

*“TENDENCIAS DE CALIDAD DEL AIRE  
VINCULADAS A LA EXPORTACIÓN DE  
CONCENTRADO DE COBRE EN PUERTO  
BOLÍVAR, ECUADOR”*

*AIR QUALITY TRENDS RELATED TO COPPER CONCENTRATE  
EXPORTS IN PUERTO BOLIVAR, ECUADOR*

## **Autores**

---

**Luis Angel Vargas Collaguazo**

Ing. Ambiental, Universidad Técnica de Machala, Ecuador

[lvargas@utmachala.edu.ec](mailto:lvargas@utmachala.edu.ec)

<https://orcid.org/0000-0001-7619-1323>

---

**Carlos Daniel Ramírez Bermeo**

Ing. Ambiental, Universidad Técnica de Machala, Ecuador

[cramirez8@utmachala.edu.ec](mailto:cramirez8@utmachala.edu.ec)

<https://orcid.org/0009-0009-4494-4752>

---

**Allan Eduardo Gonzabay Galarza**

Ing. Ambiental, Universidad Técnica de Machala, Ecuador

[agonzabay3@utmachala.edu.ec](mailto:agonzabay3@utmachala.edu.ec)

<https://orcid.org/0009-0004-2113-2384>

---

**Juan Carlos Berrú Cabrera**

Ing. Civil, Universidad Técnica de Machala, Ecuador

[jberru@utmachala.edu.ec](mailto:jberru@utmachala.edu.ec)

<https://orcid.org/0000-0003-0505-9135>

---

TENDENCIAS DE CALIDAD DEL AIRE  
VINCULADAS A LA EXPORTACIÓN DE  
CONCENTRADO DE COBRE EN PUERTO  
BOLÍVAR, ECUADOR

RESUMEN

RESUMEN

La calidad del aire está fuertemente influenciada por factores climáticos y antrópicos, siendo fundamental regular el impacto de las actividades al aire. En este contexto, el presente estudio evaluó la influencia de la exportación de concentrado de cobre en la calidad del aire en Puerto Bolívar. Se emplearon técnicas de teledetección utilizando el producto MCD19A2 de MODIS para obtener la profundidad óptica de aerosoles (POA) durante el período 2014–2024, complementadas con información sobre los volúmenes de exportación de concentrado de cobre reportados en el informe preliminar de 2023. Con estos insumos se analizaron posibles correlaciones entre ambas variables con el fin de identificar patrones que permitan comprender la relación entre la actividad exportadora y la dinámica atmosférica. Los resultados obtenidos mediante la regresión segmentada y el modelo ARIMA indicaron que no existe un cambio de tendencia de la POA, dado que no se identificaron puntos de quiebre durante el período analizado. La prueba ADF arrojó un estadístico de -9.1393 y un valor p igual a 0, confirmando una estacionariedad de la POA. Por su parte, el análisis de regresión lineal entre las exportaciones de concentrado de cobre y la POA reveló la ausencia de una correlación entre estas variables, respaldada por los coeficientes de correlación de Pearson y Spearman, que fueron de -0.010 y -0.096, respectivamente.

**Palabras claves:** calidad del aire, modis, POA, mcd19a2, teledetección

ABSTRACT

Air quality is strongly influenced by climatic and anthropogenic factors, making it essential to regulate the impact of activities on the air. In this context, the present study evaluated the influence of copper concentrate exports on air quality in Puerto Bolívar. Remote sensing techniques using the MODIS MCD19A2 product were employed to obtain the aerosol optical depth (AOD) for the period 2014–2024, complemented by information on copper concentrate export volumes reported in the 2023 preliminary report. With this data, possible correlations between both variables were analyzed to identify patterns that would allow for an understanding of the relationship between export activity and atmospheric dynamics. The results obtained through segmented regression and the ARIMA model indicated that there is no trend change in the AOD, as no breakpoints were identified during the analyzed period. The ADF test yielded a statistic of -9.1393 and a p-value of 0, confirming the stationarity of the POA. Meanwhile, the linear regression analysis between copper concentrate exports and the POA revealed no correlation between these variables, supported by Pearson and Spearman correlation coefficients of -0.010 and -0.096, respectively.

**Keywords:** air quality, MODIS, POA, MCD19A2, remote sensing

**Nota Editorial:** Recibido: 10 de Julio 2025 Aceptado: 17 de noviembre 2025

## 1. INTRODUCCIÓN

La calidad del aire es un indicador esencial para el bienestar ambiental y humano, debido a su relación directa con la salud pública y la biodiversidad. En áreas urbanas e industriales, los contaminantes de aerosoles como el material particulado abarcan un riesgo significativo para la salud humana, enfocándolo en zonas cercanas a actividades industriales y portuarias. Este material particulado se clasifica según el diámetro de las partículas: PM10 incluye partículas de hasta 10 micrómetros ( $\mu\text{m}$ ), mientras que PM2.5 agrupa aquellas de 2.5  $\mu\text{m}$  o menores, siendo esta última fracción la más dañina debido a su capacidad de penetrar profundamente en el sistema respiratorio. Para ello, la utilización de tecnologías avanzadas como son las imágenes satelitales y modelos de calidad del aire permiten una vigilancia permanente de las concentraciones de los contaminantes del aire, facilitando la implementación de estrategias para la correcta gestión ambiental ante este problema [1][2].

La relación que tiene la calidad del aire con la salud pública se basa en la susceptibilidad de la población a desarrollar enfermedades respiratorias. Esta problemática afecta particularmente a los sectores sociales más vulnerables y de bajos ingresos, en los que suelen estar expuestos a entornos en los que la calidad del aire tiende a ser inferior, lo que incrementa el riesgo de impactos negativos en la salud [3].

La calidad del aire en entornos urbanos es resultado de la interacción entre las condiciones del ambiente, las fuentes naturales y antropogénicas [4]. La dinámica cambiante de estas condiciones genera variaciones en la composición, concentración y distribución de los contaminantes atmosféricos a lo largo del tiempo, lo que puede llevar a incrementos locales en las concentraciones de dichos contaminantes y, consecuentemente, al deterioro de la calidad del aire.

En Ecuador, la calidad del aire ha sido un tema de creciente preocupación, especialmente en ciudades costeras con intensa actividad comercial e industrial. Estudios recientes muestran que los niveles de material particulado en regiones urbanas pueden exceder los límites establecidos por organismos internacionales, lo que afecta de manera desproporcionada a comunidades vulnerables [5] [6]. En el contexto regional, otros países de América Latina también enfrentan retos similares, destacándose la necesidad de fortalecer el monitoreo y regulación ambiental [7].

Machala, conocida como una de las principales ciudades costeras de Ecuador, cuenta con una infraestructura portuaria clave en Puerto Bolívar. Este puerto se especializa en la gestión de productos para la exportación como el banano, cuya exportación representa una parte significativa de la economía nacional. Sin embargo, la actividad portuaria también puede generar emisiones contaminantes relacionadas con el transporte marítimo y terrestre, así como el manejo de materiales industriales, incrementando la concentración de aerosoles en el área [5] [8].

El concentrado de cobre es el producto resultante de los procesos de extracción y beneficio del mineral, mediante los cuales se logra la separación de minerales como la calcopirita y la calcocita del material estéril (relave). Este concentrado presenta un contenido de cobre que varía entre el 20 % y el 45 %, y se caracteriza por un tamaño de partícula intermedio, generalmente en el rango de 50 a 70  $\mu\text{m}$  [9]. Sin embargo, una fracción menor del material puede presentar partículas finas inferiores a 10  $\mu\text{m}$ , las cuales son altamente susceptibles a la suspensión en el aire durante el transporte, manipulación o almacenamiento del material, contribuyendo potencialmente a la emisión de material particulado respirable (PM 2.5 y PM 10).

La gestión de concentrados de cobre en los puertos representa un desafío tanto logístico como ambiental, ya que este material, proveniente de actividades mineras, requiere de procesos con buenas técnicas de almacenamiento y transporte que permitan mitigar su dispersión en el aire. La manipulación inadecuada de concentrados de cobre puede ser causante de la emisión de material particulado fino, que afectan la calidad del aire y generan riesgos para las zonas urbanas cercanas al puerto y a las rutas de transporte.

