

Aplicación de modelos de aprendizaje de máquina e imágenes digitales para el pronóstico de la calidad del aire.

Raúl Andrés García Rojas¹, Dayam Calderón Rivera², Nidia Isabel Molina Gomez^{3*}

¹ Universidad Santo Tomas. raulgarciarsantotomas.edu.co

² Universidad Santo Tomas. dayamcalderon@usantotomas.edu.co

³ Universidad Santo Tomas. * nidiamolina@usantotomas.edu.co

La contaminación atmosférica representa graves impactos sobre la salud de la población; particularmente la exposición a altas concentraciones de ozono troposférico puede provocar problemas respiratorios y cardiovasculares, es por esto que un sistema eficiente de seguimiento y monitoreo de la calidad del aire es de gran beneficio para la salud humana y el control de la contaminación atmosférica. En esta investigación, se aborda el pronóstico de la calidad del aire mediante la aplicación de modelos de aprendizaje de máquina e imágenes digitales en función del índice de calidad del aire (ICA) para el contaminante O₃, haciendo uso de la técnica de redes neuronales convolucionales, bajo una arquitectura de modelado VGG16. Para evaluar el método propuesto, se creó un conjunto de datos que contiene un total de 366 imágenes, registradas a las 07:00 y 12:00 horas del día, en dirección de cuatro localidades de la ciudad de Bogotá, durante un periodo de tiempo establecido de marzo a octubre del año 2021. El conjunto de imágenes fue clasificado frente a los datos recopilados de las estaciones de monitoreo de: Las Ferias, Puente Aranda, Centro de Alto Rendimiento y Fontibón. El entrenamiento y validación del modelo se ejecutó a 50 épocas y un tamaño de lote de 64 muestras. El modelo identificó tres categorías del índice de calidad del aire (ICA); buena, aceptable y dañina a la salud de grupos sensibles. Los resultados de las métricas de rendimiento del modelo para estas categorías reflejan en términos de accuracy (70%), (50%) y (46%) respectivamente, sin embargo, se establece, que se puede mejorar dicho rendimiento aplicando estrategias de sobre muestreo y refinamiento de algoritmos. El modelo propuesto es válido contrastado a lo identificado en la literatura y puede ser una herramienta prometedora para la clasificación de imágenes digitales.

Keywords aprendizaje automático; redes neuronales convolucionales; ozono troposférico.

Abstract- Air pollution represents serious impacts on the health of the population; particularly exposure to high concentrations of tropospheric ozone can cause respiratory and cardiovascular problems, which is why an efficient air quality monitoring system is of great benefit to human health and air pollution control. In this research, air quality forecasting is addressed through the application of machine learning models and digital images as a function of the air quality index (AQI) for the pollutant O₃, making use of the convolutional neural network technique, under a VGG16 modeling architecture. To evaluate the proposed method, a dataset was created containing a total of 366 images, recorded at 07:00 and 12:00 hours of the day, in the direction of four localities of the city of Bogotá, during a period of time established from March to October 2021. The set of images was classified against the data collected from the monitoring stations of: Las Ferias, Puente Aranda, Centro de Alto Rendimiento and Fontibón. The training and validation of the model was run at 50 epochs and a batch size of 64 samples. The model identified three categories of air quality index (AQI); good, acceptable and harmful to the health of sensitive groups. The results of the model performance metrics for these categories reflect in terms of accuracy (70%), (50%) and (46%) respectively, however, it is established that the performance can be improved by applying strategies of oversampling and algorithm refinement. The proposed model is valid in contrast to what has been identified in the literature and can be a promising tool for digital image classification.

Keywords machine learning; convolutional neural networks; tropospheric ozone.

1 Introducción

La calidad del aire es el resultado de las interacciones entre fuerzas motrices en las cuales se encuentran: el crecimiento demográfico, un modelo de desarrollo económico, los patrones de movilidad, como también el estado de las tecnologías. La sinergia de dichas fuerzas da como resultado la generación de emisiones contaminantes provenientes del transporte, la industria, entre otros (Baena Salazar, Jiménez, Zapata, & Ramírez Cardona, 2019). Los contaminantes emitidos se encuentran condicionados a procesos de dispersión, transporte y transformación de la atmósfera. No obstante, a pesar de los importantes avances en la comprensión de las emisiones y los diferentes tipos de contaminantes, así como en la reducción de sus niveles en algunas zonas urbanas durante las últimas décadas; la contaminación atmosférica mata alrededor de 3 millones de personas al año en todo el mundo (Zang, Bocquet, Mallet, Seigneur, & Baklanov, 2012).

La contaminación atmosférica en Colombia es uno de los factores de mayor preocupación debido a los impactos generados en la salud de las personas y en el ambiente. Con base en los registros obtenidos por los sistemas de vigilancia de calidad del aire (SVCA), el contaminante con mayor problemática en el país es el material particulado con tamaños menores a dos puntos cinco y diez micras ($PM_{2.5}$ y PM_{10}). Existen además otros contaminantes que impactan directamente en el ambiente y en la salud de la población, como los gases de combustión (óxidos de nitrógeno NO_x , el dióxido de azufre SO_2 , el monóxido de carbono CO , entre otros), los compuestos orgánicos volátiles (COV) y contaminantes secundarios formados por reacciones químicas en el aire, como el ozono troposférico (O_3) (Ministerio de Ambiente y Desarrollo Sostenible, 2019).

El ozono se produce en la tropósfera por oxidación en fase gaseosa de hidrocarburos y monóxido de carbono, esta reacción es catalizada por radicales de óxido de hidrógeno y radicales de óxido de nitrógeno (Jacob, 2000); además en diversos estudios se afirma que la concentración del ozono troposférico presenta una dependencia de varios parámetros meteorológicos (Makarova, Evstafeva, Lapchenco, & Varbanov, 2021), entre estos, se encuentran la nubosidad (Belán, 2010), la influencia de sistemas de altas presiones a escala sinóptica, la presencia de altas temperaturas con bajos índices de humedad y la presencia de vientos a bajas velocidades (Collazo, Morales, & Morales, 2012). Adicionalmente, los autores Abdul-Wahab & Al-Alawi (2002) afirman que el óxido de nitrógeno, el dióxido de azufre, la humedad relativa, los hidrocarburos no metánicos y el dióxido de nitrógeno tienen el mayor efecto sobre las concentraciones de ozono.

Por otra parte, se encuentran sumideros de ozono troposférico que según Delgado Saborit (2005) se dividen en deposición seca donde el contaminante es absorbido irreversiblemente en el suelo, el agua o la superficie de las plantas y la deposición húmeda, donde el contaminante es incorporado a elementos de precipitación, compuestos por nubes, gotas de lluvia y aerosoles. Sobre este último sumidero, Warneck (1988) afirma que la deposición húmeda evidencia un bajo rendimiento en el lavado de la atmósfera por precipitación, esto se debe a que el ozono presenta baja solubilidad en agua.

Se destaca además que la exposición al ozono troposférico representa un grave problema de salud pública (Makarova, Evstafeva, Lapchenco, & Varbanov, 2021); su exposición a corto plazo se asocia con la hipoxemia en donde disminuye la función pulmonar, pues el ozono es un gas altamente oxidante al alcanzar las vías respiratorias bajas, como lo afirman Rosales, Torres Meza, & Olaiz Fernandez (2001), generando así ingresos hospitalarios por enfermedades respiratorias y cardiovasculares. En consecuencia, se establece que las cargas de salud estimadas atribuibles a la contaminación del aire y específicamente al ozono troposférico son cercanas a 250.000 muertes anuales en todo el mundo (Doherty, Heal, & O'Connor, 2017).

A razón de lo mencionado, la conferencia de las naciones unidas sobre medio ambiente y desarrollo de 1992 estableció que la degradación ambiental en las urbes constituía un aspecto que requería atención inmediata. Por lo cual se motivó a los gobiernos locales y nacionales, así como a la comunidad internacional, a incrementar los esfuerzos para obtener información confiable y accesible sobre las concentraciones de contaminantes, sus fuentes y sus efectos (Programa de las Naciones Unidas para el Medio Ambiente PNUMA, 1994).

En este orden de ideas, el seguimiento y evaluación de los niveles máximos permisibles para contaminantes del aire, en la ciudad de Bogotá, Colombia, es realizado por la Red de Monitoreo de Calidad del Aire de Bogotá (RMCAB), la cual opera desde el año de 1997, esta red es la encargada de recolectar información sobre la concentración de contaminantes y variables meteorológicas de forma continua en las diferentes localidades de la ciudad. La red está conformada por veinte estaciones de monitoreo, las cuales permiten un monitoreo continuo de las concentraciones de contaminantes criterio: material particulado (PM_{10} , $PM_{2.5}$), y gases contaminantes (SO_2 , NO_2 , CO , O_3), así como de las variables meteorológicas: precipitación, velocidad y dirección del viento, temperatura, radiación solar, humedad relativa y presión barométrica (Ministerio de Ambiente y Desarrollo Sostenible, 2019).

1 A nivel mundial se han utilizado diversas fuentes de información para predecir los niveles de contaminación
2 atmosférica con el fin de mitigar los impactos generados en el ambiente y en la salud de la población; uno de los
3 métodos más prometedores es el aprendizaje automático, que en los últimos años ha ganado atención en
4 aplicaciones de ingeniería (Dissanayake, Nguyen, Poologanathana, & Perampalama, 2022), debido a su capacidad
5 para procesar, con alta exactitud, datos complejos (Saleem & Chishti, 2021). El aprendizaje automático es un
6 método científico que permite a los dispositivos con capacidad computacional aprender a extraer por sí solos
7 patrones y relaciones existentes en los datos. Esos patrones pueden ser usados para predecir comportamientos de
8 la información analizada para la toma de decisiones, siendo este un subcampo de las ciencias de la computación y
9 una rama de la inteligencia artificial, cuya finalidad es desarrollar técnicas que permitan a las máquinas aprender,
10 siendo así el eje principal para el manejo de datos a gran escala, para la creación de modelos y algoritmos
11 (Mitchell, 1997), estos últimos tienen la capacidad de dividir, ordenar y transformar (Reichstein, Camps Valls,
12 Stevens, Jung, & Denzler, 2019), un conjunto de datos multidimensional comprendidos por sonidos, textos e
13 imágenes (Piuri, Raj, Genovese, & Srivastava, 2020).

14
15 Concretamente, Park, Cheong Took, & Seong, (2018), afirman que el aprendizaje automático es capaz de
16 resolver una amplia variedad de problemas, en donde se incluyen el reconocimiento de imágenes y la fotografía
17 computacional, dando lugar a una nueva dimensión de investigación, en donde se formulan enfoques relacionados
18 con el uso de redes neuronales artificiales, ya que estas han mostrado un gran avance en el desempeño en estas
19 áreas, haciendo uso especialmente de las redes neuronales convolucionales como lo establece en su investigación
20 Sharma, Jain, & Mishra (2018).

21
22 Las redes neuronales convolucionales, procesan sus capas imitando al córtex visual del cerebro humano para
23 identificar distintas características en las entradas. Para ello, la red contiene varias capas ocultas especializadas y
24 con una jerarquía: las primeras capas detectan propiedades o formas básicas y se van especializando hasta llegar a
25 capas más profundas capaces de reconocer formas complejas (Perez Carrasco, 2019). Este tipo de redes permite
26 una clasificación efectiva y eficiente de imágenes ya que incluyen la capacidad de manejar datos de alta
27 dimensionalidad y mapear clases con características muy complejas (Maxwell & Warner, 2018). Estas redes se
28 componen de tres tipos de capas; convolución, agrupación y capas totalmente conectadas. Las dos primeras
29 realizan la extracción de características, mientras que la tercera, una capa completamente conectada, mapea las
30 características extraídas en el resultado final (Yamashita, Nishio, Kinoshita, & Togashi, 2018).

