



Universidad Autónoma del Estado de México



Facultad de Economía

**Análisis de los Niveles de Ozono Troposférico ( $O_3$ ) en la Ciudad de México durante 2020: Impacto de la Emergencia Sanitaria por COVID-19 en el Medio Ambiente.**

Tesis para obtener el título de Licenciado en Actuaría

Presenta:

Leyva García Rojas José Antonio.

Asesor:

Dr. En E.P. Daniel Lozano Keymolen

Septiembre 2024

# Índice

<b>Índice de Gráficos y Tablas</b> .....	<b>IV</b>
<b>Introducción</b> .....	<b>1</b>
El problema de investigación .....	4
Preguntas de investigación .....	6
Objetivos de investigación.....	6
Objetivos específicos .....	6
Hipótesis de investigación .....	7
La importancia de los pronósticos de ozono troposférico .....	7
<b>Capítulo 1. Marco Teórico: El Ozono Troposférico y la pandemia por COVID-19</b> ....	<b>10</b>
1.1 Introducción.....	10
1.2 Definición y relaciones económicas y de la salud del Ozono Troposférico .....	11
1.2.1 Ozono Troposférico y la Economía .....	12
1.2.2 Ozono Troposférico y la Salud.....	13
1.3 Implicaciones Sociales, Económicas y de la Salud de la contingencia sanitaria por COVID-19	15
1.3.1 Implicaciones sociales.....	16
1.3.2 Implicaciones Económicas .....	18
1.3.3 Implicaciones en la Salud.....	22
1.4 Conclusiones del capítulo.....	24
<b>Capítulo 2. Discusión: El Ozono Troposférico en la Ciudad de México</b> .....	<b>26</b>
2.1 Introducción al capítulo .....	26
2.2 El análisis del Ozono Troposférico en México y en la Ciudad de México .....	26
2.3 El Ozono Troposférico en el contexto de la pandemia por COVID-19.....	28
2.4 Conclusiones del capítulo.....	31
<b>Capítulo 3. Metodología de investigación</b> .....	<b>32</b>
3.1 Introducción al Capítulo .....	32
3.2 Fuente de Datos .....	32
3.3 Conceptos Necesarios para definir la Metodología .....	33
3.4 Técnicas de Estimación.....	36
3.4.1 Procesos ARMA.....	36

3.4.1.1	Procesos Autorregresivos .....	36
3.4.1.2	Procesos Medias Móviles.....	39
3.4.1.3	Procesos Autorregresivos y de Medias Móviles .....	41
3.4.2	Procesos ARIMA.....	42
3.4.2.1	Procesos Autorregresivos Integrados.....	43
3.4.2.2	Procesos Autorregresivos Integrados y de Medias Móviles .....	43
3.4.3	Componente estacional en una ecuación ARMA o ARIMA .....	45
3.4.4	Evaluación de ecuaciones de pronóstico .....	46
3.4.4.1	Criterios bayesianos de evaluación.....	46
a)	Criterio Bayesiano de Ajuste de Akaike (AIC).....	46
b)	Criterio Bayesiano de Ajuste de Schwartz (BIC).....	47
3.4.4.2	Análisis de residuos de la ecuación.....	48
3.5	Aplicación de la metodología propuesta .....	51
3.5.1	Aplicación de la metodología propuesta al Conjunto de Datos 1.....	51
3.5.2	Aplicación de la metodología propuesta al Conjunto de Datos 2.....	52
3.6	Justificación de la Selección de la Metodología ARIMA.....	54
3.7	Conclusiones del capítulo.....	56
<b>Capítulo 4. Análisis de los Niveles de Ozono Troposférico en la Ciudad de México durante 2020.....</b>		<b>58</b>
4.1	Introducción al capítulo .....	58
4.2	Metodología: Modelo Box-Jenkins.....	58
4.2.1	Metodología Box-Jenkins: Conjunto de Datos 1.....	59
4.2.1.1	Análisis de la ecuación de Pronóstico: Conjunto de Datos 1.....	62
4.2.2.1	Estacionariedad del Proceso: Conjunto de Datos 1.....	63
a)	Análisis de Autocorrelación no estacional: Conjunto de Datos 1.....	64
b)	Análisis de Autocorrelación estacional: Conjunto de Datos 1.....	66
c)	Pruebas de Estacionariedad en el proceso con Estacionalidad: Conjunto de Datos 1.....	68
4.2.1.2	Polinomios Autorregresivos Estacionales e Integrados: Conjunto de Datos 1.....	70
4.2.1.3	Análisis de Residuos de la Ecuación de Pronóstico .....	72
4.2.1.4.	Pronósticos de las concentraciones de ozono troposférico: Datos 1.....	75
4.2.1.4.1	Análisis de los pronósticos .....	75
4.2.1.5.	Comparación del Pronóstico del Conjunto de Datos 1 con los datos de 2020 en la Emergencia Sanitaria. ....	77
4.2.1.6	Comparación del Pronóstico con los datos de 2020 y los límites para la Salud: Datos 1.....	79