La exposición prolongada a altos niveles de aerosoles, incluyendo los que contienen material particulado PM2.5 y PM10, está asociada con un aumento en la incidencia de enfermedades respiratorias y cardiovasculares, como hipertensión y ataques al corazón, debido a su capacidad de inducir inflamación sistémica. En regiones portuarias como Machala, donde las actividades industriales y de transporte generan emisiones significativas, la población enfrenta un mayor riesgo de padecer estas enfermedades. Estudios realizados en ciudades con características similares han demostrado correlaciones claras entre la concentración de material particulado en el aire y la prevalencia de estas afecciones [2] [6].

El monitoreo de material particulado en los años de estudio proviene del instrumento MODIS (*Moderate Resolution Imaging Spectroradiometer*) es un sensor clave a bordo de los satélites terra (EOS AM-1) y Aqua (EOS PM-1), en concreto el producto MCD19A2, producto de teledetección recopilado por los sensores MODIS, apropiado para analizar los impactos de aerosoles en áreas urbanas, con resoluciones espaciales de 1 km y temporales de 1 día el cual capta el AOD (*Aerosol Optical Depth*) en tierra por medio del algoritmo MAIAC (*Multi-angle Implementation of Atmospheric Correction*) con la colección 6.1 [10]. De esta manera, el uso de este producto satelital posibilita la evaluación cualitativa del comportamiento de las concentraciones de material particulado en el área de estudio, permitiendo su procesamiento, análisis y representación espacial a través de las imágenes derivadas del producto MODIS MCD19A2.

La aplicación de mecanismos de teledetección para identificar contaminantes es una herramienta útil cuando no se poseen estaciones terrestres de monitoreo para medir los diferentes compuestos perjudiciales directamente en el ambiente local objeto de interés, por ello direccionar un estudio hacia el análisis del comportamiento del material particulado y relacionarlo con las exportaciones de concentrado de cobre, permitirá comprender la influencia de sus operaciones con la calidad del aire.

**Objetivo general:** Evaluar la influencia de los volúmenes de concentrado de cobre manipulados para la exportación en la calidad del aire en Puerto Bolívar durante el período 2014-2024, mediante el análisis de tendencias temporales obtenidas a través de sensores remotos con el fin de identificar posibles afectaciones al recurso aire.

### Objetivos específicos:

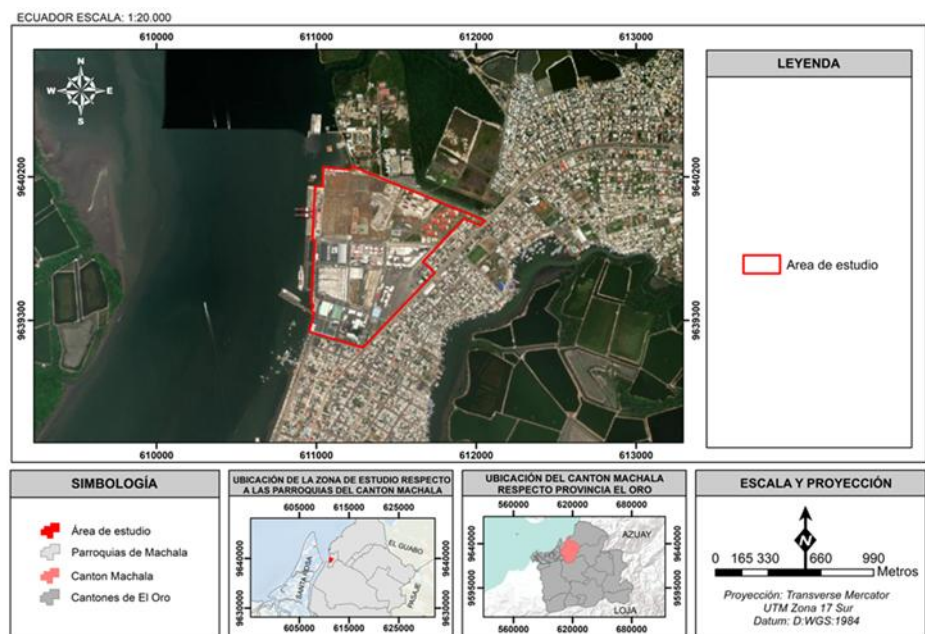
- Obtener y analizar datos de POA del producto MCD19A2 de MODIS para la parroquia Puerto Bolívar en el período 2014-2024.
- Analizar los cambios de tendencia del POA en el periodo 2014-2024 mediante un análisis multitemporal.
- Evaluar la correlación entre POA y las exportaciones de concentrado de cobre mediante un análisis estadístico.

## 2. DESARROLLO

### 2.1. DELIMITACIÓN DEL ÁREA DE ESTUDIO

Para la delimitación del área de estudio se utilizó el sistema de información geográfica (ArcGIS 10.3). Utilizando el mapa base como referencia se ubicó de forma precisa el área de interés y a continuación se superpusieron la capa de polígono para delimitar un área que representa fielmente el área de estudio.

El presente estudio se desarrolla en la parroquia Puerto Bolívar, cantón Machala, en la provincia de El Oro, Ecuador. La zona de estudio se encuentra específicamente en el área de operaciones del Puerto Bolívar, como se muestra en figura 1. Esta área ha sido delimitada debido a las actividades de almacenamiento de concentrados de cobre destinadas a su posterior exportación.



### 2.2. MATERIALES Y MÉTODOS

Se seleccionó el producto MCD19A2 del sensor MODIS debido a su reconocida correlación con los niveles de material particulado, a través de la variable de POA. Para la obtención de los datos, se empleó un código por medio de la plataforma *Google Earth Engine* (GEE), que implementa un proceso de filtrado en tres etapas: en primer lugar, se restringen las imágenes disponibles al área de estudio; en segundo lugar, se seleccionan únicamente aquellas que contienen datos válidos de POA; y, finalmente, se aplica un filtrado adicional utilizando los bits 0–2 del conjunto POA\_QA, correspondiente a la máscara de nubes, seleccionando únicamente las escenas con condiciones atmosféricas claras para su posterior exportación y procesamiento manual.

Para el diseño experimental, debido a la resolución espacial del producto MCD19A2, se dividió al área de influencia de la zona de estudio en 9 sectores, que representan los puntos cardinales como se observa en la figura 2, en donde el sector CENTRO corresponde a la ubicación del área de almacenamiento de concentrado de cobre, considerada como el punto de origen de la emisión. Esta segmentación permite una evaluación espacial más precisa de la posible dispersión de la pluma de contaminación.

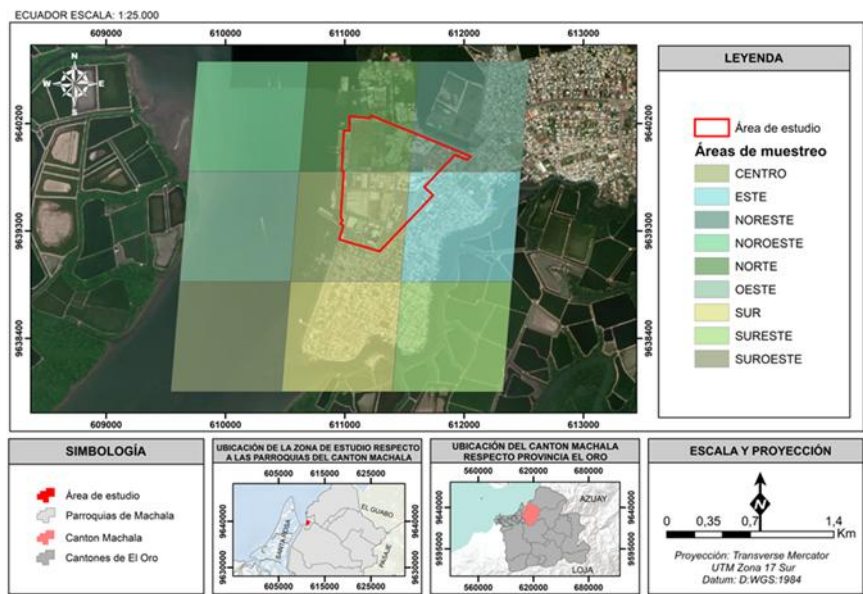


Fig. 2- Mapa de ubicación de las áreas muestreadas

### 2.3. PROCESOS PARA EXTRACCIÓN DE DATOS POA EN PUERTO BOLÍVAR

.Para la obtención de los datos POA se siguieron los siguientes pasos dentro de la plataforma de GEE como se muestra en la figura 3.

