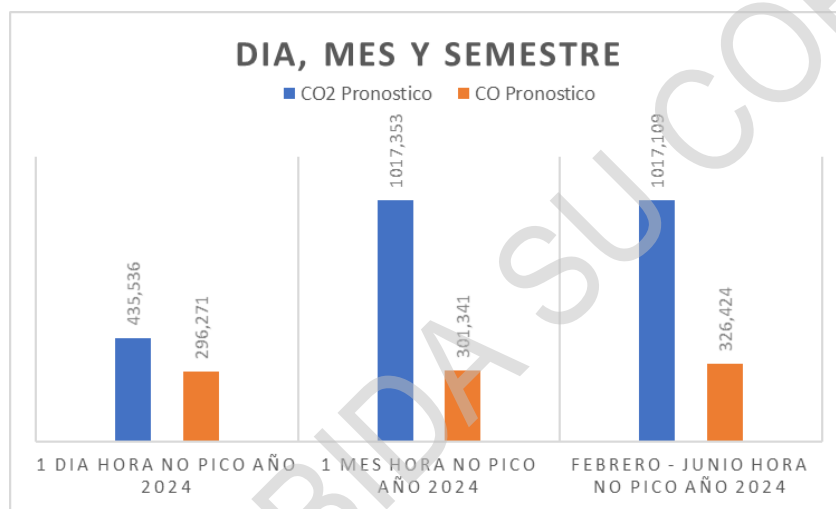
*Nota.* Fuente: autoría propia

Al analizar los datos de los niveles pico de contaminación en 2024, se observan algunas tendencias interesantes al comparar en las escalas de tiempo de un día, un mes y varios meses. El nivel pico de CO<sub>2</sub> para un día aislado es bastante alto, lo que podría deberse a un evento específico como un incendio forestal grande. Sin embargo, el promedio mensual y de varios meses es más consistente con las tendencias actuales. Los niveles de CO muestran una clara tendencia descendente en todas las escalas de tiempo, reflejando los continuos esfuerzos para reducir las emisiones vehiculares. Los niveles de ozono son estables, mientras que el NO<sub>2</sub> y las partículas PM<sub>2.5</sub> y PM<sub>10</sub> tienen una tendencia gradual a la baja, con posibles picos debidos a eventos extraordinarios. En conjunto, los datos sugieren que las regulaciones y políticas actuales están teniendo un impacto positivo en la calidad del aire, pero eventos episódicos pueden causar altos niveles de contaminación localizados que

afectan la salud pública a corto plazo. Un análisis cuidadoso de los datos en diferentes escalas de tiempo es esencial para entender las tendencias subyacentes en la contaminación atmosférica.

**Figura 34**

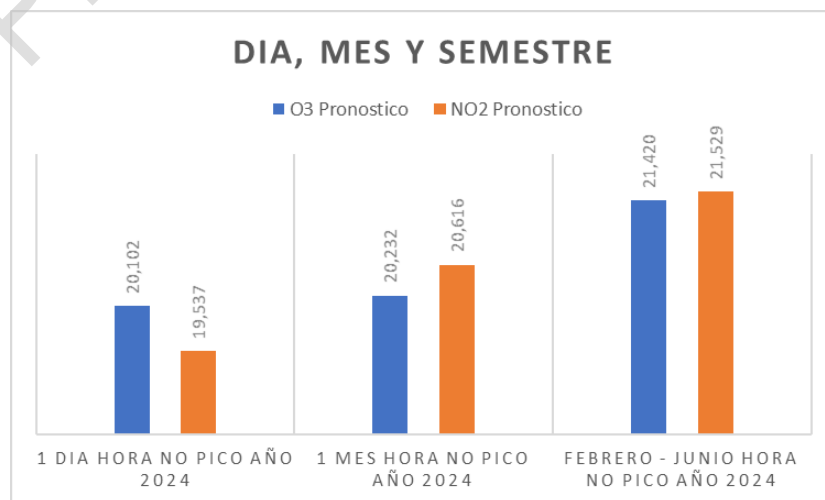
*Relación entre día, mes y semestre para CO<sub>2</sub> y CO en hora no pico 2024*



*Nota.* Fuente: autoría propia

**Figura 35**

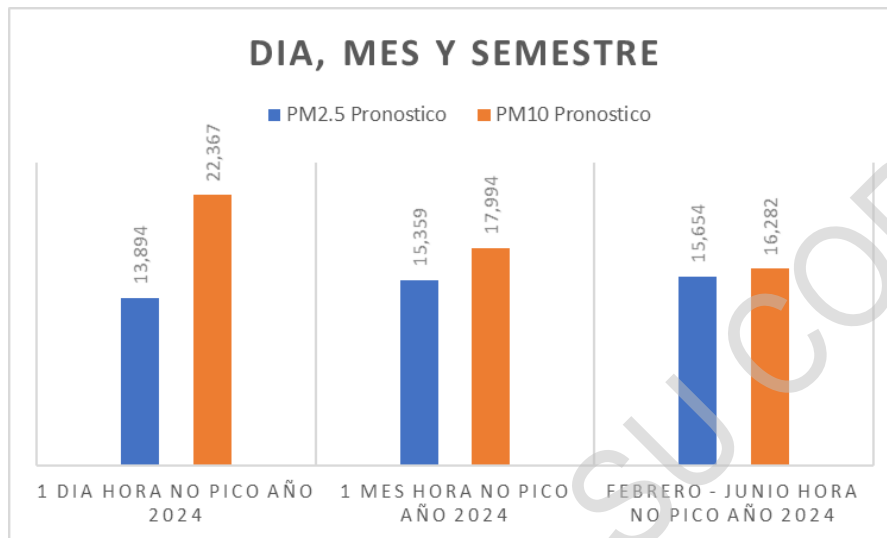
*Relación entre día, mes y semestre para O<sub>3</sub> y NO<sub>2</sub> en hora no pico 2024*