31
32 El uso de este tipo de redes para la predicción de ozono troposférico también se llevó a cabo en la ciudad de
33 Vitoria, Brasil; el objetivo de los autores fue comprobar la viabilidad de utilizar modelos de redes neuronales
34 recurrentes y convolucionales en la tarea de predecir los niveles de O_3 cada hora durante 24 horas, como resultado,
35 los autores Junior, Sperandio Nascimento, & Martins Moreira (2020) concluyeron que este tipo de redes
36 presentaban un gran potencial de predecir los niveles de O_3 en un área urbana. Los autores además infirieron sobre
37 el comportamiento de las concentraciones del contaminante en los datos de prueba para cada modelo utilizado con
38 el uso de la red neuronal recurrente de memoria a corto plazo.

39
40 Por otra parte, cabe resaltar que las diferentes técnicas de aprendizaje automático han aportado
41 sustancialmente al seguimiento y monitoreo de la calidad del aire a nivel mundial, esto se puede evidenciar en
42 proyectos desarrollados en Centroamérica particularmente en el Salvador, donde se llevó a cabo un sistema
43 telemático de monitoreo de calidad del aire en zonas remotas, como también el desarrollo de una plataforma para
44 el análisis de datos y generación de modelos por medio de técnicas de *big data* y *machine learning*, los cuales
45 apoyan las mediciones realizadas por el Ministerio de Medio Ambiente y Recursos Naturales siendo ésta la entidad
46 encargada de realizar las mediciones y divulgación de datos referente a la calidad del aire en dicho país (Martínez
47 Pérez & López de Jiménez, 2020).

48
49 Baena Salazar, Jiménez, Zapata, & Ramírez Cardona (2019) desarrollaron una red neuronal artificial para el
50 pronóstico de eventos críticos de $PM_{2.5}$ en el Valle de Aburrá en Colombia, a una escala diaria, en el cual hacían
51 uso de información de tres estaciones de la Red de Monitoreo de Calidad del Aire del Área Metropolitana y donde
52 concluyeron que el modelo construido bajo la técnica de redes neuronales, identifica dentro del periodo de
53 validación los posibles eventos de contaminación crítica; sin embargo, tiene un margen de error del 30% entre los
54 valores pronosticados y los valores observados.

55
56 En la localidad de Kennedy en Bogotá-Colombia, Pedroza Camelo (2018) desarrolló una investigación en la cual
57 empleó un modelo de aprendizaje automático para la predicción de partículas finas, en esta investigación el autor
58 concluyó que la red neuronal utilizada permite la predicción del contaminante, como también afirma que se pueden
59 comprobar las posibilidades sobre las que se puede trabajar al aplicar métodos de aprendizaje automático en
60 distintos aspectos que impactan a los seres humanos. En correspondencia, en investigaciones como la realizada
61 por Molina-Gómez (2021), fue posible establecer la incidencia de la calidad del aire sobre el desarrollo urbano
62 sostenible, en sus dimensiones ambiental, social y económica, mediante el uso de herramientas de aprendizaje
63 automático, incluyendo a las redes neuronales artificiales, tomando como caso de estudio a la localidad de Kennedy

1 en Bogotá. Esta investigación concluyó que haciendo uso de las herramientas de aprendizaje automático como las
 2 redes neuronales es posible, además, predecir el comportamiento espacial del desempeño urbano sostenible en un
 3 micro territorio.
 4

5 Particularmente Suk Suh, Min, Yang , Kim, & Park (2022) desarrollaron una técnica de aprendizaje
 6 automático que utiliza patrones de imagen para predecir las concentraciones de partículas con un diámetro
 7 aerodinámico de $10\mu\text{m}$ que se originan en los vehículos de la carretera perteneciente al distrito Yuseong de Daejeon
 8 en Corea del Sur. Específicamente los autores, seleccionaron 600 datos de imágenes para las predicciones de las
 9 concentraciones de PM_{10} generadas por los vehículos, en donde identificaron patrones específicos en las imágenes
 10 mediante un algoritmo de reconocimiento de imágenes desarrollado bajo la técnica de redes neuronales
 11 convolucionales, dicho algoritmo obtuvo un 98% de precisión en la predicción de concentraciones de PM_{10}
 12 generadas. Los autores concluyeron que el método propuesto es una herramienta efectiva para monitorear la
 13 calidad del aire al conectar la información de tráfico en regiones donde el equipo de medición de partículas no se
 14 puede instalar cerca de las carreteras.
 15

16 Dicho esto, es importante mencionar que en la ciudad de Bogotá no se han realizado investigaciones
 17 particulares empleando técnicas de aprendizaje automático para la predicción particular del contaminante
 18 denominado ozono troposférico. Además, aun cuando se cuenta con una red de monitoreo de la calidad del aire,
 19 el uso de imágenes digitales puede aportar en la predicción del contaminante. Es por este motivo que, esta
 20 investigación tiene como objetivo desarrollar un modelo clasificatorio de imágenes digitales en función del índice
 21 de calidad del aire (ICA) para el contaminante O_3 , haciendo uso de la técnica de redes neuronales convolucionales,
 22 bajo una arquitectura de modelado denominada VGG16. Tomando en cuenta la falta de cobertura en las redes de
 23 seguimiento y monitoreo de la calidad del aire en diferentes áreas del territorio para el ozono troposférico, se
 24 plantea la necesidad de emplear un instrumento que suministre dicha información, es por ello que la investigación
 25 desarrollada establecerá un precedente en estudios futuros en la identificación del comportamiento de la calidad
 26 del aire a partir de imágenes digitales.
 27
 28

29 2 Métodos

30
 31 La presente investigación consta de cuatro etapas como se describen a continuación (ver figura 1): 1) área de
 32 estudio, 2) preparación de los datos, 3) modelado y 4) evaluación del modelo.
 33
 34

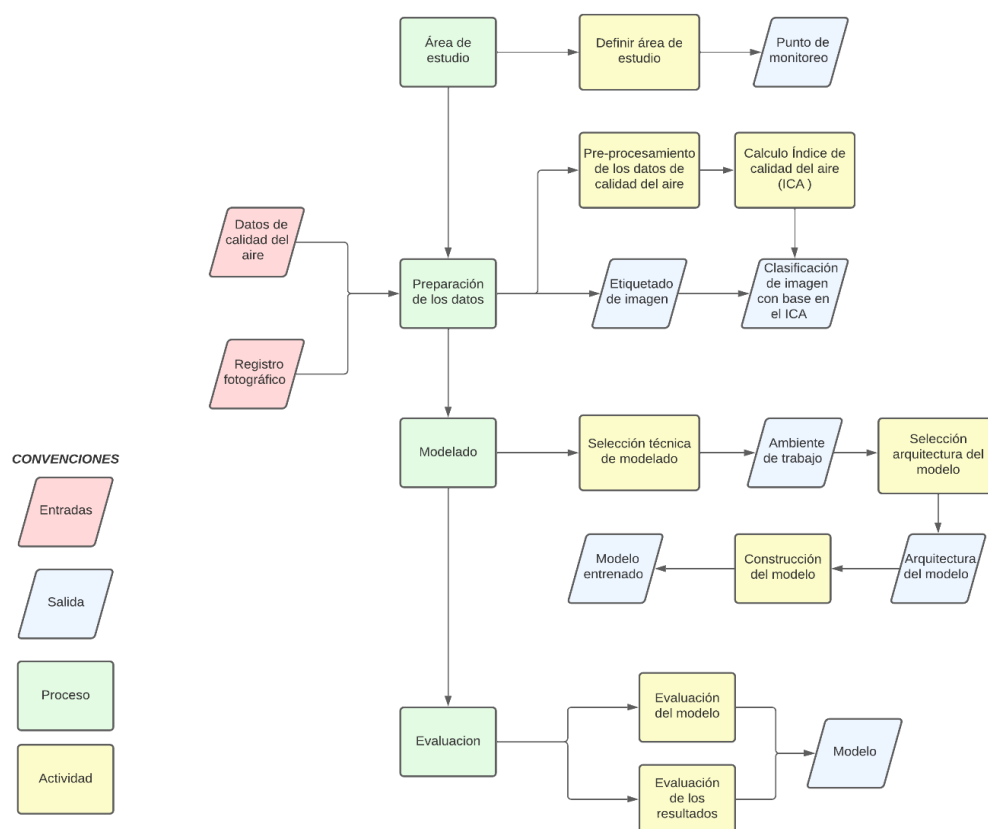


Fig. 1. Modelo sinóptico de la metodología de estudio.

2.1) Área de estudio.

2.1.1) Definir área de estudio.

La primera actividad de la investigación consistió en el establecimiento del área de estudio, esta se definió para cuatro localidades de la ciudad de Bogotá debido a la continua presencia en los episodios de variabilidad en los niveles de contaminación del aire, particularmente de ozono troposférico (O₃), adicionalmente por la presencia de la malla vial, usos del suelo y presencia de fuentes finas y móviles que componen cada una de las zonas seleccionadas.

En este orden de ideas, el área de estudio incluye cuatro localidades y sus respectivas estaciones de monitoreo de calidad del aire; Puente Aranda (Estación Puente Aranda - PTE), Fontibón (Estación Fontibón - FTB), Engativá (Estación Las Ferias- LFR), Barrios Unidos (Estación Centro de alto rendimiento - CDAR), de la ciudad de Bogotá, como se observa en la figura 2. Estas localidades fueron seleccionadas ya que presentan una variabilidad de forma periódica en las concentraciones de O₃, como se evidencia en la figura 3, en donde se observa las concentraciones anuales de O₃ para los años 2016 a 2020.

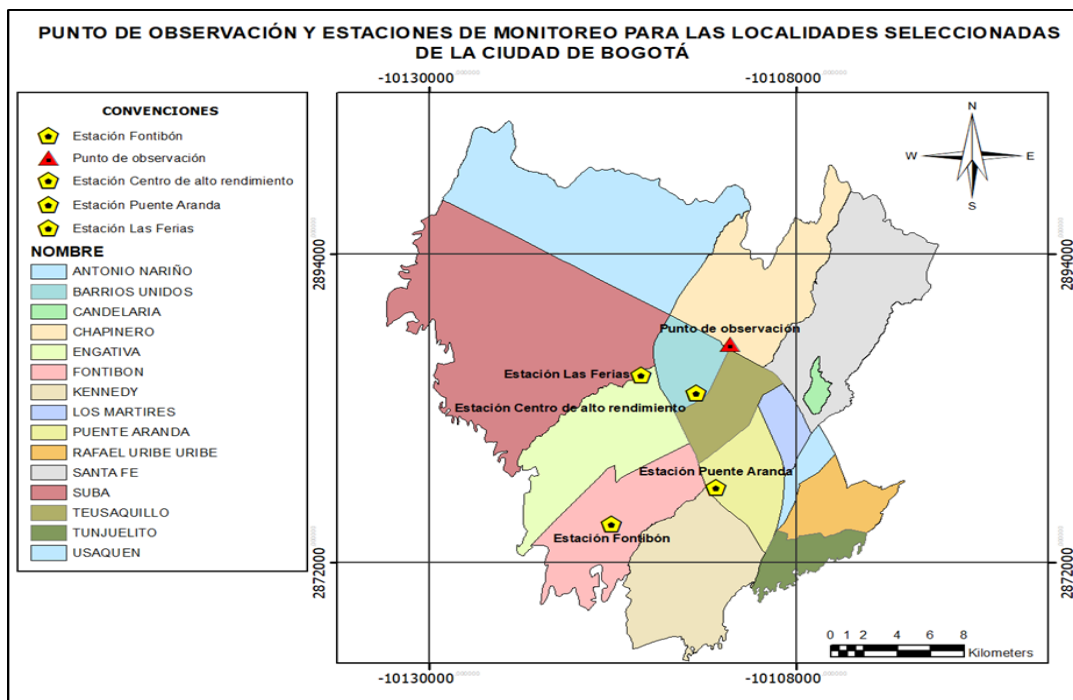


Fig. 2. Punto de observación y toma de fotografías digitales, y estaciones de la red de monitoreo de calidad del aire para las localidades seleccionadas