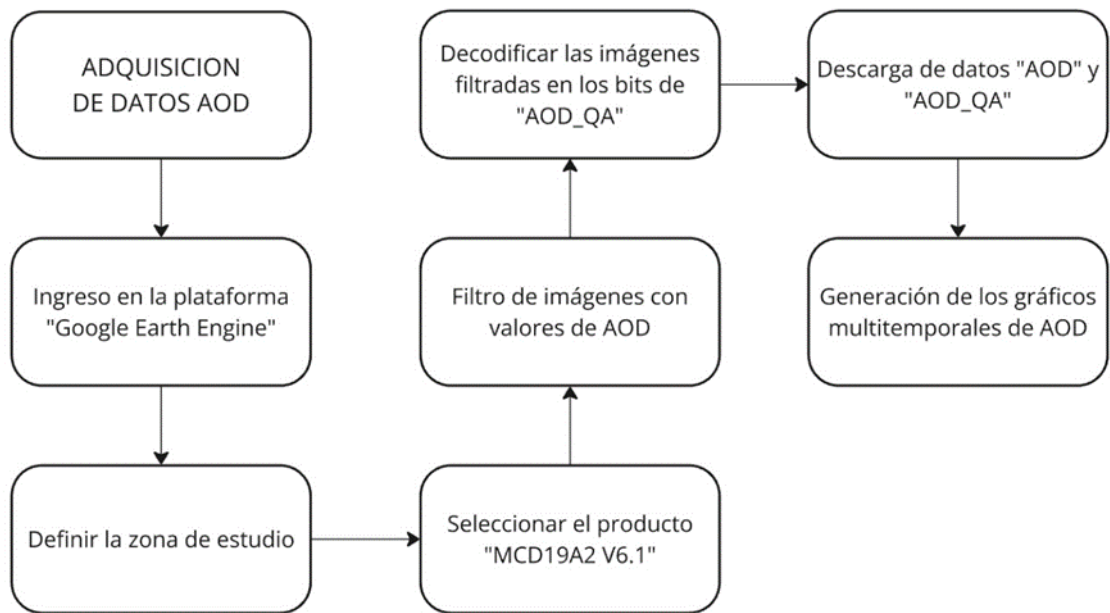


Fig. 3- Diagrama de flujo de procesos realizados

#### Definir la zona de estudio en Google Earth Engine

Como primer paso, se definió la coordenada central de referencia con la que se trabajó en el análisis, correspondiente a una latitud de  $-3.26^{\circ}$  y una longitud de  $-80.00^{\circ}$ , expresadas en grados decimales y con datum WGS84, formato requerido por la plataforma Google Earth Engine (GEE). Esta coordenada se utilizó como punto base para la delimitación espacial del área de estudio.

A partir de este punto central, se establecieron ocho puntos adicionales distribuidos en las direcciones cardinales y colaterales: N (norte), S (sur), NE (noreste), NO (noroeste), E (este), O (oeste), SE (sureste) y SO (suroeste), y por último se crea una figura geométrica (denominada como “geometry” dentro de GEE) que representa una cuadrícula que encierra los píxeles de los 9 puntos antes establecidos con el siguiente código, como se muestra en la tabla 1.

**Tabla 1-**Coordenadas de los puntos de muestreo

Punto	Coordenada (point)
C	-80.00012884487714, -3.2631151325028394
N	-80.00015745349911, -3.255888456425933
S	-80.00004301418866, -3.270056122313961
NE	-79.99240408291425,-3.2559170183595496
NO	-80.0075961147746,-3.2557456340620052
E	-79.99291906704511, -3.2631151325028394
O	-80.00742445339765, -3.262943749431475
SE	-79.99291906704511, -3.270227504171103
SO	-80.0072527920207, -3.270827340440378

Luego se dispuso a elegir el producto a trabajar, en este caso el MCD19A2, señalando en el código que las imágenes se las requiriere desde el 2014 hasta el 2024, estableciendo las fechas en periodos de 1 año para la descarga de información en su versión de MAIAC 6.1, también se filtraron las imágenes para la zona anteriormente denominada “geometry” y fueron seleccionadas las bandas “Optical\_Depth\_047” y “POA\_QA” para posteriores filtros.

1. Filtrar imágenes con valores en geometría

En la siguiente sección se aplica una función a cada imagen de la colección para después extraer la máscara de la banda “Optical\_Depth\_047”, del cual se establece válido cuando exista al menos 1 píxel con datos de POA en el área de “geometry”. Esta función es devuelta a la imagen y se agrega una nueva máscara denominada “hasData” con valores de 0 (sin píxeles válidos) y 1 (con al menos 1 píxel válido), finalmente se filtran las imágenes con un “hasData” de 1.

1. Decodificación de bits de QA

Se establece una función destinada a decodificar las imágenes previamente filtradas para posteriormente seleccionar la banda “POA\_QA” y se agregan nuevas bandas correspondientes a los rangos de bits y nombres establecidos en [9]. Finalmente, esta función se asigna a una variable, lo que permite su aplicación sistemática sobre la colección de imágenes.

1. Aplicar decodificación, máscara y recorte

Para filtrar los datos de POA utilizando el criterio de máscara de nubes, se aplica la función previamente definida en el punto 3 a las imágenes correspondientes en los puntos de muestreo, incorporando bandas que representan el contenido de los bits. Posteriormente, se selecciona la banda Cloud\_Mask y se establece el criterio 1, correspondiente a cielo claro. Este proceso identifica los píxeles que cumplen con el criterio, los cuales son extraídos y recortados por el área geometry, devolviendo la máscara a las imágenes filtradas.

1. Función para crear gráfico de POA y QA

Para la descarga de datos de POA, se desarrolló una función que permite representar los valores obtenidos mediante un gráfico de dispersión. En este proceso, se define la variable POAChart, donde se seleccionan las bandas “Optical\_Depth\_047” y “POA\_QA”, las cuales recuperan los datos de un punto de muestreo específico. A continuación, se establecen las propiedades de visualización que tendrá la gráfica, Por último, la función es asignada a una variable para generar los gráficos correspondientes a los nueve puntos de muestreo.

Todos estos pasos descritos, fueron realizados con un programa en lenguaje Python, cuyo código se muestra fueron realizados con un programa en lenguaje Python, cuyo código se muestra en la figura 4 dentro del Google Earth Engine.

```

//CARGAR EL PRODUCTO MODIS
var modisCollection = ee.ImageCollection('MODIS/061/MCD19A2_GRANULES')
  .filterDate('2024-01-01', '2024-12-31')
  .filterBounds(geometry)
  .select(['Optical_Depth_047', 'AOD_QA']);
//FILTRAR IMÁGENES CON VALORES EN GEOMETRÍA
var modisConAOD = modisCollection.map(function(image) {
  var mask = image.select('Optical_Depth_047').mask().reduceRegion({
    reducer: ee.Reducer.anyNonZero(),
    geometry: geometry}).get('Optical_Depth_047');
  return image.set('hasData', mask);});
var modisFiltrado = modisConAOD.filter(ee.Filter.eq('hasData', 1));
//DECODIFICACIÓN DE BITS DE QA
function decodeQA(image) {
  var qa = image.select('AOD_QA');
  return image.addBands([
    qa.rightShift(0).bitwiseAnd(7).rename('Cloud_Mask'),
    qa.rightShift(3).bitwiseAnd(3).rename('Land_Water_Snow_Ice'),
    qa.rightShift(5).bitwiseAnd(7).rename('Adjacency_Mask'),
    qa.rightShift(8).bitwiseAnd(15).rename('QA_AOD'),
    qa.rightShift(12).bitwiseAnd(1).rename('Glint_Mask'),
    qa.rightShift(13).bitwiseAnd(3).rename('Aerosol_Model'),
    qa.rightShift(15).bitwiseAnd(1).rename('Reserved')]);}
var decodificado = decodeQA;
//APLICAR DECODIFICACIÓN, MÁSCARA Y RECORTE
var modisDecodificado = modisFiltrado
  .map(decodeQA)
  .map(function(img) {
    var mask = img.select('Cloud_Mask').eq(1);
    var masked = img.updateMask(mask).clip(geometry);
    return masked.copyProperties(img, ['system:time_start']);});
//CONTROL DE IMAGENES (OPCIONAL)
print('Número total de imágenes:', modisCollection.size());
print('Número luego de aplicar máscara de calidad:', modisDecodificado.size());
//FUNCIÓN PARA CREAR GRÁFICO DE AOD Y QA
function crearGrafico(punto, titulo) {
  var aodChart = ui.Chart.image.series({
    imageCollection: modisDecodificado.select(['Optical_Depth_047', 'AOD_QA']),
    region: punto,
    reducer: ee.Reducer.first(),
    xProperty: 'system:time_start'}).setChartType('ScatterChart')
  .setOptions({
    title: 'AOD 0.47  $\mu$ m y QA_AOD (' + titulo + ')',
    hAxis: {title: 'Fecha', format: 'dd-MM-yy', gridlines: {count: 10}},
    vAxis: {title: 'Valor'},
    pointSize: 4,
    series: {
      0: {color: 'red', labelInLegend: 'QA_AOD'},
      1: {color: 'blue', labelInLegend: 'AOD'}}});
  return aodChart;
}
print(crearGrafico(punto_C, 'C'));
print(crearGrafico(punto_N, 'N'));
print(crearGrafico(punto_S, 'S'));
print(crearGrafico(punto_E, 'E'));
print(crearGrafico(punto_O, 'O'));
print(crearGrafico(punto_NE, 'NE'));
print(crearGrafico(punto_NO, 'NO'));
print(crearGrafico(punto_SE, 'SE'));
print(crearGrafico(punto_SO, 'SO'));