*Nota.* Fuente: autoría propia

**Figura 36**

*Relación entre día, mes y semestre para PM2.5 y PM10 en hora no pico 2024*

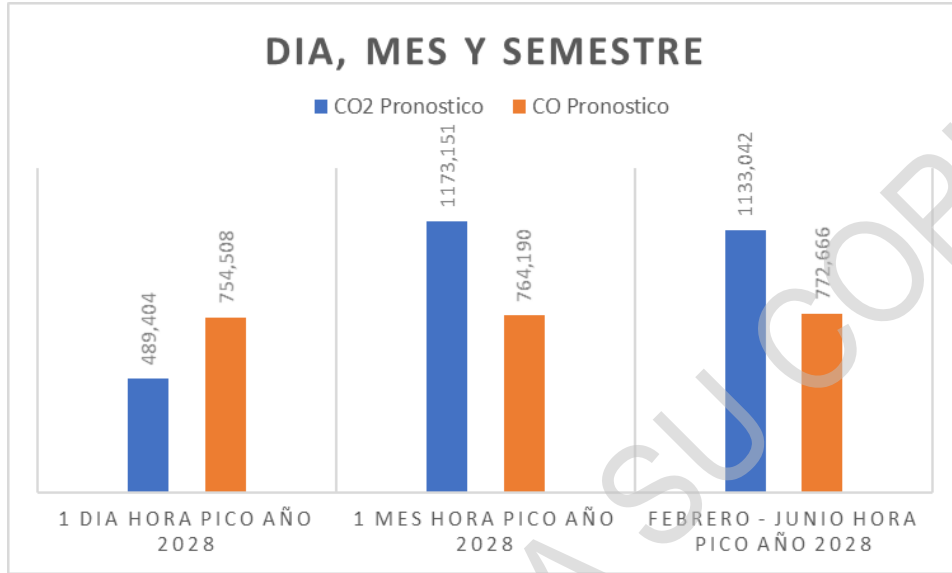


*Nota.* Fuente: autoría propia

Los datos de los niveles no pico de contaminación muestran tendencias interesantes al comparar en las diferentes escalas de tiempo. El nivel de CO<sub>2</sub> para un día aislado es normal y no indica algún evento inusual. Los promedios mensuales y de varios meses son consistentes con los niveles base actuales, sin expectativa de grandes cambios. El CO no pico sigue una clara tendencia a la baja que se mantiene en el corto y largo plazo, reflejando reducciones sostenidas en este contaminante. El ozono no pico se mantiene estable, mientras que el NO<sub>2</sub>, PM<sub>2.5</sub> y PM<sub>10</sub> no pico declinan gradualmente sobre todas las escalas de tiempo. Esto sugiere que las regulaciones ambientales están teniendo el efecto deseado para los contaminantes relacionados con la actividad vehicular e industrial. El análisis de los niveles no pico complementa el de los niveles pico al informar sobre las condiciones promedio de la calidad del aire y mostrar que las tendencias positivas se mantienen consistentemente.

**Figura 37**


*Relación entre día, mes y semestre para CO<sub>2</sub> y CO en hora pico 2028*



*Nota.* Fuente: autoría propia

**Figura 38**


*Relación entre día, mes y semestre para O<sub>3</sub> y NO<sub>2</sub> en hora pico 2028*



*Nota.* Fuente: autoría propia

**Figura 39**

*Relación entre día, mes y semestre para PM2.5 y PM10 en hora pico 2028*



*Nota.* Fuente: autoría propia

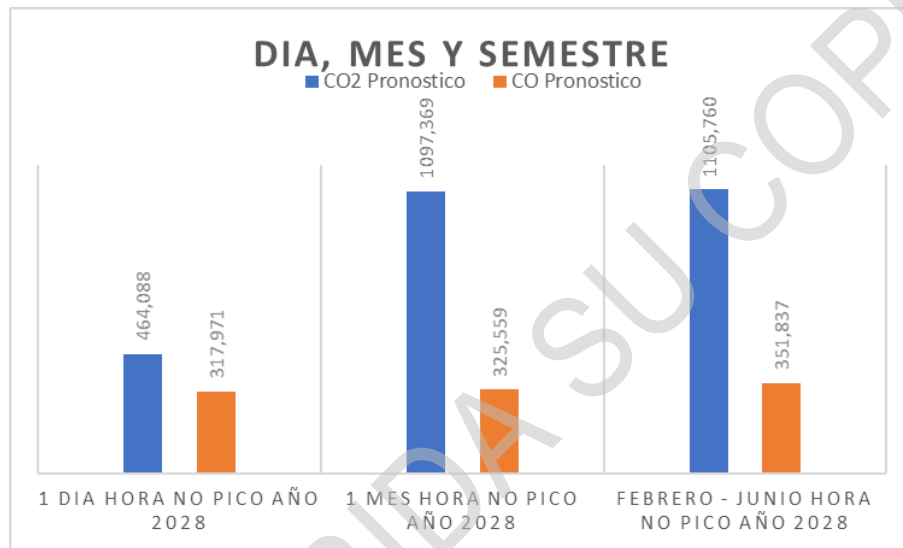
Los niveles pico de contaminación en 2028 muestran algunas tendencias mixtas al comparar en las diferentes escalas de tiempo. El nivel pico de CO<sub>2</sub> para un día aislado ha aumentado con respecto a 2024, posiblemente indicando mayores emisiones puntuales. Sin embargo, los promedios mensuales y de varios meses se mantienen más estables y consistentes con las tendencias a largo plazo. El CO pico continúa su tendencia descendente en todas las escalas de tiempo, mientras que el ozono pico se ha incrementado levemente, debido a condiciones meteorológicas que propician su formación. Los niveles pico de NO<sub>2</sub>, PM<sub>2.5</sub> y PM<sub>10</sub> son variables, con algunos incrementos para periodos cortos pero una tendencia a la baja en promedios mensuales y de varios meses. En general, los contaminantes relacionados con el transporte y la industria siguen mejorando, pero los niveles pico sugieren



la necesidad de mantener los esfuerzos de mitigación para lograr reducciones sostenidas a largo plazo en la calidad del aire.