4.2.2 Metodología Box-Jenkins: Conjunto de Datos 2.....	81
4.2.2.1 Análisis de la ecuación de Pronóstico: Conjunto de Datos 2.....	82
4.2.2.2 Estacionariedad del Proceso: Conjunto de Datos 2.....	83
a) Análisis de Autocorrelación no estacional: Conjunto de Datos 2.....	84
b) Análisis de Autocorrelación estacional: Conjunto de Datos 2.....	84
c) Pruebas de Estacionariedad en el proceso con Estacionalidad: Conjunto de Datos 2.....	84
4.2.2.3 Polinomios Autorregresivos Estacionales e Integrados: Conjunto de Datos 2.....	85
4.2.2.4. Análisis de Residuos de la Ecuación de Pronóstico: Conjunto de Datos 2.....	87
4.2.2.5 Pronósticos de las concentraciones de ozono troposférico: Conjunto de Datos 2.....	88
4.3 Conclusiones del capítulo.....	90
<b>Capítulo 5: Discusión y Conclusiones.....</b>	<b>93</b>
5.1 Discusión con la Bibliografía Seleccionada.....	93
5.1.1 Discusión con la Bibliografía Seleccionada en aspectos Sociales.....	96
5.1.2 Discusión con la Bibliografía Seleccionada en aspectos de Salud.....	96
5.1.3 Discusión con la Bibliografía Seleccionada en aspectos Económicos.....	97
5.2 Contribución al conocimiento.....	98
5.3 Implicaciones para las políticas públicas.....	98
5.4 Recomendaciones para futuras investigaciones.....	99
5.5 Reflexión sobre las limitaciones del estudio.....	99
5.6 Cierre reflexivo.....	100
<b>Bibliografía.....</b>	<b>101</b>

## Índice de Gráficos y Tablas

Gráfico 2.1 Concentraciones normales de ozono y climatología de la temperatura y la humedad para el periodo de 1996 a 2019 comparada con la irradiación solar potencial media mensual. ..	27
Gráfico 4.1 Evolución de la serie de tiempo: Conjunto de Datos 1.....	60
Gráfico 4.2 Descomposición Aditiva: Conjunto de Datos 1.....	61
Tabla 4.1 Pruebas de Estacionariedad en la Serie de Tiempo: Conjunto de Datos 1.....	63
Gráfico 4.4 Correlogramas de Autocorrelación Simple y Parcial: Conjunto de Datos 1.....	65
Gráfico 4.5 Autocorrelación Simple y Parcial con Diferencias Estacionales: Conjunto de Datos 1 .	67
Tabla 4.2 Pruebas en la Serie de Tiempo tras diferencias Estacionales: Conjunto de Datos 1.....	68
Tabla 4.3 Comparación de las Ecuaciones Pronóstico: Datos 1.....	71
Tabla 4.4 Pruebas de las Ecuaciones Pronóstico: Datos 1. ....	73
Tabla 4.5 Pruebas de las Ecuación SARMA (1,0,2)(0,0,1)e: Datos 1. ....	74
Fuente: Elaboración propia. ....	74
Tabla 4.6 Pronóstico de las Ecuación SARMA (1,0,2) (0,0,1)e: Conjunto de Datos 1.....	75
Gráfico 4.6 Pronóstico de las Ecuación SARMA (1,0,2)(0,0,1)e: Datos 1. ....	76
Tabla 4.7 Análisis del Pronóstico de las Ecuación: Datos 1.....	77
Gráfico 4.7 Comparación del pronóstico y los datos captados en 2020 contra la medida recomendada de Salud: Conjunto de Datos 1. ....	80
Gráfico 4.8 Evolución de la serie de tiempo: Conjunto de Datos 2.....	82
Gráfico 4.9 Análisis de Autocorrelación Estacional y no estacional: Conjunto de Datos 2. ....	83
Tabla 4.8 Pruebas de las Ecuaciones Pronóstico: Datos 2. ....	86
Gráfico 4.10 Análisis de Residuos del Modelo ARIMA(3,0,1)(1,0,1): Conjunto de Datos 2.....	88
Gráfico 4.11 Pronóstico de la ecuación ARIMA(3,0,1)(1,0,1): Conjunto de Datos 2.....	89