```

Fig. 4- Código para la descarga de datos de POA

a) Análisis estadístico de las series temporales

Para la aplicación de la regresión segmentada, el modelo ARIMA (*Autoregressive Integrated Moving Average*) y la regresión lineal, fue necesario homogeneizar los datos mediante el cálculo del promedio mensual de los valores de POA. Este proceso permitió mantener la coherencia temporal con los datos de exportación de concentrado de cobre, cuya frecuencia de registro es mensual.

En cuanto a los datos de volúmenes exportados de concentrados de cobre, estos fueron extraídos del informe preliminar del año 2023 elaborado por la Autoridad Portuaria de Puerto Bolívar, el cual nos aporta datos de exportación desde el año 2020. Para los análisis estadísticos se utilizó la plataforma Google Collaboratory con las bibliotecas y funciones de la tabla 2.

**Tabla 2-** Funciones y bibliotecas para el análisis estadístico

<b>FUNCION</b>	<b>BIBLIOTECA</b>	<b>USO</b>
<b>Regresión segmentada</b>	ruptures	Permite detectar puntos de cambio en series temporales y modelar segmentos con comportamientos distintos a lo largo del tiempo.
<b>Modelo ARIMA</b>	statsmodels.tsa.arima.model	Permite estimar el comportamiento de una serie temporal a lo largo de un periodo.
<b>Autocorrelación parcial (PACF)</b>	statsmodels.graphics.tsaplots	Permite determinar la correlación entre la serie y sus retardos descontando los efectos intermedios y permite estimar el componente “p” del modelo ARIMA
<b>Funciones de autocorrelación (ACF)</b>		Permite determinar la correlación entre la serie y sus retardos (lags) y permite estimar el componente “q” del modelo ARIMA
<b>Prueba de Dickey-Fuller Aumentada (ADF)</b>	statsmodels.tsa.stattools	Se utilizó para evaluar la estacionariedad de la serie temporal mediante pruebas estadísticas y determinar el componente “d” del modelo ARIMA.
<b>Regresión lineal</b>	scipy.stats y seaborn	Para la representación gráfica de la regresión lineal y el cálculo de los coeficientes de correlación de Pearson y Spearman.

### 3. RESULTADOS

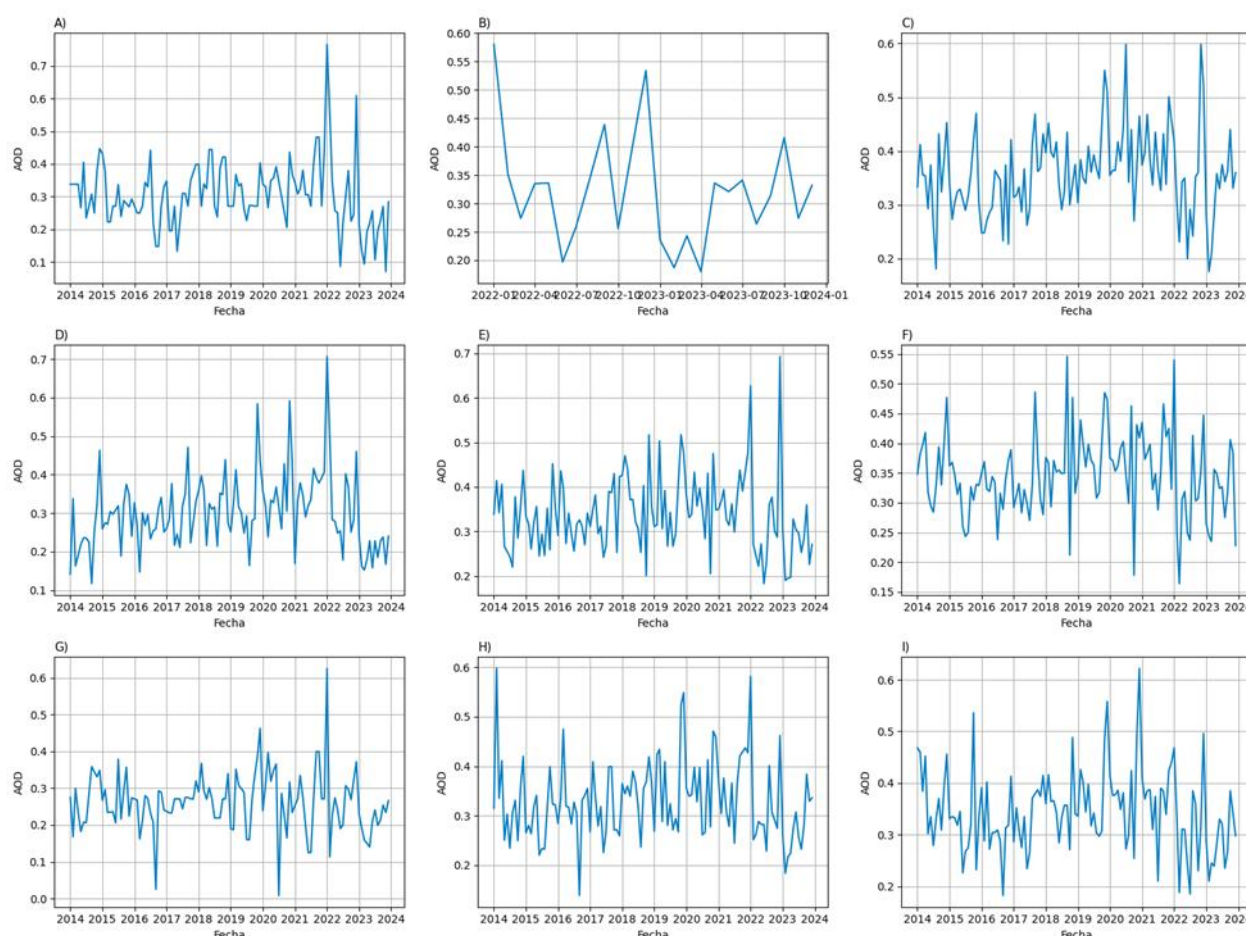
#### 3.1. ANÁLISIS DE DATOS DE POA DEL PRODUCTO MCD19A2 DE MODIS

Para mejorar la representatividad de los aerosoles durante el período 2014–2024, se implementó un riguroso filtrado de las imágenes satelitales utilizando la banda POA\_QA. En la plataforma GEE se procedió al filtrado en tres momentos. Primero, se seleccionaron únicamente las escenas del producto MCD19A2 de MODIS que cubrían las áreas de muestreo; a continuación, se filtraron para conservar solo aquellas con datos válidos de POA; y, finalmente, se aplicó el criterio “claro” de la máscara de nubes (bits 0–2 de POA\_QA) para eliminar píxeles nublados. Tras este procesamiento, los valores de POA resultantes se exportaron en formato Excel.