Fig. 3. Concentraciones anuales promedio de O₃ años 2016 a 2020. (Secretaría Distrital De Ambiente, 2020)

1 Existe una tendencia al incremento de las concentraciones del O₃ troposférico en las localidades
2 seleccionadas, presentándose los incrementos más notables en las localidades de Fontibón con 9 µg/m³ y en la
3 localidad de Barrios Unidos con 11 µg/m³ respecto a 2019 (ver Fig. 3). Adicionalmente, la localidad de Puente
4 Aranda cuenta con el récord histórico más bajo frente a las demás, donde se observó que el aumento en la
5 concentración del contaminante es de 2 µg/m³. La localidad de Engativá presentó un comportamiento estable en
6 los años de 2019 y 2020 con una concentración de 25 µg/m³ durante ese periodo.
7

8 El comportamiento de las concentraciones de O₃ ha variado en el tiempo, ya que estas son influenciadas por
9 los cambios en las variables meteorológicas de cada época del año, como también la continua variación en las
10 concentraciones de los precursores de ozono (Secretaría Distrital De Ambiente, 2020).
11

12 Por otra parte, y con base a lo anteriormente mencionado, se tomaron en cuenta diferentes criterios de
13 selección de dichas localidades, su ubicación geográfica, el uso de suelo, la presencia de malla vial, y
14 adicionalmente la presencia de fuentes móviles y fuentes fijas.
15

16 A razón de lo anterior, la localidad de Puente Aranda, fue seleccionada por su ubicación geográfica, ya que
17 se encuentra ubicada en el centro occidente de la ciudad (ver Fig. 2). Esta localidad se ha caracterizado por ser el
18 centro de la actividad industrial de la ciudad de Bogotá (Alcaldía local de Puete Aranda, 2017), presentando un
19 récord histórico de una mala calidad del aire en su territorio, debido a las altas concentraciones de contaminantes
20 criterio como el material particulado y el O₃ (ver fig. 3). Este precedente de contaminación atmosférica se debe
21 principalmente a las fuentes móviles como lo afirma (Secretaria Distrital de Ambiente, 2020), ya que Puente
22 Aranda cuenta con vías principales en las que se encuentran la Carrera 50, la Avenida carrera 68, Avenida Calle
23 13, Avenida de las Américas y la Carrera 30 mantienen un alto flujo vehicular (Alcaldía Mayor de Bogotá, 2020).
24

25 La localidad de Barrios Unidos fue seleccionada por su ubicación geográfica, ya que se encuentra ubicada en
26 el noroccidente de la ciudad y limita, al occidente, con la Avenida carrera 68, que la separa de la localidad de
27 Engativá; al sur, con la calle 63, separándose de la localidad de Teusaquillo; al norte con la calle 100, que la separa
28 de la localidad Suba y, al oriente, con la Avenida Caracas, que la separa de la localidad de Chapinero (ver Fig. 2).
29 La presencia de los corredores viales que componen esta localidad y el continuo flujo vehicular impactan
30 directamente en el deterioro de la calidad del aire de este territorio, ya que las emisiones generadas por estas
31 fuentes, aportan como contaminantes precursores de la formación del ozono troposférico (Alcaldía Local de
32 Barrios Unidos, 2017).
33

34 Por otra parte, se seleccionó la localidad de Fontibón (Estación Fontibón), debido a su ubicación geográfica,
35 ya que limita con las localidades de Engativá (al norte), Puente Aranda (al oriente), Kennedy al sur (ver Fig. 2).
36 Esta localidad representa una de las mayores transformaciones en los cambios del uso del suelo a nivel distrital,
37 debido a la predominancia de uso de suelo industrial en la composición de las unidades de planeación zonal (UPZ)
38 (Cogua Morena , 2013), siendo esto una tendencia constante clasificándose como una de las tres localidades del
39 distrito con mayores niveles de contaminación atmosférica (Alcaldía Local de Fontibón, 2012).
40

41 Partiendo de lo anterior, una de las mayores problemáticas en la calidad del aire de esta localidad se refiere
42 a las fuentes de emisión, ya que existe un total de 455 fuentes fijas de emisión de contaminantes atmosféricos
43 pertenecientes a industrias ubicadas en las siguientes UPZ: Granjas de Techo, Capellanía, Zona Franca y Fontibón.
44 Sumado a ello la problemática de las emisiones de las fuentes móviles, pues esta localidad cuenta con una malla
45 vial constituida por la Avenida Centenario, Avenida Calle 13, Avenida Ciudad de Cali, Avenida El Dorado o Calle
46 26 y Avenida La Esperanza (Alcaldía Local de Fontibón, 2012).
47

48 Finalmente, fue seleccionada la localidad de Engativá (Estación Las Ferias) no sólo considerando la
49 ubicación geográfica y zonas colindantes (ver figura 2) sino también debido a que es una de las localidades con
50 mayores índices de contaminación en la ciudad (Secretaria Distrital de Ambiente, 2019), producto de una dinámica
51 y diversificada actividad productiva e industrial con un amplio margen de expansión (Alcaldía local de Engativá,
52 2016).
53

54 2.1.2) Selección del Punto de monitoreo, punto de observación y toma de imágenes digitales.

55 El punto de observación seleccionado se encuentra ubicado en el edificio Fénix, en la Carrera 11# 64-25
56 localidad de Chapinero, piso número doce, de diez y seis pisos; se localiza a una altura de 36 metros. El punto de
57 observación presenta las siguientes coordenadas cartesianas: 4.6505936,- 74.0624409 en sistema wgs84 como se
58 evidencia en la figura 2. Este punto fue elegido debido a la visibilidad que otorgó hacia el occidente de la ciudad
59 en la cual se encuentran las cuatro localidades seleccionadas. Dicha visibilidad fue un aspecto relevante para la
60 elección del punto de toma de las imágenes digitales debido a que el ozono se caracteriza porque en lugar de
61
62

1 encontrarse en una concentración homogénea a lo largo de la atmósfera, dicha concentración presenta una fuerte
2 dependencia con la altitud (Delgado Saborit , 2005).

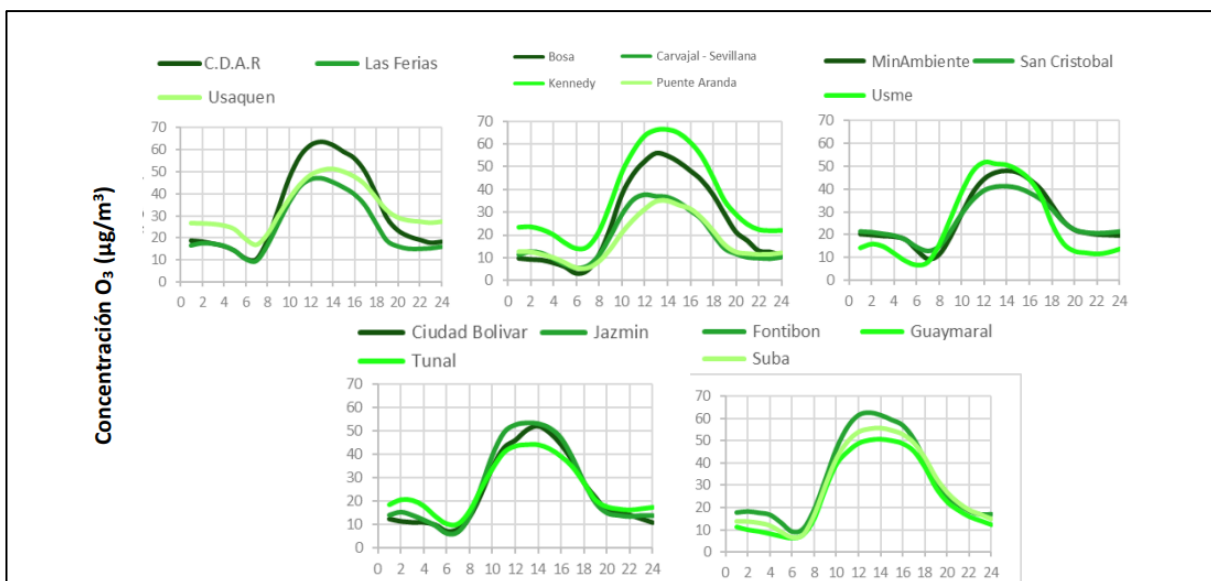
3 4 5 2.2) Preparación de los datos.

6 7 2.2.1) Datos de calidad del aire.

8
9 Esta actividad consistió en la recolección de información a partir de los registros generados por la RMCAB
10 para el periodo de tiempo horario comprendido entre marzo de 2021 a octubre del mismo año. Esta información
11 fue suministrada por la Secretaría Distrital de Ambiente de Bogotá, la cual contiene los registros mensuales, diarios
12 y horarios del comportamiento del contaminante O₃.

13
14 Se llevó a cabo la recolección de los datos para el periodo anteriormente mencionado a través de la página
15 web de la RMCAB, los datos descargados se encuentran en formato de extensión .xls, los cuales cuentan con una
16 estructura en la que se evidencia la estación de monitoreo, la fecha junto a la hora en la que se realizó la medición
17 del contaminante ozono troposférico y finalmente la concentración de este en partes por billón (ppb).

18
19 Los datos obtenidos para cada una de las estaciones de monitoreo pertenecientes a las localidades del área de
20 estudio fueron discriminados de manera horaria; esta actividad consistió en la discriminación de los datos para dos
21 horas específicas; 7:00 y 12:00, para cada uno de los días del periodo de estudio. Esto se debe a que
22 particularmente, las horas seleccionadas presentaron un récord histórico de variabilidad en la concentración de O₃
23 en cada una de las localidades seleccionadas, como se evidenció en la figura 4, la cual permitió conocer el
24 comportamiento en la concentración promedio horario del contaminante seleccionado para el año 2020. En la
25 figura 4 es posible observar que los niveles de concentración son influenciados por la variación de la radiación
26 solar durante el día, registrando los picos más altos hacia el mediodía; en la mañana las concentraciones del
27 contaminante son bajas, tras la baja radiación solar, según la (Secretaría Distrital De Ambiente, 2020).



29
30 Fig. 4. Comportamiento en la concentración promedio horaria de O₃ en la ciudad de Bogotá para el año 2020
31 (Red de monitoreo de Calidad del aire de Bogotá - RMCAB , 2020)

32 33 34 2.2.2) Registro fotográfico.

35
36 En esta etapa se realizó el registro fotográfico del área de estudio, comprendida por las cuatro localidades
37 ubicadas en el occidente de Bogotá; el método ejecutado para este registro consistió en la captura de imágenes
38 digitales mediante un dispositivo móvil durante el periodo de marzo a octubre del año 2021. Esta etapa culminó
39 con la aplicación del indicador de clasificación denominado índice de calidad del aire (ICA).

40
41 El registro de imágenes digitales se realizó con una cámara de equipo de telefonía móvil marca Xiaomi
42 referencia Redmi 9^a, el cual cuenta con cuatro cámaras: haciendo uso de la cámara trasera del dispositivo de 13
43 Megapíxeles, con una apertura de objetivo comprendida en un rango de f/1.89 a f/2.2, esta apertura hace referencia
44 a los valores máximos focales en caso de hacer un acercamiento al realizar la fotografía. Sin embargo, esta apertura

también está relacionada estrechamente con la profundidad de campo, es decir, la distancia que se encuentra por delante y por detrás del punto al cual se requiere enfocar, en consecuencia, si la apertura del objetivo es de gran tamaño la distancia es reducida, generando así un efecto de desenfoque en la fotografía, en contraste al reducir la apertura del objetivo se dispone de elementos con un alto grado de nitidez y entrada de luz al capturar la imagen.