**Figura 40**


*Relación entre día, mes y semestre para CO<sub>2</sub> y CO en hora no pico 2028*



*Nota.* Fuente: autoría propia

**Figura 41**


*Relación entre día, mes y semestre para O<sub>3</sub> y NO<sub>2</sub> en hora no pico 2028*



*Nota.* Fuente: autoría propia

**Figura 42**

*Relación entre día, mes y semestre para PM2.5 y PM10 en hora no pico 2028*



*Nota.* Fuente: autoría propia

Los datos de los niveles no pico de contaminantes en 2028 muestran tendencias principalmente positivas. El nivel de CO<sub>2</sub> para un día aislado se mantiene estable, mientras que los promedios mensuales y de varios meses continúan sin cambios significativos, como es esperado para este contaminante relacionado con emisiones a escala global. El CO no pico persiste en su tendencia descendente a corto y largo plazo. El ozono no pico permanece estable, con leves incrementos probablemente debidos a condiciones meteorológicas específicas. Los niveles no pico de NO<sub>2</sub>, PM<sub>2.5</sub> y PM<sub>10</sub> declinaron sustancialmente en todas las escalas de tiempo analizadas. Esto indica que las regulaciones y políticas de control de la contaminación están logrando reducciones sostenidas para emisiones vehiculares e industriales. En conjunto, los niveles no pico en 2028 muestran progreso continuo en la calidad del aire, aunque se requiere mantener los esfuerzos de mitigación para asegurar esta tendencia positiva.



## 9. CONCLUSIONES

En esta investigación se identificó la escasez de estudios actualizados que aborden la problemática de la calidad del aire en la ciudad de Pasto. En este contexto, la necesidad de llevar a cabo una monitorización de partículas PM10 y PM2.5, así como la vigilancia de gases contaminantes como el ozono, el dióxido de nitrógeno y el monóxido de carbono, se hizo evidente. La capacidad de detectar y comprender de manera temprana la presencia de estos contaminantes se convirtió en un elemento esencial para la implementación de medidas adecuadas destinadas a proteger tanto la salud de la población como el entorno, mitigando los riesgos tanto agudos como crónicos asociados con la contaminación atmosférica en la ciudad.

Se construyó un dispositivo portátil de un solo módulo equipado con sensores específicos para medir las variables de calidad del aire requeridas. Este enfoque permitió la creación de un dispositivo compacto y eficiente, con Arduino desempeñando un papel central al controlar tanto la adquisición como la transmisión de los datos capturados por los sensores. El resultado final fue un dispositivo que cumple con nuestro objetivo de construir algo compacto y de fácil traslado para el monitoreo de la calidad del aire.

Se implementó con éxito el dispositivo portátil diseñado para medir las variables de la calidad del aire en varios puntos de la Comuna 1. Durante esta fase de desarrollo, se presentó un problema relacionado con la elección de una fuente de alimentación que garantizara una autonomía prolongada para su funcionamiento. Para abordar este problema, optamos por utilizar baterías recargables con el voltaje y corriente necesaria para alimentar tanto el

Arduino como el módulo de sensores. Esta elección aseguró una autonomía y funcionalidad extendida, permitiendo que el dispositivo operará durante varias horas sin interrupción, lo que refuerza la capacidad del dispositivo para recopilar datos esenciales en diferentes ubicaciones de la comuna.

Se aplicó el aprendizaje automático a través de la regresión para entrenar una red neuronal que predice la calidad del aire a partir de datos de entrada. Para lograrlo, se realizó un preprocesamiento de datos que incluyó la normalización de características y la división en conjuntos de entrenamiento, validación y prueba. Luego, se construyó un modelo de red neuronal personalizado utilizando Keras, una herramienta conocida por su facilidad de uso, flexibilidad y capacidad de integración con otros marcos como TensorFlow. Este proceso de entrenamiento y evaluación culminó con el almacenamiento de los resultados, tanto las predicciones como los valores reales, en un archivo Excel.

Se comparó un análisis de la calidad del aire en donde revela que se proyecta un significativo aumento del 12% en los niveles de PM2.5 para el año 2028 en comparación con 2024, según el Índice de Calidad del Aire. Aunque en 2028 los niveles de CO, NO2 y PM10 se mantienen en la categoría "Buena" de acuerdo con la normativa vigente, PM2.5 alcanza un nivel "Aceptable", posiblemente debido al crecimiento del tráfico vehicular. Además, se observa un incremento generalizado en los niveles de los contaminantes, como CO2, CO, O3, NO2, PM2.5 y PM10, tanto en horas pico como en horas no pico, siendo el mayor aumento



en las concentraciones de dióxido de carbono (CO<sub>2</sub>), con un crecimiento estimado del 8.7% durante las horas pico de febrero a junio entre 2024 y 2028.