Para evaluar la posible influencia de las exportaciones de concentrado de cobre sobre la calidad del aire, se enfocó el análisis en el sector CENTRO (área de almacenamiento) y en sus ocho sectores adyacentes. Dado que el producto MCD19A2 tiene una resolución espacial de 1 km, cada área de muestreo se definió con la misma dimensión.

Después del filtrado, el número de observaciones de POA por área osciló entre 276 y 845 datos a lo largo de los 11 años estudiados. El sector NORTE no aportó datos hasta 2022 que correspondieron a 276 datos de POA para el periodo 2022 - 2024, mientras que SUROESTE y NOROESTE registraron solo 493 y 352 observaciones, respectivamente, siendo los tres sectores con menor cantidad de datos. No obstante, los restantes sectores presentaron entre 656 y 845 observaciones. Para homogeneizar la serie temporal, se promedió la cantidad de datos a nivel mensual, obteniéndose 120 valores de POA por sector, salvo en el sector Norte, que dispuso de únicamente 36 datos mensuales.

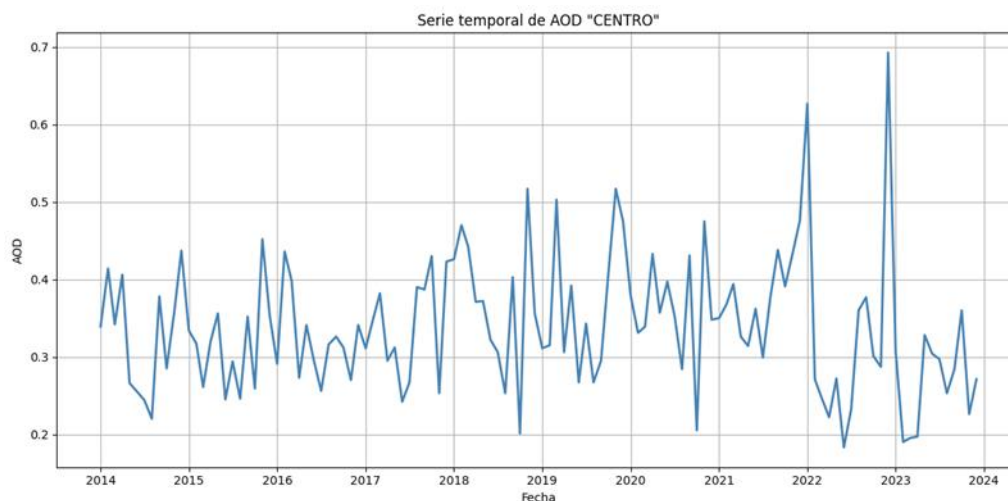
Como se observa en la figura 5, no se evidencia un cambio claro en la tendencia del POA en las nueve áreas de muestreo. No obstante, se identifican incrementos en los valores hacia finales de año, siendo particularmente acentuados en 2021, donde todas las áreas registran picos elevados. De manera similar, los años 2019 y 2022 presentan aumentos significativos en los niveles de POA, aunque no de forma homogénea en todas las zonas. Estos incrementos tienden a estabilizarse rápidamente al inicio del año siguiente.



**Fig. 5-** Comportamiento del POA en las 9 áreas de muestreo respecto al centro en la sección E)

### 3.2. SERIE TEMPORAL DEPURADA DE POA (QA APLICADO)

Tras la aplicación de filtros de calidad (QA) para la eliminación de píxeles no válidos, se procede a graficar la serie temporal del punto de muestreo central, dado que este corresponde al área de almacenamiento de concentrado de cobre. Como se observa en la figura 7, la serie temporal del POA presenta un comportamiento relativamente estable durante los primeros ocho años del periodo analizado, con valores que oscilan entre 0,2 y 0,5. Sin embargo, los últimos dos años, se registran picos que superan los 0,6 y descensos por debajo de 0,2 los cuales podrían estar asociados a variaciones meteorológicas propias de esos periodos, más que a la actividad exportadora. Por ejemplo, en años con condiciones más secas, la dinámica del material particulado podría verse modificada por menos precipitación y una mayor suspensión de partículas. En ese sentido, estudios futuros deberían incorporar variables climáticas con el fin de evaluar la correlación entre POA y la estacionalidad entre época húmeda y seca. Estos cambios no reflejan una tendencia sostenida, sino variaciones transitorias, que se analizará más adelante con la regresión segmentada y el modelo ARIMA.

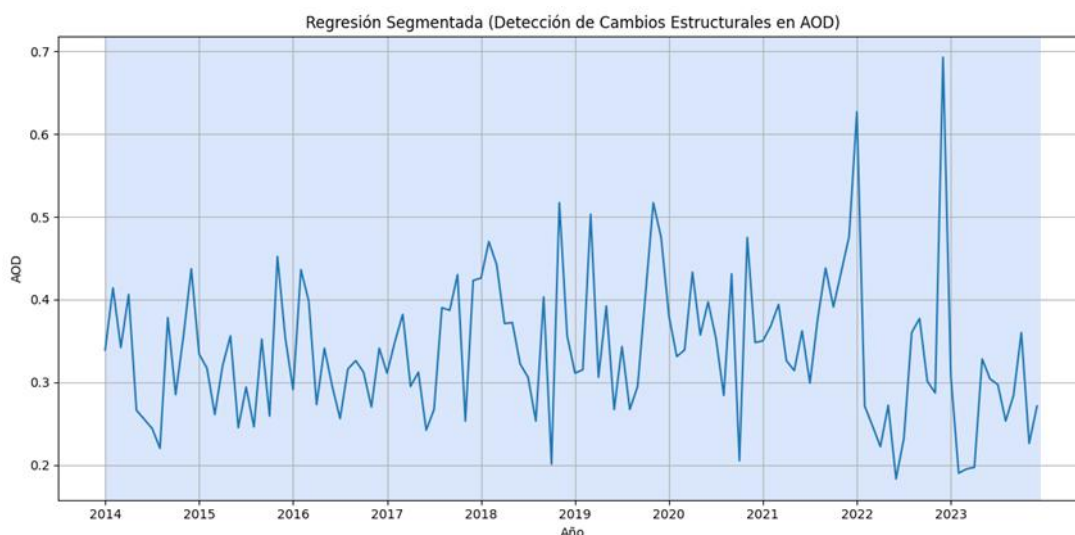


**Fig. 6-** Serie temporal de POA del punto de muestreo central del área de estudio

### 3.3. CAMBIOS EN LA TENDENCIA DEL MATERIAL PARTICULADO A PARTIR DE POA A TRAVÉS DE UN ANÁLISIS MULTITEMPORAL

- Regresión segmentada

Para determinar un posible aumento en los niveles de material particulado se analizó la serie temporal de POA mediante una regresión segmentada, considerando el periodo entre 2014, año de inicio de la vigilancia, y 2023, como se muestra en la figura 7, durante estos diez años el comportamiento del POA no evidencia una segmentación marcada, lo que se refleja en la continuidad del fondo azul del gráfico. Esto indica que no existe puntos de quiebre o variabilidad significativa a lo largo de la serie temporal. El comportamiento de la dinámica de la serie temporal, y como sus picos han ido creciendo sostenidamente, demuestran que existe una variable que esta influyendo directamente sobre los resultados. Esto fortalece la necesidad de incorporar en futuros estudios variables climáticas.