El registro de las imágenes se realizó con una apertura de objetivo máximo de f/2.2, el cual otorgó a las fotografías el mayor grado de nitidez que puede ofrecer el dispositivo utilizado; adicionalmente se determinó que el encuadre de las fotografías se llevaría a cabo de manera horizontal, dado que el dispositivo provee una mayor distancia focal al capturar las fotografías. Cabe resaltar que las imágenes capturadas no fueron objeto de modificación, es decir, se utilizaron las imágenes sin aplicación de efectos de suavizado, nitidez, recorte de imagen, entre otros.

2.2.3) Cálculo del índice de calidad del aire (ICA).

El Índice de Calidad del Aire, adoptado en Colombia por el Ministerio de Ambiente y Desarrollo Sostenible (MADS), es un instrumento desarrollado por la Agencia de Protección Ambiental de los Estados Unidos, el cual permite evaluar los efectos a la salud y las medidas preventivas a implementar con base en la concentración de un contaminante específico (Instituto de Hidrología, Meteorología y Estudios Ambientales IDEAM, 2021).

En este orden de ideas, la calidad del aire en el área de estudio se establece mediante el denominado (ICA) o el índice de calidad del aire, el cual es un valor adimensional que oscila entre 0 y 500, como se evidencia en la tabla 1, representa el grado de contaminación del aire ambiente y los potenciales efectos perjudiciales en la salud humana. Este índice se desarrolla por medio de la aplicación de una metodología de cálculo; en Colombia esta metodología se contempla en la Resolución 2254 de 2017, junto a la descripción de cada condición de calidad del aire y sus puntos de corte pertenecientes (Red de Monitoreo de Calidad del Aire de Bogotá, 2018).

Tabla 1. Categorías índices de calidad del aire ICA (Red de Monitoreo de Calidad del Aire de Bogotá, 2018)

| Índice de Calidad del Aire | | | Puntos de corte del ICA | | | | | | |
|----------------------------|----------|---------------------------------------|---|--|------------------------------------|--|--|---|--|
| ICA | Color | Categoría | PM ₁₀ µg/m ³ 24 horas | PM _{2.5} µg/m ³ 24 horas | CO µg/m ³ 8 horas | SO ₂ µg/m ³ 1 hora | NO ₂ µg/m ³ 1 hora | O ₃ µg/m ³ 8 horas | O ₃ µg/m ³ 1 hora |
| 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 | 795 - 1185 |

Se aplicó la metodología de cálculo para los datos previamente obtenidos y discriminados, para el periodo de tiempo comprendido entre marzo y octubre del año 2021. Para ello se ingresó cada concentración del contaminante presente a las 07:00 y 12:00 horas de cada localidad seleccionada en la ecuación 1 (Red de monitoreo de Calidad del aire de Bogotá - RMCAB, 2020), donde se obtuvo la categoría de cada dato perteneciente al área de estudio y al periodo del mismo

$$ICAP = \frac{I_{Alto} - I_{Bajo}}{PC_{Alto} - PC_{Bajo}} * (C_p - PC_{Bajo}) + I_{Bajo} \quad (1)$$

Donde: $ICAP$ – Índice de calidad del aire para contaminante P
 C_p – Concentración registrada 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 para PC_{alto} ;
 I_{bajo} – Valor del ICA para PC_{bajo} ;

2.2.4) Clasificación de imágenes.

Se etiquetó cada imagen con el código de la estación junto a la fecha y hora en la que fue registrada como se evidencia a continuación; para la localidad de Engativá (Estación Las Ferias) se etiquetó con el código F-Fecha-Horas, la localidad de Puente Aranda (Estación Puente Aranda) se etiquetó con el código P- Fecha- Hora, la localidad de Fontibón (Estación Fontibón) se etiquetó con el código O- Fecha- Hora y finalmente, la localidad de Barrios Unidos (Estación centro de alto rendimiento) se etiquetó con el código C-Fecha-Hora.

Enseguida, se procedió a realizar la clasificación de las imágenes digitales con base al ICA, para ello se tomó cada dato resultante de la ecuación 1 y se contrastó frente a cada imagen etiquetada en el registro fotográfico; posteriormente se realizó la división de la información de la siguiente manera: se crearon dos carpetas de denominadas 07:00 y 12:00, en el interior de cada una de ellas se crearon las categorías pertenecientes al índice de calidad del aire (ver tabla 1), a partir de lo anterior se ingresó cada imagen a su categoría y hora correspondiente.

2.3) Modelado de la Red Neuronal Convolutiva.

2.3.1) Selección técnica de modelado.

Esta etapa consistió en el modelado, el cual se llevó a cabo a partir de la técnica de redes neuronales convolucionadas. Estas redes presentan la capacidad para reconocer atributos o características complejas de alto nivel mediante la combinación de filtros y adicionalmente los sistemas basados en estas redes son los que obtienen tasas de error considerablemente más bajas que las ofrecidas por otras técnicas de inteligencia artificial, como los sistemas difusos y los algoritmos evolutivos en donde se destacan los sistemas inmunes artificiales y la inteligencia de enjambre según se demuestra en Large Scale Visual Recognition Challenge 2015 (ILSVRC2015). Adicionalmente se hizo uso de un ambiente de trabajo establecido bajo el lenguaje de programación Python y un entorno integrado de código abierto denominado spyder.

2.3.2) Arquitectura del modelo

La arquitectura del modelo consistió en un modelo de clasificación de imágenes denominado VGG16 (ver figura 5), el cual es un modelo propuesto en el año 2014 por K. Simonyan y A.Zisserman de la Universidad de Oxford, en el cual demuestran una alta precisión en el entorno de reconocimiento de imágenes a gran escala, siendo esta una de las arquitecturas más utilizadas este tipo de procesos (Simonyan & Zisserman, 2015).




Fig. 5. Arquitectura modelo VGG16 (Nash , Drumond , & Birbilis, 2018)

Para la construcción del modelo se realizó la carga e instalación de las siguientes librerías: Os (Python Software Foundation , 2022) esta se encarga de gerenciar archivos, por otra parte, la librería numpy se utilizó para cálculos matemáticos, la librería PIL (Lundh & Clark, 2022) se utilizó para el procesamiento de imágenes, la librería matplotlib (Hunter, Dale, Firing , & Droettboom , 2022) se usó para la creación de gráficas y finalmente la librería tensorflow se empleó para construir y entrenar redes neuronales. La librería anteriormente mencionada permite detectar y descifrar patrones y correlaciones, análogos al aprendizaje y razonamiento usados por los humanos.

1 Adicionalmente, se elaboró un dataset, cuya función fue albergar la información en el ambiente de trabajo en
2 donde se hizo uso de las carpetas creadas en la etapa anterior, denominadas 07:00 y 12:00 horas, seguido a ello se
3 listaron las categorías pertenecientes al dataset. En función de lo anterior se llevó a cabo la estandarización de las
4 imágenes listadas en las categorías, este proceso es necesario debido a que un modelo no reconoce imágenes en
5 diferentes tamaños, por lo cual se redefinió el ancho y el alto de las imágenes a 224 x224 píxeles. Posteriormente
6 se creó una matriz donde se guardó cada una de las imágenes redimensionadas, adicionalmente se empleó un
7 archivo cuya función consistió en guardar de manera local todas las imágenes en donde se especificó que las
8 mismas presentaran un espectro visible de tres bandas denominado (RGB). Seguido a esto se ejecutó un vector
9 que redimensiona la imagen por el método bicubic, se llevó a cabo este método ya que hace uso de interpolaciones
10 que mejoran la calidad de la imagen cuando se redimensiona.

11
12 En este orden de ideas, se cargó en el ambiente de trabajo la arquitectura del modelo denominado VGG16,
13 el cual está constituido por 13 capas convolucionales (ver Fig. 5), la función de cada una de estas capas consiste
14 en la extracción de los píxeles que componen cada imagen, para posteriormente convertirlo en una combinación
15 lineal. Las capas denominadas maxpooling, permiten analizar el contenido de una imagen por sectores, lo que
16 permite extraer la información más representativa, esto proporciona la reducción en la cantidad de datos que
17 transitan cada una de las capas, facilitando así el procesamiento de las imágenes (Nadi , Ducatelle, Di Caro , &
18 Ciresan , 2011). A estas le siguen 3 capas totalmente conectadas y finalmente un clasificador softmax esta capa se
19 usa en modelos de categorías múltiples donde genera como resultado las probabilidades de cada clase, en donde
20 la clase objetivo tiene la probabilidad más alta.

21
22 La función Softmax aparece principalmente en casi todas las capas de salida de las arquitecturas de
23 aprendizaje automático donde se utilizan (Nwankpa, Ijomah , & Gachagan, 2020). La utilización de esta
24 arquitectura se caracteriza por emplear varios parámetros para entrenar, lo que puede hacer que su entrenamiento
25 dure más que el resto de las redes (Nash , Drumond , & Birbilis, 2018). Para finalizar la arquitectura del modelo
26 se hizo uso de un optimizador de la librería keras denominado Adam (Nain, Paul, & Maynard-Reid, 2022), este es
27 un algoritmo de optimización que se puede utilizar en lugar del procedimiento de descenso de gradiente estocástico
28 clásico para actualizar los pesos de red de forma iterativa en función de los datos de entrenamiento (Kingma &
29 Lei Ba, 2017).

30 31 *2.3.4) Entrenamiento y validación del modelo.*

32
33 En esta etapa se hizo uso de la librería scikit-learn (Scikit-learn developers, 2022), cuya función consistió en
34 dividir el conjunto de datos pertenecientes al dataset, en un 70% para entrenar y 30% para validar; a razón de lo
35 anterior se generó una matriz de vectores, que se transformó por medio de la función one hot encoder, la cual
36 permitió al modelo interpretar los datos de entrenamiento y validación (Scikit-learn developers, 2022).

37
38 El entrenamiento y validación del modelo se desarrolló con 50 épocas, siendo estas iteraciones u operaciones
39 matemáticas que se llevan a cabo haciendo uso de los parámetros entrenables. Concretamente este número de
40 épocas se seleccionó a partir de las afirmaciones de Afaq & Rao (2020), donde establecen que estos procesos
41 deben ser detenidos cuando se presente una súbita elevación en el porcentaje de error o denominada categorical
42 cross entropy, a esto se le denomina parada temprana.

43
44 Se estableció que el tamaño de lote utilizado en cada época es de 64 muestras, esto se refiere al total de
45 muestras que se propagaran a través de la red en cada una de las épocas. Este número dependió directamente de
46 la capacidad de CPU Y GPU pertenecientes al dispositivo computacional.

47
48 Lo anteriormente mencionado se realizó mediante el uso de un computador portátil ASUS TUF Gaming, con
49 un procesador AMD Ryzen 5 3550H with Radeon Vega Mobile Gfx, 2100 MHz, 4 procesadores principales, 8
50 procesadores lógicos, 8GB de RAM, 500 GB de almacenamiento y equipado con una tarjeta gráfica AMD R560X.

51 52 53 *2.4) Evaluación del modelo.*

54 55 *2.4.1) Métricas de evaluación del modelo.*

56
57 En función de lo obtenido en la etapa anterior se llevó a cabo la actividad de evaluación del modelo. Para la
58 primera actividad se construyó una matriz de confusión, la cual es una tabla que describe el rendimiento de los
59 modelos de aprendizaje automático, esta se utiliza para estimar la precisión y la exactitud del modelo, esta presenta
60 un resumen de los aciertos y desaciertos generados por la red neuronal convolucional en la clasificación, mediante
61
62
63

la contabilización de cuatro variables: verdaderos positivos (TP) , verdaderos negativos (TN), falsos negativos (FN) y falsos positivos (FP) (Huerta Mora , Gonzales Huitron , & Rodriguez Mata , 2020). Los resultados de la aplicación del modelo se evaluaron a partir del cálculo de las métricas que se evidencian en las ecuaciones 2, 3 y 4.