## Introducción

El ozono troposférico ( $O_3$ ) es un gas compuesto por tres átomos de oxígeno presente en la troposfera, la capa más baja de la atmósfera. A diferencia del ozono estratosférico, que protege la Tierra de la radiación ultravioleta, el  $O_3$  es un contaminante atmosférico secundario (OMS, 2022). Este compuesto se forma a partir de reacciones químicas complejas entre los óxidos de nitrógeno ( $NO_x$ ) y los compuestos orgánicos volátiles ( $COV$ ) en presencia de luz solar, por lo que reducir las emisiones de  $NO_x$  y  $COV$  es fundamental para disminuir la formación de  $O_3$  y sus impactos negativos. De acuerdo con la Comisión Europea (2008), se determinan estándares de calidad del aire en los cuales la concentración de  $O_3$  no debe superar los  $110 \mu\text{g}/\text{m}^3$  ( $0.051\text{ppm}$ ) en los promedios de 8 horas (Comisión Europea, 2008).

Los precursores del  $O_3$ ,  $NO_x$  y  $COV$ , se originan tanto de fuentes naturales como antropogénicas. Los relámpagos, incendios forestales y emisiones de la vegetación son ejemplos de fuentes naturales, mientras que las emisiones vehiculares, los procesos industriales, las centrales eléctricas y el uso de solventes y pinturas son ejemplos de fuentes antropogénicas. La formación de  $O_3$  está influenciada por diversos factores, como la intensidad de la luz solar, la temperatura y la concentración específica de  $NO_x$  y  $COV$ , especialmente en altas temperaturas y sequías (Portal Ambiental de Andalucía, 2020).

El  $O_3$  desempeña un papel dual en el medio ambiente. En concentraciones bajas, actúa como un purificador natural del aire al eliminar contaminantes como el monóxido de carbono y ciertos  $COV$ . Sin embargo, en altas concentraciones, se convierte en un contaminante perjudicial para la salud humana, animal y vegetal, causando problemas respiratorios, daños a los cultivos y alteraciones en los ecosistemas. Se ha documentado que estos compuestos ocasionan daños pulmonares que desencadenan en asma o en disminución de las funciones pulmonares, así como el desarrollo de enfermedades respiratorias de importancia (OMS, 2008). Sin embargo, estas

afecciones respiratorias son solo una parte del impacto total en la salud humana (Kim et al., 2020).

Además de los problemas respiratorios directos, el  $O_3$  puede alterar la función cardiovascular, lo que contribuye a un aumento en las hospitalizaciones, el absentismo escolar y laboral, y el consumo de medicamentos. Estos efectos no solo afectan la calidad de vida de las personas, sino que también tienen un impacto económico significativo debido a los costos médicos y la pérdida de productividad (U.S. Environmental Protection Agency, 2013). Además, la exposición prolongada a  $O_3$  contribuye al aumento de los riesgos de mortalidad prematura (Zhang et al., 2019; Hua et al., 2024) o, incluso al desarrollo de accidentes cerebrovasculares (Observatorio Europeo del Clima y la Salud, 2023).