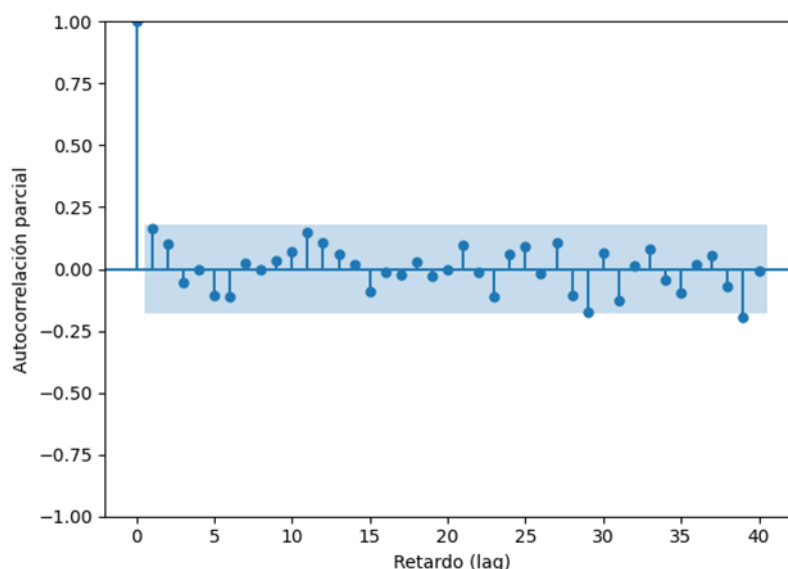


**Fig. 7-** Regresión segmentada de POA

- Media móvil integrado autorregresiva (ARIMA)

El modelo ARIMA es una herramienta útil para modelar y predecir el comportamiento de series temporales. Su aplicación requiere la identificación de tres componentes clave: el orden autorregresivo ( $p$ ), el grado de estacionariedad ( $d$ ), y el orden de la media móvil ( $q$ ). Para determinar estos parámetros, se utilizan métodos como la función de autocorrelación parcial (PACF), la prueba de raíz unitaria de Dickey-Fuller aumentada (ADF) y la función de autocorrelación total (ACF), los cuales permiten establecer el tipo de modelo idóneo para predecir el comportamiento del POA.

Para evaluar la relación directa entre la variable en el tiempo actual y sus rezagos, eliminando el efecto de los rezagos intermedios se utilizó la función de autocorrelación parcial (PACF). El resultado obtenido indica que no existe una autocorrelación entre una observación y sus rezagos, lo que indicaría que no existe una autoregresividad por lo tanto el componente  $p$  es de 0, como se muestra en la figura 8.



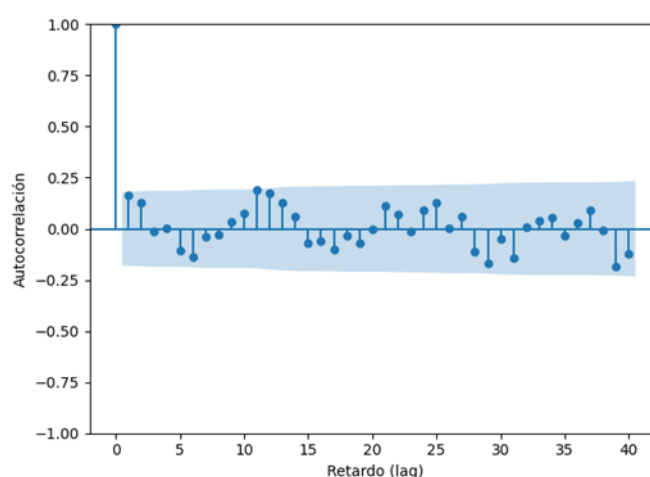
**Fig. 8-** Función de autocorrelación parcial (PACF) de POA.

Para verificar la estacionariedad de la serie temporal, se aplicó la prueba de Dickey-Fuller Aumentada (ADF). Esta prueba permite determinar la presencia de una raíz unitaria, lo cual indicaría que la serie no es estacionaria. Los resultados obtenidos muestran que el estadístico ADF es significativamente menor que los valores críticos como se muestra en la tabla 3. Además, dado que el valor  $p$  es inferior a 0.05, se rechaza la hipótesis nula de no estacionariedad, concluyéndose que la serie es estacionaria por lo tanto el componente  $d$  es de 0.

**Tabla 3-** Prueba ADF y valores críticos de la prueba ADF

Prueba ADF		Valores críticos AOF	
<b>Estadístico ADF:</b>	-9.1393	1%	-3.4865
<b>p-valor:</b>	0.0000	5%	-2.8862
		10%	-2.5799

Para identificar la presencia de correlaciones significativas entre los rezagos de la serie temporal se analizó la función de autocorrelación total (ACF), la cual permite observar el comportamiento de los picos de autocorrelación a distintos rezagos. Los resultados obtenidos muestran que no existe una autocorrelación entre una observación y sus rezagos, lo que indicaría que no existe una media móvil (MA) por lo tanto el componente  $q$  es de 0, como se muestra en la figura 9.



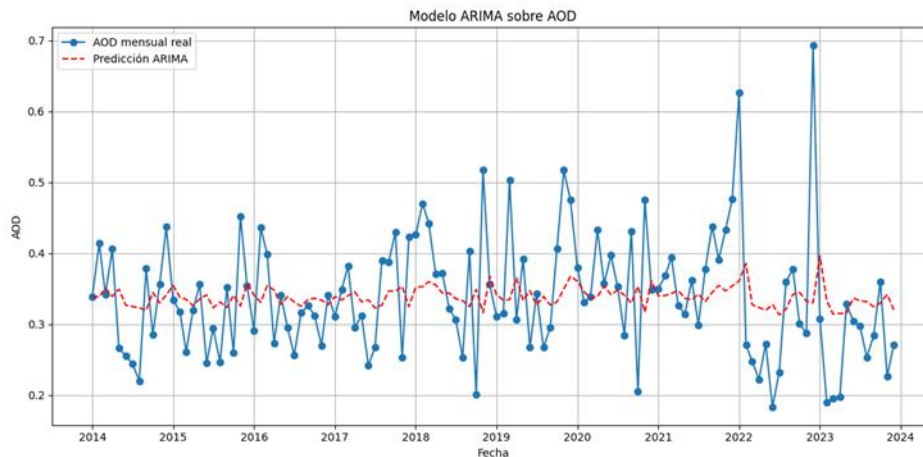
**Fig. 9-** Función de autocorrelación total (ACF) de POA

No obstante, el análisis del coeficiente de covarianza, calculado mediante el producto externo de gradientes en el software EViews 12, indica que los términos de constante ( $C$ ) y autorregresivo ( $AR$ ) presentan una significancia estadística adecuada, como se evidencia en la tabla 4. En consecuencia, se sugiere la aplicación de un modelo  $ARIMA(1,0,0)$ , dado que la serie ya ha sido confirmada como estacionaria y la inclusión de un componente de media móvil ( $MA$ ) podría introducir distorsiones en el ajuste del modelo.

**Tabla 4-** Resultado del análisis del coeficiente de covarianza.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.338304	0.010566	32.01923	0.0000
AR (1)	0.162947	0.078358	2.079535	0.0398
SIGMASQ	0.007111	0.000727	9.782042	0.0000

Por temas prácticos se seleccionó el modelo ARIMA (1,0,0) para la predicción del comportamiento del POA en el área de almacenamiento de concentrado de cobre, en donde no se observa un incremento significativo en los niveles de POA durante la mayor parte del período analizado. Sin embargo, se identifica un aumento no significativo en las concentraciones de POA entre los años 2020 y 2022, en comparación con los valores esperados según la predicción del modelo ARIMA. Posteriormente, los niveles de POA regresan a sus valores normales, lo que sugiere una anomalía transitoria sin una tendencia sostenida como se representa en la figura 10.



**Fig. 11-** Regresión lineal entre Exportación de cobre y POA

- Correlación y significancia (Pearson)

De manera similar, el coeficiente de correlación de Spearman, utilizado para evaluar relaciones monótonas en series temporales, fue de  $-0.096$ , lo que también indica una correlación prácticamente nula. Esta interpretación es consistente con el valor p obtenido (0.2985), que respalda la inexistencia de una relación monótona entre las variables analizadas representadas en la tabla 5.

**Tabla 5-** Matriz de correlación y significancia (Pearson).

	POA	Exportación	Significancia	N
POA	1	-0.010	-	120
Exportación	-0.010	1	P=0.9155	120

## 4. DISCUSIÓN

El análisis estadístico de la serie temporal del POA se la realizó con diferentes modelos, siendo el primero la regresión segmentada, que permite identificar cambios de tendencia través del tiempo. El análisis de la regresión segmentada indica que no existe un punto de quiebre y por lo tanto señala una continuidad sin cambios de tendencia significativos. Cuando no se detecta cambio significativo se asume que la relación entre las variables permanece constante a lo largo del tiempo analizado [11]. La estabilidad relativa de los datos de POA puede atribuirse a la constancia de las condiciones normales atmosféricas, en contraste, si bien no ocurren cambios abruptos, sí existen variaciones considerables para los cuales se implementa otro enfoque como el modelo ARIMA.