Se analizó que el crecimiento del parque vehicular en la ciudad tiene un impacto directo en los niveles de contaminación del aire, específicamente en contaminantes como CO, NO<sub>2</sub> y material particulado, que están relacionados con las emisiones de escape, este porcentaje de crecimiento vehicular se utilizó para entrenar la red neuronal y hacer los pronósticos futuros. Por lo tanto, el modelo está incorporando el efecto del aumento proyectado en la flota vehicular sobre los niveles de contaminantes, El incremento anual relativamente bajo (1.0194%) sugiere que el impacto del parque vehicular será gradual.

## 10. Recomendaciones

Con base en la experiencia adquirida al abordar el problema de la elección de la fuente de alimentación para el dispositivo, se sugiere para un futuro proyecto explorar fuentes de energía alternativas, como la energía solar o eólica, dependiendo de la ubicación y los requisitos del proyecto. Estas fuentes pueden proporcionar una solución sostenible y autónoma en ciertos contextos.

Dado que el dispositivo requiere un período inicial para estabilizarse y registrar datos correctos al ser iniciado, es esencial considerar que los datos recopilados durante este tiempo de aproximadamente 1 minuto, no deben incluirse en el conjunto de entrenamiento de la red neuronal. Estos datos iniciales deben ser descartados para garantizar la precisión y confiabilidad de la red neuronal durante su entrenamiento.

Se destacan recomendaciones clave para mantener esfuerzos de mitigación continuos y lograr reducciones sostenidas, incluyendo:

- Fomentar el uso del transporte público, bicicletas y caminar para reducir el tráfico y las emisiones vehiculares.
- Aplicar medidas de control del polvo en sitios de construcción y carreteras.
- Establecer sistemas de monitoreo de la calidad del aire para informar al público sobre los niveles de partículas en el aire.
- Llevar a cabo campañas de concienciación para informar a la población sobre los riesgos asociados a la contaminación del aire y cómo reducir la exposición.



- Promover la plantación de árboles y vegetación en áreas urbanas para mejorar la calidad del aire al capturar partículas.
- Impulsar el uso de vehículos eléctricos, híbridos y de bajas emisiones, así como sistemas de transporte público eficientes.

En base al pronóstico de la calidad del aire se debe tener en cuenta otros factores como el número de vehículos que no están registrados en la secretaría de tránsito y transitan por la ciudad, a medida que los años pasan, es común que los vehículos envejezcan, lo que a menudo se traduce en un aumento en sus emisiones contaminantes.

PROHIBIDA SU COPIA

## 11. ANEXOS

### ANEXO A

### CÓDIGO ARDUINO UTILIZADO EN EL DISPOSITIVO

```
codigo2 §
#include "SoftwareSerial.h"
#include <SPI.h>
#include <SD.h>
#include <Wire.h>
#define TX A3
#define RX A2

SoftwareSerial WinsenSerial(TX, RX);
int pml;int pm25;
int pml0;int co2;
int voc;float temp;
float rh;float ch2o;float co;
float o3;float no2;
int chk;
void read_winsen() {
  const uint8_t cmd[9] = {0xFF, 0x01, 0x86, 0x00, 0x00, 0x00, 0x00, 0x00, 0x79};
  for (int i = 0; i < 9; i++) {
    WinsenSerial.write(cmd[i]);
  }
  byte s[26];
  if (WinsenSerial.available()) {
    for (int i = 0; i < 26; i++) {
      s[i] = WinsenSerial.read();
    }
    pml = s[2] * 256 + s[3];pm25 = s[4] * 256 + s[5];
    pml0 = s[6] * 256 + s[7];co2 = s[8] * 256 + s[9];
    voc = s[10];temp = ((s[11] * 256 + s[12]) - 500) * 0.1;
    rh = s[13] * 256 + s[14];ch2o = (s[15] * 256 + s[16]) * 0.001;
    co = (s[17] * 256 + s[18]) * 0.1;o3 = (s[19] * 256 + s[20]) * 0.01;
    no2 = (s[21] * 256 + s[22]) * 0.01;chk = s[25];
  }
}
File ArchivoCSV;
int segundos=0;
int minutos=0;
int horas=0;
int dia=0;
void setup()
{
  Serial.begin(9600);
  //WinsenSerial.begin(9600);
  if (!SD.begin(4))
    Serial.println("Error al acceder a tarjeta SD.");//Mensaje de error.
    return;
  }
  Serial.println("Acceso correcto a tarjeta SD.");
  WinsenSerial.begin(9600); // Inicializa
```



```
}
void loop() {
  ArchivoCSV = SD.open("Datos.txt", FILE_WRITE);
  if (ArchivoCSV) { //Si se logra abrir, hacemos lo siguiente
    Serial.print("Escribiendo SD: ");
    delay(5000);
    read_winsen();
    co2 = (co2);String A = "ppm";
    voc = (voc);temp = (temp);String B = "°C";
    rh = (rh);String C = "%RH";
    ch2o = (ch2o);String D = "mg/m3";
    co = (co);String E = "ppm";
    o3 = (o3);String F = "ppm";
    no2 = (no2);String G = "ppm";
    pm1 = (pm1);String H = "ug/m3";
    pm25 = (pm25);String I = "ug/m3";
    pm10 = (pm10);String J = "ug/m3";
    segundos=segundos+10;
    if (segundos>=60) {
      segundos=segundos-60;
      minutos=minutos+1;
      if(minutos>=60) {
        minutos=minutos-60;
        horas=horas+1;
        if (horas>=24) {
          dia=dia+1;
          horas=horas-24;
        }
      }
    }
    ArchivoCSV.print("Tiempo = Dia ");ArchivoCSV.print(dia);
    ArchivoCSV.print(", ");
    if (horas<10)
    {
      ArchivoCSV.print("0");
    }
    ArchivoCSV.print(horas);ArchivoCSV.print(":");
    if (minutos<10)
    {
      ArchivoCSV.print("0");
    }
    ArchivoCSV.print(minutos);ArchivoCSV.print(":");
    if (segundos<10)
```

```

{
    ArchivoCSV.print("0");
}
ArchivoCSV.print(minutos);ArchivoCSV.print(":");
if(segundos<10)
{
    ArchivoCSV.print("0");
}
    ArchivoCSV.print(segundos);
    ArchivoCSV.print(" , CO2 = "); ArchivoCSV.print(co2 + A);
ArchivoCSV.print(" , VOC = ");ArchivoCSV.print(voc);
ArchivoCSV.print(" , TEMP = "); ArchivoCSV.print(temp + B);
ArchivoCSV.print(" , RH = ");ArchivoCSV.print(rh + C);
ArchivoCSV.print(" , CH2O = ");ArchivoCSV.print(ch2o + D);
ArchivoCSV.print(" , CO = ");ArchivoCSV.print(co + E);
ArchivoCSV.print(" , O3 = ");ArchivoCSV.print(o3 + F);
ArchivoCSV.print(" , NO2 = ");ArchivoCSV.print(no2 + G);
ArchivoCSV.print(" , PM1 = ");ArchivoCSV.print(pm1 + H);
ArchivoCSV.print(" , PM2.5 = ");ArchivoCSV.print(pm25 + I);
ArchivoCSV.print(" , PM10 = ");ArchivoCSV.println(pm10 + J);

ArchivoCSV.close(); //cerramos el archivo

Serial.print("Tiempo = Dia ");
Serial.print(dia);
Serial.print(" , ");
if(horas<10)
{
    Serial.print("0");
}
Serial.print(horas);
Serial.print(":");
if(minutos<10)
{
    Serial.print("0");
}
Serial.print(minutos);
Serial.print(":");
if(segundos<10)
{
    Serial.print("0");
}
Serial.print(segundos);
Serial.print(" , CO2 = ");Serial.print(co2 + A);
Serial.print(" , VOC = ");Serial.print(voc);
Serial.print(" , TEMP = ");Serial.print(temp + B);
Serial.print(" , RH = ");Serial.print(rh + C);

Serial.print(" , CH2O = ");Serial.print(ch2o + D);
Serial.print(" , CO = ");Serial.print(co + E);
Serial.print(" , O3 = ");Serial.print(o3 + F);
Serial.print(" , NO2 = ");Serial.print(no2 + G);
Serial.print(" , PM1 = ");Serial.print(pm1 + H);
Serial.print(" , PM2.5 = ");Serial.print(pm25 + I);
Serial.print(" , PM10 = ");Serial.println(pm10 + J);
}
else {
    Serial.println("Error al abrir el archivo");
}
while(millis()%36000!=0){}
}