En resumen, el  $O_3$  representa una amenaza significativa para la salud humana, con efectos que van desde problemas respiratorios agudos hasta enfermedades crónicas y mortalidad prematura. Sin embargo, el  $O_3$  afecta de manera diferencial a las personas ya que los grupos de población más vulnerables a los efectos del gas se constituyen por los niños y las personas de edades avanzadas (Centro Nacional de Prevención de Desastres, 2019).

El  $O_3$  también impacta negativamente en el medio ambiente ya que actúa como un gas de efecto invernadero, contribuyendo al calentamiento global al atrapar el calor en la atmósfera. Además, daña los tejidos vegetales, afectando el crecimiento de las plantas y su capacidad para absorber dióxido de carbono actuando como un contaminante que puede tener serios efectos negativos en la agricultura y los ecosistemas (Li et al., 2019).

En la agricultura el " $O_3$  es un oxidante fuerte que tiene efectos adversos en la agricultura, perjudicando la salud de las plantas y disminuyendo los rendimientos de los cultivos" (Coalición Clima y Aire Limpio, sf). Entre las principales consecuencias sobre la agricultura y la vida vegetal se encuentran (Bergmann et al., 2016):

- Daño Foliar: El ozono puede causar manchas, decoloración y necrosis en las hojas de las plantas, dificultando la fotosíntesis y señalando estrés en las plantas.
- Reducción del Crecimiento: Las plantas expuestas a niveles altos de ozono pueden mostrar un crecimiento reducido debido a la interferencia del ozono en su capacidad para producir y almacenar energía.
- Disminución del Rendimiento: Los cultivos sometidos a concentraciones elevadas de ozono suelen tener rendimientos más bajos. Por ejemplo, el trigo, la soja y el maíz pueden ver reducidas sus cosechas debido al daño por ozono.
- Calidad del Producto: No solo la cantidad, sino también la calidad de los productos agrícolas puede verse afectada. Frutas y verduras pueden presentar una apariencia menos atractiva y menor contenido nutricional en condiciones de alto ozono.

El ozono a nivel de suelo también afecta significativamente a los ecosistemas naturales, con consecuencias como:

- Biodiversidad Vegetal: El ozono puede afectar a diferentes especies de plantas de manera diversa, alterando la composición de las comunidades vegetales. Las especies más sensibles pueden disminuir, mientras que las más resistentes pueden proliferar, alterando el equilibrio del ecosistema.
- Cadenas Tróficas: Los cambios en la salud y composición de las plantas pueden afectar toda la cadena trófica. La reducción en la calidad y cantidad de las plantas puede influir en los herbívoros y, a su vez, en los depredadores que se alimentan de ellos.
- Ecosistemas Forestales: Los bosques son particularmente vulnerables al  $O_3$ . Árboles jóvenes y especies sensibles pueden sufrir daños en las hojas y crecimiento reducido, afectando la estructura y función del bosque a largo plazo.
- Ciclos Biogeoquímicos: El ozono puede alterar los ciclos de nutrientes y agua en los ecosistemas. Al dañar las plantas, el ozono puede afectar la absorción de agua y nutrientes, con efectos en cadena en el suelo y otros organismos del ecosistema.

Para mitigar la formación de  $O_3$  y sus efectos negativos, es crucial reducir las emisiones de  $NO_x$  y  $COV$  provenientes de diversas fuentes, como el transporte, la industria y la generación de energía. La educación pública sobre los riesgos para la salud asociados con la exposición al ozono y la promoción de la conciencia sobre la calidad del aire son fundamentales para fomentar cambios de comportamiento a nivel individual y minimizar las actividades que generan  $O_3$ .

La Ciudad de México (CDMX) ha tratado de impartir regulaciones más estrictas, la adopción de tecnologías más limpias y la promoción de fuentes de energía alternativas son estrategias clave para lograr este objetivo. Además, fomentar prácticas urbanísticas sostenibles, como el transporte público, la creación de ciudades peatonales y la expansión de áreas verdes urbanas, puede contribuir a reducir la congestión del tráfico y, por ende, las emisiones de  $COV$ . Según el propio Gobierno de la CDMX: “Las principales fuentes de emisión de los  $NO_x$  y  $COV$  son los vehículos que utilizan combustibles fósiles, fugas de gas LP y gas natural, las industrias y las estaciones de gasolina” (Gobierno de la CDMX, Julio 2019).