La modelación con el método ARIMA se empleó para analizar la variación mensual de datos, evidenciando características de estacionariedad, ya que no se identificaron patrones de autocorrelación en la serie temporal. Esto sugiere que las fluctuaciones observadas entre los valores no responden a un patrón sistemático, sino que corresponden a variaciones estacionarias independientes. En concordancia con el estudio realizado por [12] que empleó el modelo ARIMA, el autor lo utilizó para predecir datos futuros de evapotranspiración y modelar variables necesarias para el estudio. Con esto, demostrando su utilidad para pronosticar variables de interés, caracterizar datos temporales y comprender la distribución de esos datos a lo largo de una serie temporal.

El análisis para la regresión lineal no mostró una relación estadísticamente significativa entre las exportaciones de cobre y POA así que impide rechazar la hipótesis nula de no correlación con la pendiente casi nula, la correlación de Pearson ( $r = -0.010$ ) y el valor de  $p = 0.9155$  ( $p > 0.05$ ). Estos resultados se ajustan a lo que señala [13] ya que el aumento o disminución del POA se influncia más por factores meteorológicos como la altura de la capa límite, la temperatura, etc. mas no a la presencia de los concentrados de cobre.

La detección de cambios en el comportamiento de la profundidad óptica de aerosoles resulta una técnica útil para obtener datos de la calidad ambiental, especialmente en regiones donde no existen sistemas de vigilancia permanente. En el presente estudio, se utilizó el producto satelital MCD19A2 que detecta la profundidad óptica de aerosol en una resolución espacial de 1 km. En comparación, otros productos como el MOD04\_3k que utiliza el algoritmo de aerosoles Dark Target (DT) con una resolución espacial de 3 km [14], presenta limitaciones frente al producto MCD19A2. Este último, al integrar observaciones simultáneas de los sensores a bordo de los satélites Terra y Aqua, permite un control más riguroso de la calidad de los datos y una mayor densidad de observaciones, lo que se traduce en una mejora significativa en la precisión espacial. Además, su resolución más detallada facilita la vigilancia de áreas de menor extensión, optimizando la estimación de la profundidad óptica de aerosoles (POA) en regiones con escasa cobertura de vigilancia terrestre.

En el estudio de [14] realizado en Shandong en China se utilizó el producto MOD04\_3k en el que presenta ciertas limitaciones, especialmente en las áreas con superficies brillantes o presencia frecuente de nubosidad, lo que genera errores en la detección precisa de aerosoles. Por consiguiente, el estudio reporta una marcada variabilidad estacional, con una mayor concentración de aerosoles en primavera y verano, y una disminución significativa en otoño e invierno. En contraste, en Ecuador no se observa esta variabilidad estacional pronunciada. A pesar de contar con una estación invernal, las condiciones climáticas no afectan la detección de aerosoles.

Para la estimación del material particulado PM<sub>2,5</sub> a partir de la profundidad óptica de aerosoles (POA) en el estudio realizado por [15] señala varias metodologías como los modelos de regresión estadística, la regresión lineal múltiple [16], el modelo de regresión ponderada geográficamente (GWR), la regresión de ponderación espaciotemporal geográfica y el modelo lineal de efectos mixtos. Siendo eficaces de estimar la cantidad de material particulado en el ambiente, sin embargo, el autor señala que presentan limitaciones importantes, especialmente al abordar la influencia de factores meteorológicos y características superficiales sobre la distribución del PM<sub>2,5</sub>. De este modo, presenta un método que soluciona estas dificultades a través del aprendizaje automático (*machine learning*).

El método empleado por [15] requiere una densa red de vigilancia permanente para su calibración y validación, el autor se apoya en una red de 775 estaciones de medición de PM<sub>2.5</sub>. Esto podría limitar su aplicabilidad en regiones con escasa infraestructura de vigilancia. Sin embargo, el estudio deja como dato válido el POA para estimar el material particulado y siempre dependiendo de variables atmosféricas y geomorfológicas que pueden alterar esta correlación.

Como se señalaba anteriormente, el POA es un dato válido para tener un registro de la carga de aerosoles y la estimación posterior del PM<sub>2.5</sub>, ya que el POA sirve para representar la presencia de aerosoles en la atmósfera, y con ello se puede correlacionar con las concentraciones de las partículas en suspensión. Para mejorar esta relación es necesario ajustar el POA con factores meteorológicos como la humedad relativa, temperatura y la presión atmosférica [17]. De este modo, el POA se caracteriza por considerarse como una herramienta estratégica para el análisis multitemporal y espacial en países en vía de desarrollo, siempre y cuando se tomen en cuenta las limitaciones que conlleva y se utilicen productos satelitales que puedan validarse y ajustarse con un buen filtro.

En presente estudio se enmarca la relevancia del comportamiento espacio-temporal del aerosol a partir de datos satelitales, sin embargo, también señala que se ve restringido por no disponer datos in situ de PM<sub>2.5</sub>. Esta falta de vigilancia en campo presenta limitaciones ya que impide validar y estimar valores reales del PM<sub>2.5</sub>. A pesar de la rigurosidad de la depuración de los datos satelitales, realmente no se puede expresar con objetividad sobre las estimaciones de este aerosol y con el análisis de la serie temporal se reduce a un plano cualitativo más no cuantitativo, de esta forma no se puede señalar numéricamente la dimensión del impacto.

El riguroso filtrado del POA para recopilar los datos mediante Google Earth Engine demuestra la minuciosidad en la selección de la información a analizar. Este proceso permite recopilar el POA sin ninguna alteración externa como la presencia de nubes que elevaría los niveles de POA. De esta manera, se obtiene una base de datos sólidos para que el análisis multitemporal sea más confiable y refuerce su validez en los resultados obtenidos para relacionarlos con la exportación de cobre y determinar su influencia.

El PM<sub>2.5</sub> es un contaminante perjudicial para el medio ambiente por su naturaleza higroscópica ya que este aerosol en altas condiciones de humedad absorbe el vapor de agua, incrementando su tamaño e interfiriendo en la recopilación de datos la profundidad óptica de aerosoles desde satélites. Entonces, al momento de obtener datos de POA los valores pueden estar sobreestimados sin necesidad de que haya un incremento en la cantidad de sus partículas [18]. Este fenómeno se traduce en la reducción de la visibilidad del área urbana o zona de interés que se quiere muestrear, especialmente cuando la humedad relativa supera el 60-80% [19].

Por otro lado, en temporadas secas, el PM<sub>2.5</sub> se dispersa con más facilidad por presentar un clima seco, esto prolonga el tiempo en el que se mantiene en suspensión y se transporta con más facilidad hacia otras zonas distantes. Con este clima, no ocurre el efecto llamado “wet deposition” o la deposición de los aerosoles por efecto de la lluvia incrementando las concentraciones de PM<sub>2.5</sub> [20]. Esto se evidencia en distintas regiones secas donde existen aumentos entre 2% y 15% en concentraciones de sulfatos y polvo fino [20]. En el caso del presente estudio el punto de muestreo analizado puede estar influenciado por esta característica de la estación seca y su dinámica con este contaminante, principalmente en los picos altos que presenta los meses finales de los años muestreados, específicamente de mayo a diciembre.

Otras variables meteorológicas también influyen en la concentración de PM<sub>2.5</sub> tales como la velocidad y dirección del viento o la temperatura. Por ejemplo, las capas térmicas no permiten que el contaminante ascienda y se disperse, manteniendo el aerosol al nivel del suelo, mientras que con vientos fuertes favorecen a la dispersión de estos. Los aerosoles en altos niveles de humedad favorecen a reacciones fotoquímicas para la conducción hacia nuevos aerosoles secundarios, incrementando fuertemente la carga de PM 2.5 [18].