```

## ANEXO B

## CÓDIGO PYTHON RED NEURONAL

```
D:\Users > Hp > Documents > uni > tesis > red.py > ...
1 import pandas as pd
2 import numpy as np
3 from sklearn.model_selection import train_test_split
4 from sklearn.preprocessing import StandardScaler
5 import matplotlib.pyplot as plt
6 from keras.models import Sequential
7 from keras.layers import Dense
8 import os
9
10 # Cargar Los datos desde el archivo Excel
11 data = pd.read_excel(r'd:\Users\Hp\Documents\uni\tesis\BASE_DATOS_pic_nopico.xlsx', sheet_name='NO PICO')
12
13 # Preprocesamiento de Los datos
14 X = data[['CO2', 'TEMP', 'RH', 'CO', 'O3', 'NO2', 'PM2.5', 'PM10']]
15 y = data[['CO2', 'CO', 'O3', 'NO2', 'PM2.5', 'PM10']]
16
17 scaler_X = StandardScaler()
18 scaler_y = StandardScaler()
19 X_normalized = scaler_X.fit_transform(X)
20 y_normalized = scaler_y.fit_transform(y)
21
22 # Dividir Los datos en conjuntos de entrenamiento, validación y prueba
23 X_train, X_test, y_train, y_temp = train_test_split(X_normalized, y_normalized, test_size=0.3, random_state=42)
24 X_val, X_test, y_val, y_test = train_test_split(X_test, y_test, test_size=0.5, random_state=42)
25
26 # Construcción del modelo de red neuronal
27 model = Sequential()
28 model.add(Dense(64, activation='relu', input_dim=X_normalized.shape[1]))
29 model.add(Dense(64, activation='relu'))
30 model.add(Dense(y_normalized.shape[1]))
31 model.compile(loss='mean_squared_error', optimizer='adam')
32
```

```
33 # Entrenamiento del modelo
34 model.fit(X_train, y_train, epochs=500, batch_size=32, validation_data=(X_val, y_val))
35
36 # Realización del pronóstico en el conjunto de prueba
37 y_pred_normalized = model.predict(X_test)
38
39 # Deshacer la normalización para obtener Los valores reales del pronóstico
40 y_pred = scaler_y.inverse_transform(y_pred_normalized)
41 y_test_original = scaler_y.inverse_transform(y_test)
42
43 # Calcular el promedio de cada valor de Las matrices
44 variables = ['CO2', 'CO', 'O3', 'NO2', 'PM2.5', 'PM10']
45 averages = {}
46 for i, variable in enumerate(variables):
47     real_values = y_test_original[:, i]
48     pred_values = y_pred[:, i]
49
50 # Calcular el promedio de Los valores reales y de predicción
51 avg_real = np.mean(real_values)
52 avg_pred = np.mean(pred_values)
53
54 averages[f'{variable}_Real'] = avg_real
55 averages[f'{variable}_Pred'] = avg_pred
56
57
58 # Convertir Los promedios a un DataFrame
59 averages_df = pd.DataFrame(averages, index=[0])
60
61 # Exportar a un archivo Excel y guardar Los promedios
62 file_path = r'd:\Users\Hp\Documents\uni\tesis\resultados_promedios_nopico.xlsx'
63 if os.path.exists(file_path):
64     # Leer el archivo Excel existente
```

```
65 existing_data = pd.read_excel(file_path)
66
67 # Concatenar Los nuevos promedios al DataFrame existente
68 all_data = pd.concat([existing_data, averages_df], ignore_index=True)
69 all_data.to_excel(file_path, index=False)
70 else:
71     averages_df.to_excel(file_path, index=False)
```