### **El problema de investigación**

La CDMX, siendo una de las áreas urbanas más grandes y densamente pobladas a nivel global, “en el censo de 2020 fueron contadas más de 9.2 millones de habitantes (INEGI, 2020)”, por lo que enfrenta un desafío persistente en cuanto a la calidad del aire. Entre los diversos contaminantes presentes en su atmósfera, el  $O_3$  se ha identificado como un factor determinante en la mala calidad del aire, generando preocupación por sus efectos en la salud humana y en el medio ambiente.

Sin embargo, existen factores que agravan la problemática de la concentración de  $O_3$  en la Ciudad de México:

- **Altitud:** La ubicación geográfica de la CDMX, a una altitud de más de 2.2 mil metros sobre el nivel del mar, intensifica la radiación solar, lo cual propicia la formación de

contaminantes y específicamente  $O_3$  al acelerar las reacciones entre los precursores de este contaminante.

- Topografía: La cuenca en la que se asienta la Ciudad actúa como una barrera natural que dificulta la dispersión de los contaminantes atmosféricos, incluyendo el ozono. Esta conformación geográfica favorece la acumulación de contaminantes y, por ende, el incremento de las concentraciones de ozono en el aire.
- Tráfico vehicular: La alta densidad de vehículos de combustión y la congestión vial crónica en la CDMX generan una emisión considerable de  $NO_x$  y  $COV$ , precursores fundamentales en la formación del  $O_3$ .
- Actividad industrial: Las emisiones provenientes de la actividad industrial en la zona metropolitana, con emisiones elevadas de  $NO_x$  y  $COV$ , contribuyen de forma significativa a la generación de ozono en la troposfera.

Es importante destacar que estos factores interactúan de manera sinérgica, amplificando el problema de la contaminación por ozono en la CDMX. La combinación de una altitud elevada, una topografía desfavorable, un parque vehicular extenso y una actividad industrial considerable crea un escenario propicio para la formación y acumulación de  $O_3$ .

La pandemia de COVID-19, declarada oficialmente en marzo de 2020, desencadenó una serie de medidas gubernamentales a nivel global para contener su propagación. En la CDMX, estas medidas incluyeron restricciones a la movilidad, cierre de comercios no esenciales y la promoción del teletrabajo, lo que condujo a una disminución drástica en la actividad humana y económica. El transporte, principal fuente de emisiones contaminantes de  $O_3$  en la ciudad, se vio significativamente reducido, al igual que la actividad industrial y comercial. Este escenario sin precedentes ofrece una oportunidad única para estudiar cómo la reducción abrupta de la actividad humana impacta los niveles de  $O_3$  en una de las áreas urbanas más grandes y contaminadas del mundo (Miyazaki et al., 2021; Stevenson et al., 2021).

En la CDMX, las medidas de confinamiento y restricciones para contener la propagación del coronavirus SARS-CoV-2 llevaron a una disminución significativa de la actividad económica, el transporte y la producción industrial. Este contexto plantea la pregunta sobre cómo estos cambios repentinos en la actividad humana y las emisiones contaminantes asociadas han afectado los niveles de  $O_3$  en la atmósfera de la CDMX durante el año 2020. La comprensión de estos efectos es crucial para evaluar el impacto del confinamiento de la pandemia del COVID-19 en la calidad de vida y del aire de la Ciudad.

### **Preguntas de investigación**

¿Cómo habría sido la concentración de  $O_3$  en la Ciudad de México en 2020 sin la emergencia sanitaria de COVID-19?

### **Objetivos de investigación**

Pronosticar la cantidad de  $O_3$  en la Ciudad de México en el 2020 en caso de que no se hubiera presentado la emergencia sanitaria causada por el COVID-19 y compararlos con la captación real.

### **Objetivos específicos**

- Investigar sobre el origen, crecimiento y repercusión de los niveles fuera de los parámetros recomendados de  $O_3$  en la Ciudad de México.
- Establecer una proyección a través de un modelo de la captación de  $O_3$  en la Ciudad de México.
- Determinar si el confinamiento afecta la concentración de  $O_3$  en la Ciudad de México.