La métrica denominada accuracy, es la más simple y más utilizada para medir el rendimiento de un clasificador (Juba & LE, 2017), la cual se define como el porcentaje de clasificaciones correctas, esta métrica se calculó con base en la ecuación 2 (Nawaz, Ramiah Pilai, Kaur , & Sukumaran , 2019)

$$Accuracy = (TP + TN)/(TP + TN + FP + FN + TN) \quad (2)$$

Donde:

TP–Verdadero positivo;
TN –Verdadero negativo;
FP –Falso positivo;
FN– Falso negativo;
TN– Verdadero negativo

Por otra parte, se evaluó la métrica denominada recall o exhaustividad, que corresponde con la proporción de casos reales positivos que son correctamente predichos. Esta métrica mide la cobertura de los casos reales positivos, y su identificación se logró con la aplicación de la ecuación 3 (Ward Powers, 2011). Su característica principal es que refleja cuántas imágenes clasifica correctamente el modelo para cada una de las categorías establecidas en el índice de calidad del aire.

$$Recall = TP/(TP + FN) \quad (3)$$

Donde:

TP–Verdadero positivo;
FN– Falso negativo;

Finalmente, se evaluó la métrica F1 que tiene en cuenta tanto la precisión como la exhaustividad o recall para evaluar la funcionalidad de un algoritmo. Esta es una métrica es utilizada cuando el conjunto de datos a analizar está desbalanceado en sus categorías, por lo cual combina la precisión y la exhaustividad, para obtener un valor más objetivo (Bekkar, Kheliouane Djemaa, & Alitouche, 2013), lo anterior se calculó a partir de la ecuación 4 (Vakili, Ghamsari, & Rezaei, 2020).

$$F1 = (2 \times Precision \times Recall)/(Precision + Recall) \quad (4)$$

Donde:

Recall–Exhaustividad;
Precisión– Precisión;

3 Resultados y Discusión

A partir de la aplicación de las etapas y actividades descritas en la sección de materiales y métodos, se generaron resultados que permitieron identificar el comportamiento del modelo desarrollado frente a la clasificación de imágenes por medio de la aplicación del indicador de calidad del aire ICA. La realización de dichas actividades encausadas al desarrollo del procedimiento planteado fueron el pilar fundamental de esta investigación. Los resultados de estas actividades fueron herramientas de decisión y componentes de entrada para la implementación de las etapas posteriores.

1
2 3.1) *Resultados del registro fotográfico en el área de estudio.*
3

4 Esta actividad llevada a cabo en el área de estudio y desarrollada en el periodo comprendido entre el mes de
5 marzo y octubre del año 2021, ejecutado de forma diaria a las 07:00 y 12:00 horas, dio como resultado la obtención
6 de 366 imágenes digitales registradas en el dispositivo móvil para ello utilizado. La composición de este conjunto
7 de imágenes presentó la siguiente distribución; las localidades de Barrios Unidos y Engativá contaron con 92
8 imágenes, por otra parte, Puente Aranda y Fontibón constaron de 91 imágenes cada una. Esto se debió
9 principalmente a la discriminación de dos imágenes perteneciente a estas dos últimas localidades, ya que
10 presentaron un notable desenfoque al ser capturadas.

11
12 Las imágenes capturadas en el registro fotográfico presentaron una continua similitud en sus características
13 de composición, ya que se evidencia una constante presencia de variables climatológicas, como la nubosidad y la
14 precipitación; sin embargo, se evidenció particularmente a las 07:00 horas del día 11 de junio de 2021, la presencia
15 de smog fotoquímico en la localidad de Engativá, como se puede constatar en la imagen de la figura 6.
16
17



18
19
20
21 *Fig. 6. Presencia de smog el 11 de junio de 2021 en la localidad de Engativá.*
22
23
24

25 3.2) *Análisis y resultados pertenecientes al cálculo del índice de calidad del aire ICA.*
26
27

28 Esta actividad permitió la clasificación del conjunto de imágenes perteneciente al registro fotográfico, esta
29 arrojó la presencia de tres categorías de calidad del aire; Buena (50,68%), Aceptable (35,14%) y Dañina a la salud
30 de grupos sensibles (14,16%), frente a las seis existentes en este índice como se observa en la tabla 1.
31

32 La distribución de estas categorías se representa en la figura 7 y 8, en la cual se denota una predominancia
33 en la categoría de calidad del aire denominada buena, seguido de una distribución similar en las categorías
34 aceptable y dañina a la salud de grupos sensibles en el conjunto de imágenes perteneciente a las obtenidas a las
35 07:00 horas. Por otra parte, se identificó que la distribución perteneciente a las imágenes obtenidas a las 12:00
36 horas presentó una leve predominancia de la categoría de calidad del aire denominada como aceptable, seguido de
37 la categoría buena y dañina a la salud de grupos sensibles.
38
39




Fig. 7. Distribución del conjunto de imágenes capturados a las 07:00 con base al Índice de Calidad del Aire.

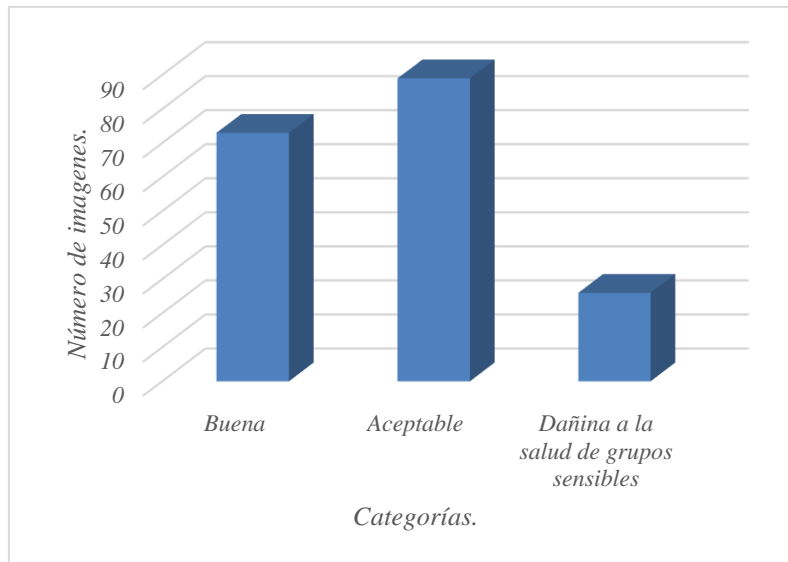


Fig. 8. Distribución del conjunto de imágenes capturados a las 12:00 con base al Índice de Calidad del Aire.

Las mayores concentraciones del contaminante se presentaron a las 12:00 horas, siendo la categoría de calidad del aire denominada aceptable la que presentó una leve predominancia sobre las demás. La generación de este contaminante es asociada a la presencia de radiación solar (Centro de Investigaciones, Energéticas Medioambientales y Tecnológicas CIEMAT, 2009). A partir de esto, Isra, Hashmi, Rahman, Ahmad, & Ali (2015) afirmaron que los precursores del ozono troposférico se comienzan a acumular a primeras horas del mañana, evidenciando que el punto máximo de concentración de este no se alcanza hasta las primeras horas de la tarde, esto se reflejó en el comportamiento en la concentración del contaminante en las figuras 7 y 8.

El comportamiento del ozono troposférico (ver figura 4) se presentó debido a que la presencia de los contaminantes precursores (NO_x e hidrocarburos), estos emitidos por fuentes móviles en conjunto de las fuentes fijas pertenecientes a las actividades antrópicas en el área de estudio. Esta afirmación se basa en los procesos fotoquímicos en los que intervienen los contaminantes mencionados ya que estos son productos comunes de las actividades antropogénicas, en las áreas urbanas y bajo condiciones meteorológicas estables, a partir de esto, estos gases se acumulan en las capas atmosféricas de la zona de influencia de estudio, donde se llevan a cabo transformaciones fotoquímicas, las cuales generan como producto el ozono troposférico (Delgado Saborit, 2005). Ver ecuaciones 5 a 7 (Instituto de Hidrología, Meteorología y Estudios Ambientales - IDEAM, 2019),



8 Donde:

9 NO – Monóxido de nitrógeno

10 NO₂ – Dióxido de nitrógeno

11 hv – Energía de cada fotón

12 O – Oxígeno

13 O₂ – Oxígeno

14 O₃ – Ozono

15 M – Catalizador

16

17

18 Por otra parte, la notable presencia en la composición de la categoría de calidad del aire denominada como

19 buena se debió al contexto en el cual se desarrolló la investigación; en el periodo comprendido de marzo a octubre

20 del año 2021, se mantuvo la contingencia mundial debido a la pandemia generada por el Covid – 19, lo que impactó

21 directamente en las dinámicas sociales, económicas y ambientales en la zona de influencia del área de estudio.

22

23 Esta afirmación se sustentó con base al decreto 007 de 2021 en el cual ordena la suspensión de

24 aglomeraciones, actividades económicas, sociales, cívicas, religiosas o políticas, sean estas públicas o privadas,

25 esto designado para la localidad de Engativá (Alcaldía Mayor de Bogotá, 2022). Adicionalmente en la localidad

26 de Puente Aranda bajo el decreto 191 de 2020, se ordenó medidas restrictivas de la movilidad de medios de

27 transporte o personas, incluidas las de tránsito por predios privados. Por otra parte, bajo el decreto 144 de 2021, la

28 Alcaldía Mayor de Bogotá, ordenó dos cuarentenas, la primera del 16 al 19 y otra del día 22 al 26 de abril del

29 mismo año en toda la ciudad, en donde se restringió la circulación de personas y vehículos por vías y lugares

30 públicos de la misma (Alcaldía Mayor de Bogotá, 2021).

31

32 No obstante, la calidad del aire que presentó la ciudad de Bogotá durante el periodo en el que se desarrolló

33 la investigación se debe en gran parte a la aplicación de fuerzas motrices, las cuales son las encargadas de ejercer

34 presiones o influencias sobre el estado del medio ambiente (Sistema Nacional Ambiental – SINA, 2015). Estas

35 fuerzas están compuestas por determinantes sociales estructurales, referidos a factores económicos, sociales y

36 políticas de nivel superior. Se destaca la Resolución 2254 de 2017 Ministerio del Medio Ambiente en su artículo

37 15, el cual establece que; las zonas en donde se excedan las normas de calidad del aire, la autoridad ambiental

38 competente, deberá elaborar un programa de reducción de la contaminación, identificando acciones y medidas que

39 permitan reducir los niveles de concentración de los contaminantes a niveles por debajo de los máximos

40 establecidos.

41

42 Dicho esto, la Secretaria Distrital de Ambiente llevo a cabo el Plan Decenal de Descontaminación del Aire

43 para Bogotá, el cual tuvo como objetivo central que la ciudad debía haber alcanzado una reducción de un 60% de

44 las emisiones de material particulado y mantuviera el nivel de los demás contaminantes criterio: dióxido de azufre

45 (SO₂), dióxido de nitrógeno (NO₂), monóxido de carbono (CO) y ozono (O₃) (Veeduría Distrital , 2021),

46

47 Para lograr lo dispuesto en este plan de descontaminación se efectuaron medidas en dos sectores

48 concretamente; en el industrial se llevaron a cabo medidas de conversión de carbón a gas natural y formalización

49 de industrias, como también, instalación de sistemas de control de emisiones seleccionando las industrias con un

50 único criterio de costo-efectividad. En el sector del transporte se implementaron, sistemas de control de emisiones

51 en motocicletas como también en vehículos de carga y vehículos pertenecientes al parque automotor del sistema

52 integrado de transporte de Bogotá (Secretaría Distrital De Ambiente, 2020).