## ANEXO C

### Datos recolectados

Muestra de cómo se creó la base de datos con los datos recolectados por el dispositivo.

Repositorio:

<https://github.com/AndresJA45/Dispositivo-portable-para-el-monitoreo-de-la-calidad-del-aire>

1	DIA	HORA	CO2	TEMP	RH	CO	O3	NO2	PM2.5	PM10
2	1	12:00	509,70	8,40	0,86	667,71	28,13	42,88	30,58	16,31
3	1	12:00	509,70	8,10	0,85	821,64	52,72	42,19	22,43	23,45
4	1	12:01	509,70	8,30	0,86	766,59	43,10	32,71	15,29	24,47
5	1	12:01	509,70	8,70	0,86	637,13	38,16	51,97	29,56	24,47
6	1	12:02	526,01	9,20	0,87	698,29	34,89	51,00	23,45	23,45
7	1	12:03	535,19	9,50	0,86	703,39	37,18	40,92	28,54	23,45
8	1	12:03	544,36	9,70	0,85	667,71	25,50	34,65	21,41	23,45
9	1	12:04	571,88	9,50	0,84	789,02	52,03	48,25	35,68	24,47
10	1	12:04	576,98	9,30	0,84	650,38	46,09	49,45	21,41	23,45
11	1	12:05	574,94	9,30	0,83	679,94	53,89	31,25	21,41	24,47
12	1	12:06	574,94	9,50	0,83	699,31	48,81	43,85	28,54	23,45
13	1	12:06	541,30	9,50	0,83	805,33	52,96	32,46	32,62	23,45
14	1	12:07	484,22	9,20	0,83	666,69	36,78	20,97	36,70	24,47
15	1	12:07	451,59	8,90	0,83	570,86	37,07	50,70	32,62	24,47
16	1	12:08	426,11	8,90	0,83	834,89	29,01	41,23	26,50	24,47
17	1	12:09	416,93	8,90	0,84	683,00	60,70	35,64	18,35	24,47
18	1	12:09	415,92	8,90	0,84	777,80	38,23	36,98	18,35	24,47
19	1	12:10	414,90	9,00	0,84	612,66	46,61	30,62	21,41	24,47
20	1	12:10	414,90	8,80	0,84	565,77	45,64	55,15	25,49	23,45
21	1	12:11	414,90	8,60	0,85	727,85	44,91	29,32	25,49	23,45
22	1	12:12	414,90	8,60	0,85	845,08	43,62	37,41	37,72	23,45
9985	100		407,76	15,80	62,00	575,96	38,67	29,45	32,62	20,39
9986	100		410,82	15,90	62,00	839,99	44,20	35,80	33,64	20,39
9987	100		409,80	15,20	60,00	740,08	36,38	36,15	23,45	20,39
9988	100		410,82	14,80	60,00	753,34	30,27	36,46	22,43	20,39
9989	100		407,76	14,80	60,00	804,31	55,21	41,71	35,68	20,39
9990	100		408,78	15,00	60,00	716,64	26,38	33,58	14,27	20,39
9991	100		410,82	15,20	60,00	597,37	44,50	46,24	19,37	20,39
9992	100		408,78	15,20	60,00	750,28	37,09	45,01	13,25	32,62
9993	100		407,76	14,40	60,00	502,56	37,60	42,98	19,37	32,62
9994	100		409,80	13,90	61,00	737,03	34,10	43,95	26,50	32,62
9995	100		409,80	14,70	61,00	620,81	43,37	44,42	22,43	32,62
9996	100		407,76	14,90	61,00	793,09	22,75	44,79	28,54	32,62
9997	100		410,82	14,60	61,00	542,32	38,38	43,86	29,56	32,62
9998	100		408,78	14,50	61,00	656,49	24,07	61,85	32,62	32,62
9999	100		409,80	14,80	62,00	640,18	49,63	41,89	32,62	32,62
10000	100		409,80	14,50	62,00	823,68	27,91	44,35	23,45	32,62
10001	100		411,84	14,40	62,00	568,83	30,73	37,97	13,25	32,62

**ANEXO D**

**COMUNA 1 CIUDAD DE PASTO**



ANEXO E

Información ST PASTO



Los 229.894 registros han sido registrados en las siguientes fechas:

		PARQUE AUTOMOTOR POR CLASE														TOTAL	%
ÍTEM	POR CLASE	Anteriores	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023				
1	MOTOCICLETA	72300	9840	11128	12720	11462	8850	7877	8603	3862	5771	4219	3156	159788	69,5051%		
2	AUTOMÓVIL	28542	1737	1938	1730	1322	1250	1410	1413	374	589	439	193	40937	17,8069%		
3	CAMIONETA	7863	1022	1106	1070	943	958	983	1025	479	893	667	320	17329	7,5378%		
4	CAMPERO	4789	104	129	115	117	85	60	48	22	38	45	31	5583	2,4285%		
5	CAMION	1574	48	52	70	31	30	24	37	19	30	32	18	1965	0,8547%		
6	SEMIREMOLQUE	810	33	7	16	10	10	10	14	9	20	11	12	962	0,4185%		
7	BUS	780	39	29	14	11	8	9	26	3	3	2	3	927	0,4032%		
8	MOTOCARRO	96				11	98	111	51	28	57	39	36	527	0,2292%		
9	BUSETA	441		3	4	1			4					453	0,1970%		
10	MICROBUS	356	20	25	14	3	3	4	12			4	5	446	0,1940%		
11	VOLQUETA	367	7	16	6	3	3	4	6		4	4	5	425	0,1849%		
12	TRACTOCAMION	335	2	3	1			3	3	1	1	6	3	358	0,1557%		
13	CICLOMOTOR	0						4	10	2	11	24	25	76	0,0331%		
14	MAQ. AGRICOLA	25												25	0,0109%		
15	CUATRIMOTO	16					4							20	0,0087%		
16	RETROEXCAVADORA	0			2	12	1	1			1	1	1	19	0,0083%		
17	EXCAVADORA	0			1	7	3	3	1			1		16	0,0070%		
18	TRACTOR	0			2	3		2	1		5			13	0,0057%		
19	MOTONIVELADORA	0			2	2					1		1	6	0,0026%		
20	MOTOTRICICLO	6												6	0,0026%		
21	MINICARGADOR	0						4						4	0,0017%		
22	RETROCARGADOR	0						3						3	0,0013%		
23	COMPACTADOR	0				2								2	0,0009%		
24	BULDOZER	0				1								1	0,0004%		
25	MAQ. INDUSTRIAL	1												1	0,0004%		
26	REMOLQUE	0				1								1	0,0004%		
27	SIN CLASE	0		1										1	0,0004%		
<b>TOTAL</b>		<b>118301</b>	<b>12852</b>	<b>14437</b>	<b>15767</b>	<b>13942</b>	<b>11303</b>	<b>10512</b>	<b>11254</b>	<b>4799</b>	<b>7424</b>	<b>5494</b>	<b>3809</b>	<b>229894</b>	<b>100,0%</b>		

Agradecemos la atención prestada.

Atentamente,



**JORGE ANDRÉS RESTREPO CARDONA**  
**Subgerente Operativo**  
 Servicios de Tránsito Pasto

Proyectó Jorge A Restrepo C  
 Subgerente Operativo.



## 12. REFERENCIAS

- ARCINIÉGAS, C. (2012). *DIAGNÓSTICO Y CONTROL DE MATERIAL PARTICULADO: PARTÍCULAS SUSPENDIDAS TOTALES Y FRACCIÓN RESPIRABLE PM10*.  
[http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S1909-24742012000100012](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1909-24742012000100012)
- Ballester, F. (s.f.). CONTAMINACIÓN ATMOSFÉRICA, CAMBIO CLIMÁTICO Y SALUD. *SciELO España*.  
[https://www.scielosp.org/article/ssm/content/raw/?resource\\_ssm\\_path=/media/assets/resp/v79n2/v79n2a05.pdf](https://www.scielosp.org/article/ssm/content/raw/?resource_ssm_path=/media/assets/resp/v79n2/v79n2a05.pdf)
- Benavides, I. F. (2019, September 30). *Calidad del aire en Pasto no es la mejor de Colombia*. Udenar Periódico. Retrieved March 25, 2023, from <https://periodico.udenar.edu.co/calidad-del-aire-en-pasto-no-es-la-mejor-de-colombia/>
- Burgos, L. M. (2022). *Emisiones de dióxido de carbono relacionadas con las operaciones unitarias de la industria de la construcción. Revisión de literatura*.  
<https://repository.ucc.edu.co/items/b47256e3-9112-4631-bc5e-e48080ee6bbd>
- Calidad del aire OMS*. (n.d.). Calidad del aire - OPS/OMS | Organización Panamericana de la Salud. Retrieved October 5, 2023, from <https://www.paho.org/es/temas/calidad-aire>
- Camilo, J. (s.f.). *Prototipo de un modelo de machine learning para la predicción de partículas de contaminación atmosférica finas, en la localidad de Kennedy en la ciudad de Bogotá - hdl:11349/15772*. RIUD. Retrieved March 25, 2023, from <https://repository.udistrital.edu.co/handle/11349/15772>





- Corporación Autónoma Regional de Nariño. (2017). *Sistema Vigilancia Calidad Aire*.  
Corporación Autónoma Regional de Nariño. Retrieved March 25, 2023, from  
<https://corponarino.gov.co/tramites-y-servicios/tramites-ambientales/recurso-aire/sistema-vigilancia-calidad-aire/>
- Correa, G. (2021). Prototipo de red neuronal artificial para el pronóstico de eventos críticos por partículas PM<sub>2.5</sub> en el centro de la ciudad de Manizales.  
<http://hdl.handle.net/11371/4259>
- Duque, R. (2011). *Python PARA TODOS*. Academia.edu. Retrieved April 9, 2023, from  
[https://www.academia.edu/15046254/Python\\_PARA\\_TODOS\\_Ra%C3%BAI\\_Gonz%C3%A1lez\\_Duque\\_Python\\_PARA\\_TODOS](https://www.academia.edu/15046254/Python_PARA_TODOS_Ra%C3%BAI_Gonz%C3%A1lez_Duque_Python_PARA_TODOS)
- Fernández, Y. (2018, July 21). *Qué es Arduino, cómo funciona y qué puedes hacer con uno*. Xataka. Retrieved April 9, 2023, from  
<https://www.xataka.com/basics/que-arduino-como-funciona-que-puedes-hacer-uno>
- García, V. (2008). *Sensores químicos*. Universidad de Valladolid.
- Gil, M. A., & Alvarez, L. F. (2012). *PUESTA A PUNTO DE AUTOMOTORES 2 Y 4 TIEMPOS, CARBURACIÓN E INYECCIÓN*.
- González, & Javier. (2015). *Medición de Distancia y Velocidad empleando un Sensor de Ultrasonidos*. Universidad de Valladolid. Escuela de Ingenierías Industriales.  
<http://uvadoc.uva.es/handle/10324/16646>
- Gravity: *Laser PM<sub>2.5</sub> Air Quality Sensor For Arduino*. (s.f.). DFRobot. Retrieved April 9, 2023, from <https://www.dfrobot.com/product-1272.html>