## 5. CONCLUSIONES

El comportamiento del material particulado en zonas portuarias está determinado por la interacción de factores atmosféricos, geográficos y antrópicos, lo que impide atribuirlo de manera exclusiva a las actividades de exportación de concentrado de cobre. Esta complejidad resalta la necesidad de fortalecer la investigación científica para desentrañar las contribuciones relativas de cada factor y su incidencia en la calidad del aire.

En el presente estudio se analizó la influencia de las exportaciones de concentrado de cobre sobre la concentración de aerosoles, utilizando datos satelitales de POA del producto MCD19A2 de MODIS como sustituto de las mediciones in situ, ausentes en la zona de Puerto Bolívar. La depuración rigurosa de los datos en los sectores, mediante filtrado de nubes con la banda POA\_QA, garantizó una serie de datos confiable para el periodo 2014–2024.

La aplicación de la prueba ADF muestra un estadístico de -9,1393 y un p de 0,000 confirmó la estacionariedad de las series temporales de POA, sin evidencia de una tendencia ascendente o descendente clara. Estos resultados se reforzaron mediante la regresión segmentada y el modelo ARIMA, que no identificaron rupturas significativas ni cambios de régimen en los nueve sectores estudiados. Asimismo, la regresión lineal entre los volúmenes exportados y el POA arrojó un coeficiente de Pearson de -0,010, indicando ausencia de correlación estadísticamente significativa.

En ausencia de estaciones de vigilancia atmosférico permanente, la teledetección demostró ser una herramienta complementaria válida para evaluar la calidad del aire, especialmente en regiones con recursos limitados. La integración futura de datos satelitales y mediciones de campo permitirá modelar con mayor precisión la distribución del material particulado y diseñar estrategias de vigilancia ambiental más eficientes.

1. M. A. Aman, M. S. Salman, and A. P. Yunus, "COVID-19 and its impact on environment: Improved pollution levels during the lockdown period – A case from Ahmedabad, India," *Remote Sens Appl*, vol. 20, Nov. 2020, doi: <https://doi.org/10.1016/j.rsase.2020.100382>
2. A. Chudnovsky, C. Tang, A. Lyapustin, Y. Wang, J. Schwartz, and P. Koutrakis, "A critical assessment of high-resolution aerosol optical depth retrievals for fine particulate matter predictions," *Atmos Chem Phys*, vol. 13, no. 21, pp. 10907–10917, 2013, doi: <https://doi.org/10.5194/acp-13-10907-2013>
3. S. M. Agudelo-Londoño, L. C. Blanco-Becerra, M. R. Hernández, Z. B. Suárez-Morales, L. C. Mantilla-León, and N. Solís, "Injusticia ambiental en la calidad del aire para repartidores de plataformas digitales de Bogotá, Colombia, 2021," *Biomedica*, vol. 44, no. 3, pp. 391–401, Aug. 2024, doi: <https://doi.org/10.7705/biomedica.7162>
4. M. Sorek-Hamer et al., "A Deep Learning Approach for Meter-Scale Air Quality Estimation in Urban Environments Using Very High-Spatial-Resolution Satellite Imagery," *Atmosphere (Basel)*, vol. 13, no. 5, May 2022, doi: <https://doi.org/10.3390/atmos13050696>
5. U. Fierro and C. Villacres, "DIAGNÓSTICO DE LA CADENA LOGÍSTICA DE EXPORTACIÓN DEL BANANO ECUATORIANO HACIA ESTADOS UNIDOS DE AMÉRICA\*," vol. 9(1), pp. 77–90, Jan. 2014, doi: <https://doi.org/10.18041/2382-3240/saber.2014v9n1.1985>
6. G. G. Fogelbach et al., "Contaminacion atmosferica em America Latina: impacto em la salu Y regulacion actual: reporte de grupo de Comité de Aerobiologia Sociedad Latinoamericana de Asma, Alergia e Inmunologia," *Arquivos de Asmas Alergia e Inmunologia*, vol. 4, no. 4, 2020, doi: <https://doi.org/10.5935/2526-5393.20200064>
7. D. C. Husaini, K. Reneau, and D. Balam, "Air pollution and public health in Latin America and the Caribbean (LAC): a systematic review with meta-analysis," Dec. 01, 2022, Springer Science and Business Media Deutschland GmbH. doi: <https://doi.org/10.1186/s43088-022-00305-0>
8. D. Toscano, "The Impact of Shipping on Air Quality in the Port Cities of the Mediterranean Area: A Review," Jul. 21, 2023, Multidisciplinary Digital Publishing Institute (MDPI). doi: <https://doi.org/10.3390/atmos14071180>
9. K. S. Barros, V. S. Vielmo, B. G. Moreno, G. Riveros, G. Cifuentes, and A. M. Bernardes, "Chemical Composition Data of the Main Stages of Copper Production from Sulfide Minerals in Chile: A Review to Assist Circular Economy Studies," Feb. 01, 2022, MDPI. doi: <https://doi.org/10.3390/min12020250>
10. A. Lyapustin and Y. Wang, "MODIS Multi-Angle Implementation of Atmospheric Correction (MAIAC) Data User's Guide," [https://lpdaac.usgs.gov/documents/1500/MCD19\\_User\\_Guide\\_V61.pdf](https://lpdaac.usgs.gov/documents/1500/MCD19_User_Guide_V61.pdf)
11. V. M. R. Muggeo, "Estimating regression models with unknown break-points," *Stat Med*, vol. 22, no. 19, pp. 3055–3071, Oct. 2003, doi: <https://doi.org/10.1002/sim.1545>
12. M. Phesa, N. Mbatha, and A. Ikudayisi, "MODIS Evapotranspiration Forecasting Using ARIMA and ANN Approach at a Water-Stressed Irrigation Scheme in South Africa," *Hydrology*, vol. 11, no. 10, Oct. 2024, doi: <https://doi.org/10.3390/hydrology11100176>
13. M. Sorek-Hamer, R. Chatfield, and Y. Liu, "Review: Strategies for using satellite-based products in modeling PM2.5 and short-term pollution episodes," Nov. 01, 2020, Elsevier Ltd. doi: <https://doi.org/10.1016/j.envint.2020.106057>
14. S. Meng et al., "Research on the Spatiotemporal Variation Characteristics of Different Aerosol Types and Aerosol Optical Depth Based on MODIS Data," *Aerosol Air Qual Res*, vol. 24, no. 12, Dec. 2024, doi: <https://doi.org/10.4209/aaqr.240027>
15. Z. Tian, J. Wei, and Z. Li, "How Important Is Satellite-Retrieved Aerosol Optical Depth in Deriving Surface PM2.5 Using Machine Learning?," *Remote Sens (Basel)*, vol. 15, no. 15, Aug. 2023, doi: <https://doi.org/10.3390/rs15153780>
16. P. Gupta and S. A. Christopher, "Particulate matter air quality assessment using integrated surface, satellite, and meteorological products: Multiple regression approach," *Journal of Geophysical Research Atmospheres*, vol. 114, no. 14, Jul. 2009, doi: <https://doi.org/10.1029/2008JD011496>
17. A. Van Donkelaar, R. V. Martin, M. Brauer, and B. L. Boys, "Use of satellite observations for long-term exposure assessment of global concentrations of fine particulate matter," *Environ Health Perspect*, vol. 123, no. 2, pp. 135–143, 2015, doi: <https://doi.org/10.1289/ehp.1408646>
18. E. Zender-Świercz, B. Galiszewska, M. Telejko, and M. Starzomska, "The effect of temperature and humidity of air on the concentration of particulate matter - PM2.5 and PM10," *Atmos Res*, vol. 312, Dec. 2024, doi: <https://doi.org/10.1016/j.atmosres.2024.107733>
19. X. Sun, T. Zhao, D. Liu, S. Gong, J. Xu, and X. Ma, "Quantifying the influences of PM2.5 and relative humidity on change of atmospheric visibility over recent winters in an urban area of East China," *Atmosphere (Basel)*, vol. 11, no. 5, May 2020, doi: <https://doi.org/10.3390/ATMOS11050461>
20. Y. Wang, Y. Xie, W. Dong, Y. Ming, J. Wang, and L. Shen, "Adverse effects of increasing drought on air quality via natural processes," *Atmos Chem Phys*, vol. 17, no. 20, pp. 12827–12843, Oct. 2017, doi: <https://doi.org/10.5194/acp-17-12827-2017>