53

54 Cabe resaltar otra medida empleada por la Alcaldía Mayor de Bogotá fue la implementación de buses

55 totalmente eléctricos pertenecientes al parque automotor del sistema integrado de transporte de Bogotá (SITP)

56 desde enero de 2021 en la localidad de Fontibón, contribuyendo en la mejora de la calidad del aire de la ciudad,

57 esto debido al ser vehículos de cero emisiones (Alcaldía Mayor de Bogotá, 2021).

58

59 Adicionalmente la Secretaria Distrital de Ambiente ejecuta acciones de control y vigilancia en las emisiones

60 generadas por las fuentes fijas pertenecientes a la zona de influencia del estudio. Estas acciones concretamente

61 están comprendidas por visitas de verificación, en donde los funcionarios de la autoridad ambiental toman muestras

62 e inspeccionan las obras o sistemas de control de emisiones atmosféricas para cada una de estas. Lo anterior

63 estipulado en el artículo 2.2.5.1.10.8. perteneciente al Decreto 1076 de 2015.

1 Para las fuentes móviles, la autoridad ambiental, estableció una restricción de circulación de vehículos de
2 transporte de carga con un peso superior a ocho mil quinientos kilogramos, esto en periodos de tiempo
3 comprendidos de lunes a viernes, para el rango horario entre las 06:00 y 08:00 horas, como también entre las
4 17:00 y las 20:00 horas, en la siguientes corredores viales; Avenida de las Américas, Avenida Boyacá, Avenida
5 Primero de Mayo, Avenida Carrera 68, Autopista Sur, Avenida Boyacá, Avenida Villavicencio y Avenida
6 Caracas. Esto expedido en el Decreto 077 de 2020, por la Alcaldía Mayor de Bogotá.
7

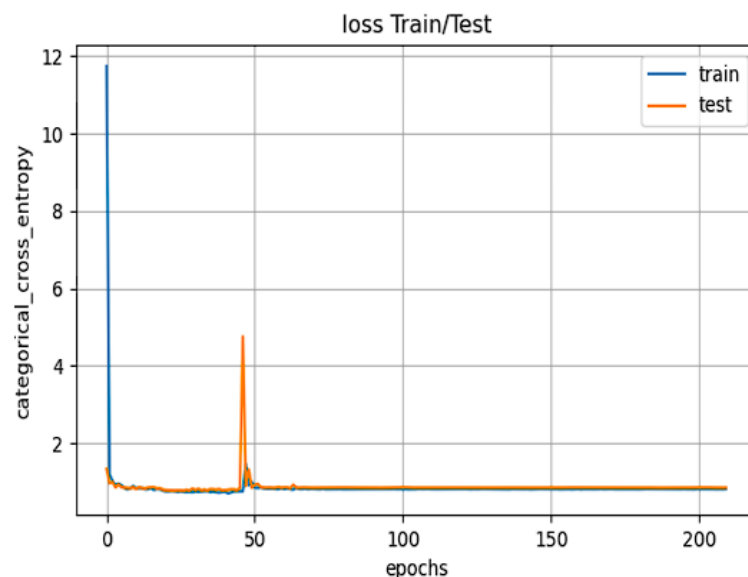
8 El conjunto de acciones desarrolladas por los diferentes actores mencionados en el marco de la investigación
9 causó un impacto directo en el estado y condiciones de la calidad del aire en el área de estudio, esto quiere decir
10 que se presentó una presión en la manifestación concreta de las fuerzas motrices lo que conllevó a una modificación
11 en el capital natural a través del cambio en las dinámicas antrópicas en el contexto de la investigación.
12

14 3.4) Resultados del modelado de las redes neuronales convolucionales.

15 Se ejecutó la arquitectura VGG16, obteniendo un total de 27'824,421 parámetros entrenables, estos
16 parámetros son las características de cada una de las imágenes ingresadas. Cabe resaltar que la arquitectura, no
17 arrojó como resultado ningún parámetro no entrenable, es decir, ninguna de las características extraídas fue
18 descartada.
19

21 3.5) Análisis y resultados del entrenamiento y validación del modelo de neuronales convolucionales.

22 La figura 8 refleja que el porcentaje de error durante el entrenamiento y validación del modelo es decreciente,
23 en un rango entre 0 y 2, en donde Cano Ramírez & Cruz Roa (2018) afirman que cuanto menor sea dicho porcentaje
24 de error, mejor será el rendimiento del modelo. Sin embargo, se evidencia una subida prominente de dicho error
25 sobre la época número 50, esto significó que el modelo está correctamente entrenado y conforme a afirmaciones
26 del estudio desarrollado por Afaq & Rao (2020).
27
28
29



30
31
32 Fig. 9. Resultados de la pérdida del modelo en la fase de entrenamiento y validación con el conjunto de datos
33 de entrenamiento (línea azul) y validación (línea naranja) durante cada época de entrenamiento.
34

35 Adicionalmente los resultados obtenidos en la figura 10, reflejaron que la fase de entrenamiento demostró un
36 incremento importante en la precisión al transcurrir cada una de las épocas planteadas; sin embargo, en la fase de
37 validación el modelo evidenció un comportamiento constante, pero a pesar de ello su accuracy fue menor a la fase
38 anterior. Este tipo de comportamiento en donde se presenta una diferencia de precisión en ambas fases indica un
39 leve sobreajuste en el modelo, este se produce cuando un sistema de aprendizaje automático se entrena demasiado
40 o con datos anómalos. Esta afirmación es soportada Afaq & Rao (2020), ya que establecieron en su investigación
41 que este suceso se presenta cuando un modelo recibe tanto los datos de entrenamiento, como también, datos
42 irrelevantes en su fase de validación, por lo cual afecta negativamente el rendimiento y precisión del mismo.
43

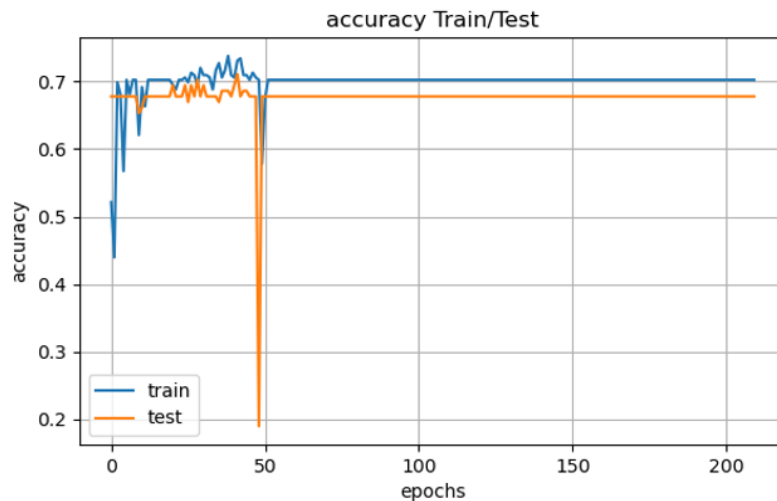


Fig. 10. Resultados de la precisión del modelo en la fase de entrenamiento y validación con el conjunto de datos de entrenamiento (línea azul) y validación (línea naranja) durante cada época de entrenamiento

3.6) Resultados métricas de evaluación del modelo.

Respecto a esta actividad, se construyó una matriz de confusiones (ver figura 11), en esta se observó el desempeño del modelo de forma detallada, esta se compuso por tres filas y tres columnas, en donde las filas indicaron la categoría a la que realmente pertenecías las imágenes, mientras que las columnas correspondieron a la predicción realizada por el modelo. Dicho esto, la diagonal principal que la comprende, establece el porcentaje de verdaderos positivos (TP) o valores estimados de forma correcta por el modelo. A partir de lo anterior, las categorías de calidad del aire denominadas como buena y aceptable, presentaron un 47% y 50% respectivamente de verdaderos positivos, sin embargo, la categoría con mayor porcentaje de valores estimados de forma correcta fue la dañina para la salud de grupos sensibles con un 70%.




Figura 11. Matriz de confusiones.

El modelo presentó verdaderos negativos (TN) en las tres categorías, es decir, son todas aquellas imágenes que son clasificadas como no pertenecientes a una categoría y que realmente no pertenecen a dicha categoría. El modelo predijo en un 100% que las imágenes clasificadas en las categoría aceptable no pertenecían ni a dañina para la salud de grupos sensibles ni a la categoría buena. Como también predijo en un 86% que las imágenes clasificadas en la categoría de calidad del aire denominada como buena, no pertenecen ni a la categoría aceptable ni a dañina a la salud de grupos sensibles.

Las categorías de calidad del aire establecidas como buena y aceptable presentaron cada una un 50% de falsos positivos (FP), en contraste la categoría dañina para la salud solamente presentó un 30%, esto quiere decir que el modelo clasificó incorrectamente imágenes de otra categoría como pertenecientes a estas. La presencia de falsos positivos se debe a la similitud en los parámetros entrenables o características extraídas en los píxeles de cada una

de las imágenes que componen el conjunto de datos utilizado. Esta afirmación se basa en la presencia de nubosidad, siendo esta una variable climatológica común en cada una de las imágenes clasificadas por el modelo como se evidencia en la figura 12. Adicionalmente la afirmación anterior fue corroborada por Abdul-Wahab & Al-Alawi (2002), en donde establecieron que la dependencia de las concentraciones de ozono y las variables climatológicas como la nubosidad presente en la zona de estudio impactan directamente en las predicciones desarrolladas en los modelos propuestos por los autores.



Figura 12. Clasificación de imágenes llevadas a cabo por el modelo propuesto.

Adicionalmente se presentaron falsos negativos (FP), estos corresponden al porcentaje de imágenes predichas por el modelo como no pertenecientes a una categoría cuando si lo eran, esto se identificó de la siguiente manera; El 14% de las imágenes fueron clasificadas como no pertenecientes a la categoría de calidad del aire denominada como buena, cuando si pertenecían a ella. Por otra parte el modelo clasificó el 49% de las imágenes como no correspondientes a la categoría aceptable cuando dichas imágenes si componían esta categoría. No obstante el porcentaje más alto que presenta el modelo de falsos negativos fue la categoría dañina a la salud de grupos sensibles ya que presentó un 70%. Finalmente, se ejecutaron las ecuaciones 2, 3 y 4, pertenecientes a las métricas de accuracy, recall y F1 respectivamente, para cada una de las categorías identificadas por el modelo propuesto reflejados en la tabla 2.

Tabla 2. Resultados métricos de evaluación.

| <i>Categoría</i> | <i>Accuracy</i> | <i>Recall</i> | <i>F1</i> |
|--|-----------------|---------------|------------|
| <i>Buena</i> | <i>70%</i> | <i>95%</i> | <i>81%</i> |
| <i>Aceptable</i> | <i>50%</i> | <i>4%</i> | <i>7%</i> |
| <i>Dañina a la salud de grupos sensibles</i> | <i>46%</i> | <i>30%</i> | <i>36%</i> |

La métrica denominada accuracy se define como el porcentaje de clasificaciones correctas realizadas (Zhou, Liu, Tang, & Wen, 2014), a partir de esto se establece que el modelo clasificó 70 imágenes de 100 de forma correcta para la categoría buena, 50 imágenes para la categoría aceptable y finalmente 46 imágenes para la categoría dañina para la salud de grupos sensibles, estos resultados para esta métrica se deben al leve sobreajuste que presentó el modelo en su fase de entrenamiento y validación, se entrenó demasiado o con datos anómalos como lo afirma Afaq & Rao (2020), este suceso afectó directamente en la precisión del modelo en el momento de clasificar las imágenes.