- Guarella, J., Heredia, J., Rodriguez, L., & Bagatto, I. (2011, 9 28). *Sensores y actuadores en motores*. Universidad Nacional de la Plata.
- Instituto de Hidrología, Meteorología y Estudios Ambientales. (s.f.). *CALIDAD DEL AIRE - Bogotá*. IDEAM. Retrieved March 25, 2023, from <http://www.ideam.gov.co/web/contaminacion-y-calidad-ambiental/calidad-del-aire>
- Menéndez, C., Rivas, P., & Saturnino. (s.f.). *Capitulo Contaminación Atmosférica*.
- Ministerio de ambiente, vivienda y desarrollo territorial. (2010, Marzo 29). *Resolución 650*.
- Ministerio de Ambiente y Desarrollo Sostenible. (2010). *Resolución 2154 de 2010*. Retrieved April 9, 2023, from <https://www.minambiente.gov.co/documento-normativa/resolucion-2154-de-2010/>
- Ministerio de Ambiente y Desarrollo Sostenible. (2017). *Resolución 2254*. Retrieved April 9, 2023, from <https://www.minambiente.gov.co/documento-entidad/resolucion-2254-de-2017/>
- Ministerio de Ambiente y Desarrollo Sostenible. (2019, March 9). *Resolución 2254 de 2017*. Retrieved October 5, 2023, from <https://www.minambiente.gov.co/wp-content/uploads/2021/10/Resolucion-2254-de-2017.pdf>
- Organización Mundial de la Salud. (s.f.). Guías de calidad del aire de la OMS relativas al material particulado, el ozono, el dióxido de nitrógeno y el dióxido de azufre. [https://apps.who.int/iris/bitstream/handle/10665/69478/WHO\\_SDE\\_PHE\\_OEH\\_06.02\\_spa.pdf;jsessionid=F61C0E0ECD91545D3B594C86F6FC4758?sequence=1](https://apps.who.int/iris/bitstream/handle/10665/69478/WHO_SDE_PHE_OEH_06.02_spa.pdf;jsessionid=F61C0E0ECD91545D3B594C86F6FC4758?sequence=1)



- Rouhiainen, L. (2018). In *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*. Alienta Editorial.
- Ruiz, A., García, F., & Noguera, J. (2010). *GUÍA PRÁCTICA DE SENSORES*. Creaciones Copyright, S.L.
- Salas, R. (s.f.). *Redes neuronales artificiales*. Universidad de Valparaíso.
- Sancarranco, E. (2022). *El dióxido de carbono como agente de contaminación ambiental en la región Piura*.
- Serrano, S., & Judith, L. (2018, October 15). *Repositorio Digital de Ciencia y Cultura de El Salvador REDICCES: Algoritmos de aprendizaje automático para análisis y predicción de datos*. REDICCES. Retrieved April 9, 2023, from <http://redicces.org.sv/jspui/handle/10972/3626>
- Solis, M. d. l. Á. L. (2018). *Análisis del comportamiento de la Radiación Eritemal UV y su relación con la Columna Total de Ozono reportada por OMI en el Estado de Zacatecas*. <http://ricaxcan.uaz.edu.mx/jspui/handle/20.500.11845/1320>
- Torres, R. (2021, October 3). *Estándares de Calidad del Aire - Legislación Comparada*. *Biblioteca del Congreso Nacional de Chile*. [https://obtienearchivo.bcn.cl/obtienearchivo?id=repositorio/10221/32571/1/Estandares\\_de\\_Calidad\\_del\\_Aire.\\_Legislacion\\_Comparada.pdf](https://obtienearchivo.bcn.cl/obtienearchivo?id=repositorio/10221/32571/1/Estandares_de_Calidad_del_Aire._Legislacion_Comparada.pdf)
- Trujillo, Caballero, & Ramon. (2020). *DETERMINACIÓN DE LAS CONCENTRACIONES DE METALES PESADOS PRESENTES EN EL MATERIAL PARTICULADO PM10 DEL MUNICIPIO DE SAN JOSÉ DE CÚCUTA, NORTE DE SANTANDER*. <https://ojs.unipamplona.edu.co/ojsviceinves/index.php/aaas/article/view/402/370>



*Vista de Contaminación ambiental producida por el tránsito vehicular y sus efectos en la*

*salud humana: revisión de literatura.* (n.d.). Revistas UNIMINUTO. Retrieved Julio 6, 2023, from

<https://revistas.uniminuto.edu/index.php/Inventum/article/view/2612/2165>

*ZPHS01B Multi-in-one Air Quality Monitoring Sensor Module--Winsen.* (s.f.). Winsen

sensor. Retrieved April 9, 2023, from

<https://www.winsen-sensor.com/sensors/co2-sensor/zphs01b.html>

PROHIBIDA SU COPIA