## **Hipótesis de investigación**

El presente estudio tiene como hipótesis que, en forma comparativa con los años previos y posteriores al 2020, los niveles de  $O_3$  en la CDMX disminuyeron durante el período de confinamiento por la COVID-19 como efecto de las restricciones sociales y económicas. Así, las variaciones en la actividad humana y las emisiones contaminantes asociadas influyeron en la concentración de  $O_3$  en la atmósfera de la CDMX.

## **La importancia de los pronósticos de ozono troposférico**

La contaminación atmosférica es un problema ambiental global con graves consecuencias para la salud humana y el medio ambiente. La quema de combustibles fósiles, la industria, el transporte y la agricultura son fuentes principales de contaminantes que degradan la calidad del aire y contribuyen al cambio climático. Estos contaminantes no solo afectan la salud humana, sino que también dañan los cultivos, reducen la productividad agrícola y perturban los ecosistemas terrestres y acuáticos, poniendo en riesgo la seguridad alimentaria, la biodiversidad y el equilibrio ecológico (Wilkinson et al, 2012; Mukherjee et al., 2021).

La investigación científica sobre los efectos del ozono y otros contaminantes atmosféricos es fundamental para comprender sus mecanismos y desarrollar soluciones efectivas. La colaboración entre gobiernos, industrias, organizaciones y la sociedad en su conjunto es esencial para lograr un aire más limpio y proteger la salud de las generaciones presentes y futuras.

La calidad del aire en grandes áreas urbanas es un tema de creciente preocupación a nivel mundial. La CDMX, siendo una de las urbes más extensas y densamente pobladas, enfrenta retos significativos en cuanto a la contaminación atmosférica, donde la concentración de  $O_3$  juega un papel crucial. El año 2020, marcado por la pandemia de COVID-19 y las medidas de confinamiento implementadas para frenar su propagación, trajo consigo cambios drásticos en la actividad humana y las emisiones contaminantes a nivel global. En la CDMX, estos cambios se manifestaron en una

disminución considerable de la actividad industrial, el transporte y otras fuentes de emisión de  $O_3$ .

El análisis del impacto de la pandemia de COVID-19 en los niveles de  $O_3$  en la CDMX durante el año 2020 es fundamental por varias razones:

- Salud pública: La exposición al  $O_3$  se asocia con diversos problemas de salud, desde afecciones respiratorias hasta enfermedades cardiovasculares (Hua et al., 2024). Comprender cómo la disminución de la actividad humana durante la pandemia influyó en los niveles de  $O_3$  es esencial para evaluar su impacto en la salud pública y diseñar estrategias de mitigación efectivas.
- Medio ambiente: El  $O_3$  puede dañar los tejidos vegetales y afectar la biodiversidad. Investigar los cambios en los niveles de  $O_3$  durante la pandemia y sus posibles efectos en los ecosistemas urbanos y periurbanos contribuye a una mejor comprensión de la interacción entre la actividad humana y el medio ambiente.
- Política pública: Los resultados de esta investigación son valiosos para la toma de decisiones informadas y la formulación de políticas públicas que promuevan la mejora de la calidad del aire y protejan la salud en la CDMX y otras áreas urbanas afectadas por la contaminación.

La relevancia de este estudio radica en su potencial para comprender el impacto de las medidas de confinamiento en la calidad del aire y la salud de la población de la CDMX. Al analizar los cambios en los niveles de  $O_3$ , un contaminante con efectos adversos para la salud respiratoria y cardiovascular, se podrán evaluar los efectos a corto y largo plazo de la reducción de emisiones contaminantes durante la pandemia por COVID-19. Esta información es fundamental para diseñar estrategias de mitigación y prevención de enfermedades relacionadas con la contaminación atmosférica, especialmente en una Ciudad con una alta vulnerabilidad a los problemas respiratorios en la población.