1 Adicionalmente la métrica recall o exhaustividad, es la proporción de casos reales positivos que son
2 correctamente predichos (Ward Powers, 2011), dicho esto el modelo propuesto clasifico 95 de 100 imágenes como
3 casos reales para la categoría buena, siendo un resultado muy favorable para la investigación; sin embargo este
4 resultado se debe principalmente a que la mayor cantidad de imágenes obtenidas y clasificadas en el registro
5 fotográfico pertenecían a esta categoría. No obstante, aunque la categoría denominada como aceptable contenía
6 un alto número de imágenes su exhaustividad fue tan solo de 4 de 100 clasificadas como casos reales, esto se debió
7 principalmente a que las imágenes presentan características climatológicas y atmosféricas similares a la categoría
8 denominada como buena, llevando al modelo a clasificarlas incorrectamente. La categoría dañina a la salud de
9 grupos sensibles, el modelo clasifico como casos reales solamente 36 de cada 100 imágenes, este resultado es
10 obtenido debido principalmente al bajo número de imágenes que componían su categoría durante el registro
11 fotográfico.

12
13 Finalmente, la métrica denominada F1, la cual se encargó de calcular el rendimiento del modelo para cada
14 una de las categorías reflejo lo siguiente, para la categoría buena se obtuvo un 81% siendo esto un resultado
15 positivo para evaluar el rendimiento del modelo, sin embargo las categorías aceptable y dañina para la salud
16 evidenciaron un 7% y un 36% respectivamente esto se debió principalmente a dos factores como lo afirma (Jin,
17 Xiao, Zhang, & Li, 2022), primeramente se produce debido a la gran dependencia de los modelos de aprendizaje
18 automático por el volumen de datos, ya que aunque se obtuvo más de tres centenas de imágenes en el registro
19 fotográfico, ligado a ello es consecuente el segundo factor el cual consiste en el desbalance en la composición
20 numérica de cada una de las categorías pertenecientes a la investigación.

21
22 La literatura existente ha encontrado una fuerte relación entre el número de imágenes que componen el
23 conjunto de datos y la métrica denominada accuracy en la utilización de redes neuronales convolucionales como
24 lo afirman Chakma, Vizena , Cao , & Lin (2017), esto se demostró a partir de los resultados obtenidos en su
25 investigación, ya que hicieron uso de 2364 imágenes pertenecientes a tres categorías de calidad del aire (buena,
26 moderada y Severa) alcanzando un accuracy 68.74%, estos fueron contrastados con el estudio desarrollado por
27 (Karayev , Trentacoste , Han , Argawala, & Darrell, 2013), el cual hizo uso de 10000 imágenes pertenecientes a
28 dos categorías (soleado y nublado) y obteniendo como resultado un accuracy de 91.1% en el desarrollo de su
29 algoritmo. Sin embargo Kow, Chang , & Chang (2020) formularon un estudio de caso en la ciudad de Kaohsiung,
30 Taiwan, en donde integraron una red neuronal convolucional y una red neuronal completamente conectada para
31 clasificar las concentraciones de PM_{2.5} y PM₁₀, haciendo uso de de 3549 conjuntos de datos divididos en las
32 categorías que componen el índice de calidad del aire (ICA), aplicaron la tecnica de clasificacion de regresion de
33 imágenes para el desarrollo de su algoritmo, a partir de esto los autores concluyeron que esta tecnica puede
34 proporcionar un enfoque practico y confiable en el avance de la clasificación de imágenes para varios
35 contaminantes utilizando solo un único modelo.

36
37 Cabe resaltar que en futuras investigaciones se pueden alcanzar mejores resultados en las métricas de
38 evaluación para conjuntos de datos desbalanceados, esto llevando a cabo diferentes estrategias, la primera de ellas
39 es el preprocesado de la muestra de imágenes previamente, para ello se puede ejecutar la técnica denominada sobre
40 muestreo (Abella Mivaret , 2021) Este consiste en replicar datos de la categoría minoritaria reduciendo así el
41 desbalanceo para ello se ejecuta un método denominado SMOTE el cual selecciona un elemento de la categoría
42 minoritaria y de entre sus vecinos más cercanos selecciona uno y crea un nuevo dato entre ambos, es decir, se crea
43 un ejemplo sintético en un punto seleccionado al azar entre los dos ejemplos en el espacio de características
44 (Brownlee, 2022). Adicionalmente otra estrategia que se puede realizar es el refinamiento de algoritmos, este
45 tiene en cuenta los costes de los distintos errores que se pueden cometer en una clasificación durante la
46 construcción del modelo, es decir, este se centra en minimizar el coste en vez de la tasa de error del clasificador,
47 por lo que presta más atención a la clase minoritaria que suele ser la prioritaria (Peng, Zhang, Yang , & Chen ,
48 2014).

4 Conclusiones

49
50
51
52
53 A partir del objetivo establecido para esta investigación, se destaca que bajo la aplicación de las redes
54 neuronales convolucionales en el marco del aprendizaje automático, fue posible construir un modelo clasificatorio
55 de imágenes digitales en función del índice de calidad del aire (ICA) para el contaminante (O₃). Puede concluirse
56 además que la calidad del aire se ve directamente influenciada por factores como las fuentes móviles y fijas, usos
57 de suelo, el comportamiento de variables climatológicas como lo afirma la literatura.

58
59 Se infiere que la clasificación de imágenes obtenidas en el registro fotográfico presentó un comportamiento
60 concordante al récord histórico del ozono troposférico en el área de estudio. Adicionalmente se estableció que
61 tanto la técnica y la arquitectura de modelado denominada VGG16 cumplen con las exigencias de clasificación de
62 imágenes digitales, a partir de las categorías propuestas en los métodos.

1 En función de lo anterior se concluye que el rendimiento del modelo es válido contrastado a lo identificado
2 en la literatura, ya que el porcentaje de precisión en el número de imágenes clasificadas correctamente en dos de
3 las tres categorías es relativamente alto; sin embargo, se establece, que se puede mejorar dicho rendimiento
4 aplicando estrategias sobre muestreo y refinamiento de algoritmos, esto con el fin de robustecer el conjunto de
5 datos y obtener mejores métricas de rendimiento en investigaciones futuras. Por su parte la literatura indica que
6 las métricas de rendimiento se deben evaluar de forma asociada, esto se debe a que distintos autores afirman que
7 al presentarse conjuntos de datos desbalanceados la presencia de un accuracy alto en conjunto con un recall bajo
8 otorga confiabilidad en el modelo propuesto.
9

10 Con la continua innovación de las tecnologías de aprendizaje automático, la aplicación de modelos de
11 aprendizaje de máquina e imágenes digitales para el pronóstico de la calidad del aire, pueden prosperar en el campo
12 de la ingeniería ambiental, ya que otorgara una variedad de enfoques al poderse articular a los diferentes
13 instrumentos con el fin de proporcionar un mayor entendimiento en las dinámicas referentes a la identificación y
14 análisis del comportamiento de la calidad del aire.
15

16 De esta manera, esta investigación tiene un impacto significativo ya que en el estado del arte referente al
17 contaminante seleccionado y la técnica desarrollada no se ha abordado específicamente para la ciudad de Bogotá,
18 con base a esto, queda en evidencia que el modelo propuesto puede ser utilizado como herramienta en el
19 seguimiento y monitoreo de la calidad del aire, ya que se pueden encaminar acciones en pro del registro de la
20 información en diferentes espacios del territorio para robustecer este tipo de redes, llevando a cabo técnicas
21 aprendizaje automático, esto con el fin de apoyar el diseño de estrategias, planes, programas y proyectos, a
22 diferentes escalas, con el objetivo de impactar de forma positiva la salud de la población y el estado del medio
23 ambiente
24
25

26 5 Referencias

- 27
28 Abdul-Wahab, S., & Al-Alawi, S. (2002). Assessment and prediction of tropospheric ozone concentration levels
29 using artificial neural networks. *Environmental Modelling & Software*, 17, 219-228.
- 30 Abella Mivaret, B. (2021). Mejora de las predicciones en muestras desbalanceadas. Madrid: UAM.
- 31 Afaq, S., & Rao, S. (2020). Significance Of Epochs On Training A Neural Network. *International journal of*
32 *scientific & technology research*, 485-488.
- 33 Alcaldía Local de Barrios Unidos. (2017). Plan Ambiental Local 2017- 020. Bogotá.
- 34 Alcaldía local de Engativá. (2016). Diagnostico ambiental de la localidad de Engativá. Bogotá: Alcaldía Mayor
35 de Bogotá.
- 36 Alcaldía Local de Fontibón. (2012). Plan ambiental local de Fontibón. Bogotá: Alcaldía Mayor de Bogotá.
- 37 Alcaldía local de Puente Aranda. (2017). Plan ambiental local Puente Aranda 2017-2020. Bogotá: Alcaldía Mayor
38 de Bogotá.
- 39 Alcaldía Mayor de Bogotá. (2020). Diagnostico local puente aranda. Bogotá: Alcaldía Mayor de Bogotá.
- 40 Alcaldía Mayor de Bogotá. (25 de 2 de 2021). Bogotá Mi Ciudad. Obtenido de [https://bogota.gov.co/mi-](https://bogota.gov.co/mi-ciudad/movilidad/sitp/buses-electricos-del-sitp-0)
41 [ciudad/movilidad/sitp/buses-electricos-del-sitp-0](https://bogota.gov.co/mi-ciudad/movilidad/sitp/buses-electricos-del-sitp-0)
- 42 Alcaldía Mayor de Bogotá. (2021). Por medio del cual se adoptan medidas adicionales para mitigar el riesgo de
43 contagio por Sars-Cov2 COVID-19 en los habitantes de la ciudad de Bogota D.C. y se dictan otras
44 disposiciones. Bogotá.
- 45 Alcaldía Mayor de Bogotá. (17 de 4 de 2022). Régimen Legal de Bogotá D.C. Obtenido de
46 <https://www.alcaldiabogota.gov.co/sisjur/normas/Norma1.jsp?i=104145>
- 47 Baena Salazar, D., Jiménez, J., Zapata, C., & Ramírez Cardona, Á. (2019). Red Neuronal Artificial aplicado para
48 el pronóstico de eventos críticos de PM2.5 en el Valle de Aburra. *DYNA*, 86(209), 347–356.
- 49 Bekkar, M., Kheliouane Djemaa, H., & Alitouche, T. (2013). Evaluation Measures for Models Assessment over
50 Imbalanced Datasets. *Journal of Information Engineering and Applications*, 27-33.
- 51 Belán, B. (2010). Ozono en la troposfera. Tomsk: Editorial del Instituto de Óptica Atmosférica SB RAS.
- 52 Brownlee, J. (28 de 04 de 2022). [https://machinelearningmastery.com/smote-oversampling-for-imbalanced-](https://machinelearningmastery.com/smote-oversampling-for-imbalanced-classification/)
53 [classification/](https://machinelearningmastery.com/smote-oversampling-for-imbalanced-classification/). Obtenido de *Machine Learning Mastery*: [https://machinelearningmastery.com/smote-](https://machinelearningmastery.com/smote-oversampling-for-imbalanced-classification/)
54 [oversampling-for-imbalanced-classification/](https://machinelearningmastery.com/smote-oversampling-for-imbalanced-classification/)
- 55 Cano Ramirez, F., & Cruz Roa, A. (2018). Entrenamiento de una Red Neuronal Convolutiva con Jupyter y
56 TensorFlow para la clasificación de tejido invasivo de cáncer de seno. II Congreso Internacional de
57 Ciencias Básicas e Ingeniería - CICI 2018. Villavicencio.
- 58 Centro de Investigaciones, Energéticas Medioambientales y Tecnológicas CIEMAT. (2009). El ozono troposférico
59 y sus efectos en la vegetación. Madrid: MARM.
- 60 Chakma, A., Vizona, B., Cao, T., & Lin, J. (2017). 2017 IEEE International Conference on Image Processing
61 (ICIP). Image-based air quality analysis using deep convolutional neural network (págs. 3949-3952).
62 Beijing: IEEE.

- 1 Cogua Morena , M. (2013). Dinámica de la construcción por usos Localidad Fontibón 2002 - 2012. Bogotá:
2 Observatorio Técnico Catastral.
- 3 Collazo, A., Morales, R., & Morales, L. (2012). Análisis de la contaminación transfronteriza y local de los
4 compuestos gaseosos precursores de la deposición ácida húmeda y formación de ozono en Cuba. Revista
5 Cubana de Meteorología, 17-30.
- 6 Delgado Saborit , J. M. (2005). Validación e implementación de técnicas de captación pasiva para el estudio de
7 los niveles y efectos de ozono troposférico y dióxido de nitrógeno en un área costera mediterránea.
8 Castellón : Universitat Jaume I.
- 9 Dissanayake, M., Nguyen, H., Poologanathana, K., & Perampalama, G. (2022). Prediction of shear capacity of
10 steel channel sections using machine learning algorithms. *Thin-Walled Structures*, 175, 109-152.
- 11 Doherty , R., Heal , M., & O'Connor , F. (2017). Climate change impacts on human health over Europe through
12 its effect on air quality. *Environmental Health*, 16(118), 33-34.
- 13 Huerta Mora , E., Gonzales Huitron , V. A., & Rodriguez Mata , A. E. (2020). Detección de enfermedades foliares
14 con arquitecturas de redes neuronales convolucionales. *Revista Internacional De Desarrollo Regional*
15 *Sustentable*, 5, 5-18.
- 16 Hunter, J., Dale, D., Firing , E., & Droettboom , M. (12 de Abril de 2022). Matplotlib. Obtenido de
17 <https://matplotlib.org/>
- 18 Instituto de Hidrología, Meteorología y Estudios Ambientales - IDEAM. (2019). El ozono. Bogotá.
- 19 Instituto de Hidrología, Meteorología y Estudios Ambientales IDEAM. (2021). Índice de Calidad del Aire (ICA)
20 (Hoja metodológica versión 1,1). Bogotá: IDEAM.
- 21 Isra , M., Hashmi, S., Rahman, G., Ahmad, S., & Ali, S. (2015). Devastating Flood of 2010, Effect on Potable
22 Water Supply in Rural Swat. *American Journal of Water Resources*, 118-123.
- 23 Jacob, D. (2000). Heterogeneous chemistry and tropospheric ozone. *Atmospheric Environment*, 34(12), 2131-
24 2159.
- 25 Jin, X., Xiao, F., Zhang, C., & Li, A. (2022). GEIN: An interpretable benchmarking framework towards all
26 building types based on machine learning. *Energy and Buildings*, 260.
- 27 Juba , B., & LE, H. (2017). Precision-Recall versus Accuracy and the Role of Large Data Sets. *Computer Science*.
- 28 Junior , A., Sperandio Nascimento , E., & Martins Moreira , D. (2020). Assessing recurrent and convolutional
29 neural networks for tropospheric ozone forecasting in the region of vitória, brazil. *Air and Water*
30 *Pollution*, 244, 101-112.
- 31 Karayev , S., Trentacoste , M., Han , H., Argawala, A., & Darrell, T. (2013). Recognizing Image Style. arXiv, 1-
32 20.
- 33 Kingma, D., & Lei Ba, J. (2017). Adam: a method for stochastic optimization. ICLR 2015. San Diego .
- 34 Kow, P., Chang , L., & Chang , F. (2020). Image Regression Classification of Air Quality by Convolutional Neural
35 Network. EGU General Assembly .
- 36 Lundh , F., & Clark, A. (9 de Abril de 2022). Pillow (PIL Fork). Obtenido de
37 <https://pillow.readthedocs.io/en/stable/>
- 38 Makarova , A., Evstafeva, E., Lapchenko, V., & Varbanov, P. (2021). Modelling tropospheric ozone variations
39 using artificial neural networks: A case study on the Black Sea coast (Russian Federation). *Cleaner*
40 *Engineering and Technology*, 5.
- 41 Martínez Perez, E. M., & López de Jiménez, R. E. (2020). Sistema telemático de monitoreo de calidad del aire en
42 zonas remotas : desarrollo de una plataforma para el análisis de datos y generación de modelos por medio
43 de técnicas de Big Data y Machine Learning. San Salvador.
- 44 Maxwell, A., & Warner, T. (2018). Implementation of machine-learning classification in remote sensing: an
45 applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817.
- 46 Ministerio de Ambiente y Desarrollo Sostenible . (2019). Estrategia BNacional de Calidad del Aire . Bogotá:
47 Ministerio de Ambiente y Desarrollo Sostenible.
- 48 Mitchell, T. (1997). *Machine Learning* . Nueva York : McGraw-Hill.
- 49 Molina Gómez, N. I. (2021). Incidencia de la calidad el aire en el desarrollo urbano sostenible. Metodología de
50 pronóstico basado en herramientas de aprendizaje automático. Bogotá .
- 51 Nadi , J., Ducatelle, F., Di Caro , G., & Ciresan , D. (2011). Max-pooling convolutional neural networks for vision-
52 based hand gesture recognition. 2011 IEEE International Conference on Signal and Image Processing
53 Applications (ICSIPA). Kuala Lumpur.
- 54 Nain, A., Paul, S., & Maynard-Reid, M. (19 de 4 de 2022). Keras. Obtenido de
55 <https://keras.io/api/optimizers/adam/>
- 56 Nash , W., Drumond , T., & Birbilis, N. (2018). A review of deep learning in the study of materials degradation.
57 *npj Materials Degradation*, 2(37), 1-12.
- 58 Nawaz, S., Ramiah Pilai, T., Kaur , S., & Sukumaran , S. (2019). Accuracy Comparison of Machine Learning
59 Algorithms for Predictive Analytics in Higher Education. *Emerging Technologies in Computing*, 254-
60 261.
- 61 Nwankpa, C., Ijomah , W., & Gachagan, A. (2020). Activation Functions: Comparison of Trends in Practice and
62 Research for Deep Learning. 2nd International Conference on Computational Sciences and Technologies.
63 Jamshoro.

- 1 Park , C., Cheong Took , C., & Seong , J. K. (2018). Machine learning in biomedical engineering. *Biomedical*
2 *Engineering Letters* volume, 1-3.
- 3 Pedroza Camelo , J. C. (2018). Prototipo de un modelo de machine learning para la predicción de partículas de
4 contaminación atmosférica. Bogotá .
- 5 Peng, L., Zhang, H., Yang , B., & Chen , Y. (2014). A new approach for imbalanced data classification based on
6 data gravitation. *Information Sciences: an International Journal*, 347-373.
- 7 Perez Carrasco , J. A. (2019). Clasificación de imágenes usando redes neuronales convolucionales en Python.
8 Sevilla : Escuela Técnica Superior de Ingeniería .
- 9 Piuri , V., Raj, S., Genovese, A., & Srivastava, R. (2020). *Trends in Deep Learning Methodologies Algorithms,*
10 *Applications, and Systems.* Academic Press.
- 11 Programa de las Naciones Unidas para el Medio Ambiente PNUMA. (1994). *Manuales de Metodología de*
12 *GEMS/Aire. Volumen 1. Aseguramiento de la calidad en el monitoreo de la calidad del aire urbano.*
13 *Nairobi .*
- 14 Python Software Foundation . (10 de Abril de 2022). Python TM. Obtenido de
15 <https://docs.python.org/es/3.10/library/os.html>
- 16 Red de Monitoreo de Calidad del Aire de Bogotá . (2018). *Informe Anual de Calidad del Aire Bogotá Año 2018.*
17 *Bogotá: Alcaldía Mayor De Bogotá .*
- 18 Red de monitoreo de Calidad del aire de Bogotá - RMCAB . (2020). *Informe Anual de Calidad del Aire de Bogotá*
19 *Año 2020. Bogotá: Alcaldía Mayor de Bogotá .*
- 20 Reichstein, M., Camps Valls, G., Stevens , B., Jung , M., & Denzler, J. (2019). Deep learning and process
21 understanding for data-driven Earth system science. *Nature*, 195-204.
- 22 Rosales, J. C., Torres Meza, V., & Olaiz Fernandez, G. (2001). Los efectos agudos de la contaminación. *Salud*
23 *Publica de Mexico del aire en la salud de la población: evidencias de estudios epidemiológicos*, 43, 544-
24 555.
- 25 Saleem, T., & Chishti, M. (2021). Deep learning for the internet of things: Potential benefits and use-cases. *Digital*
26 *Communications and Networks*, 7(4), 526-542.
- 27 scikit-learn developers. (18 de 4 de 2022). Scikitlearn . Obtenido de [http://scikit-](http://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.OneHotEncoder.html)
28 [learn.org/stable/modules/generated/sklearn.preprocessing.OneHotEncoder.html](http://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.OneHotEncoder.html)
- 29 Scikit-learn developers. (13 de Abril de 2022). Scikit-learn Machine Learning in Python. Obtenido de
30 <https://scikit-learn.org/stable/>
- 31 Secretaria de ambiente Bogotá . (s.f.). Red de Monitoreo de Calidad del Aire de Bogotá RMCAB. (Alcaldía mayor
32 de Bogotá) Recuperado el 31 de Octubre de 2021, de
33 <http://rmcab.ambientebogota.gov.co/Report/stationreport>
- 34 Secretaria Distrital de Ambiente. (2019). *Informe de calidad del aire Bogotá.*
- 35 Secretaría Distrital De Ambiente. (2020). *Informe Anual de Calidad del Aire de Bogotá Año 2020. Bogotá:*
36 *Alcaldía Mayor de Bogotá.*
- 37 Secretaria Distrital de Ambiente. (2020). *Inventario de emisiones de Bogotá, Contaminantes atmosféricos. Bogotá:*
38 *Alcaldía Mayor de Bogotá.*
- 39 Secretaría Distrital De Ambiente. (2020). *Plan decenal de descontaminación del aire para Bogotá 2010-2020.*
40 *Bogotá.*
- 41 Sharma, N., Jain , V., & Mishra, A. (2018). An Analysis Of Convolutional Neural Networks For Image
42 Classification. *Procedia Computer Science*, 377-384.
- 43 Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale imagerecognition. 3rd
44 International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings. San
45 Diego.
- 46 Sistema Nacional Ambiental – SINA. (2015). *Informe Ambiental del Estado del Medio Ambiente . Bogotá : SINA.*
- 47 Suk Suh, K., Min, B.-I., Yang , B.-M., Kim, S., & Park, K. (2022). Machine learning method using camera image
48 patterns for predictions of particulate matter concentrations. *Atmospheric Pollution Research*, 1-7.
- 49 Vakili, M., Ghamsari, M., & Rezaei, M. (27 de Enero de 2020). Performance Analysis and Comparison of Machine
50 and Deep Learning Algorithms for IoT Data Classification. Recuperado el 30 de Marzo de 2022, de
51 <https://arxiv.org/ftp/arxiv/papers/2001/2001.09636.pdf>
- 52 Veeduría Distrital . (2021). *La calidad del aire en Bogotá: Seguimiento a las metas del Plan Distrital de Desarrollo*
53 *2020 - 2024 Sobre Reducción del Material Particulado . Bogotá : Veeduría Distrital .*
- 54 Ward Powers, D. M. (2011). Evaluation: from precision, recall and f-measure to roc, informedness, markedness
55 & correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- 56 Warneck, P. (1988). *Chemistry of the Natural Atmosphere.* San Diego : International Geophysics.
- 57 Yamashita , R., Nishio, M., Kinh Gian DO , R., & Togashi , K. (2018). Convolutional neural networks: an overview
58 and application in radiology. *Insights into Imaging*, 9, 611-629.
- 59 Zang , Y., Bocquet, M., Mallet, V., Seigneur, C., & Baklanov , A. (2012). Real-time air quality forecasting, part
60 I: History, techniques, and current status. *Atmospheric Environment*, 60, 632-655.
- 61 Zhou, Y., Liu , Y., Tang , C., & Wen, S. (2014). A Strategy on Selecting Performance Metrics for Classifier
62 Evaluation. *International Journal of Mobile Computing and Multimedia Communications* , 6(4), 20-35.
- 63