Además, los resultados de esta investigación proporcionarán evidencia científica valiosa para la toma de decisiones en materia de políticas ambientales. Al identificar

cómo las diferentes actividades humanas contribuyen a la formación de ozono, se podrán diseñar políticas más efectivas y focalizadas para reducir las emisiones contaminantes y mejorar la calidad del aire en la CDMX. Esto incluye la promoción de fuentes de energía más limpias, la mejora del transporte público y la implementación de medidas para reducir las emisiones industriales y vehiculares.

Mediante el análisis comparativo de los niveles de  $O_3$  antes, durante y después del confinamiento por COVID-19 (establecido oficialmente en marzo de 2020), esta investigación busca generar información relevante para la formulación de políticas públicas destinadas a mitigar la contaminación atmosférica y proteger la salud pública en entornos urbanos altamente afectados, como la CDMX.

Una vez expuestos los fundamentos de esta investigación, el contenido de esta se desarrolla en cinco capítulos adicionales. En el Capítulo 1, se presentan los referentes conceptuales que sirven de guía al proyecto:  $O_3$  y COVID-19. Para el Capítulo 2, se exponen los antecedentes del objeto de investigación en cuanto a la revisión de bibliografía sobre el estudio del  $O_3$  y en específico, de las concentraciones de este en el contexto de la pandemia por COVID-19. En el Capítulo 3, se desarrolla la metodología del proyecto que se basa en el análisis bajo el enfoque de las Series de Tiempo y pronósticos probabilísticos. El Capítulo 4, resume los resultados de la investigación y, en el Capítulo 5, se construye una discusión sobre los resultados del proyecto.

# Capítulo 1. Marco Teórico: El Ozono Troposférico y la pandemia por COVID-19

## 1.1 Introducción

Este capítulo ofrece un marco conceptual para entender el comportamiento del  $O_3$  y sus implicaciones durante el año 2020, marcado por la Emergencia Sanitaria asociada al coronavirus SARS-CoV-2 que ocasiona la enfermedad COVID-19. Dado que esta investigación se basa en dos conceptos:  $O_3$  y la Emergencia Sanitaria dada por el COVID-19, se establece una relación indirecta, relacionada con restricciones y confinamientos que afectaron determinados factores sociales, de salud y económicos.

En el año 2020, la pandemia de COVID-19 y las medidas de confinamiento asociadas tuvieron un impacto sin precedentes en las actividades humanas y, por ende, en los niveles de contaminantes atmosféricos. La reducción drástica en el tráfico vehicular y la actividad industrial brindó una oportunidad única para observar cómo estos cambios influyen en las concentraciones de  $O_3$  en la Ciudad de México (CDMX). La importancia de este estudio radica en proporcionar una visión integral sobre cómo las actividades humanas y las políticas de control de la pandemia pueden influir en la calidad del aire. A través de esta comprensión, se pueden diseñar estrategias más efectivas para la gestión y reducción de la contaminación por  $O_3$ , contribuyendo a mejorar la salud pública y el bienestar ambiental en la CDMX y otras áreas urbanas o periurbanas.

El  $O_3$  es un contaminante atmosférico que ha captado la atención de científicos y autoridades debido a sus efectos adversos sobre la salud humana y el medio ambiente. Este compuesto se forma principalmente a través de reacciones químicas entre  $NO_x$  y  $COV$  en presencia de luz solar (IDEAM, s.f.). Las actividades humanas, especialmente en áreas urbanas e industriales, contribuyen significativamente a las emisiones de estos precursores, pues a partir del siglo XX las emisiones de este componente se han incrementado a nivel global. Sin embargo, y en conjunto con las actividades socioeconómicas humanas, otros factores como las características topográficas o las

influencias meteorológicas contribuyen a la formación y concentración de  $O_3$  (Nguyen et al., 2022).

La CDMX, una de las metrópolis más grandes y pobladas del mundo, ha experimentado niveles elevados de  $O_3$ , particularmente durante los meses de verano. La alta densidad de tráfico vehicular y la presencia de numerosas industrias agravan esta situación, llevando a la formación de este contaminante en concentraciones que superan frecuentemente los límites establecidos por las normas de calidad del aire (Ontiveros-Jiménez, 2019).

A continuación, se presenta la exposición conceptual del  $O_3$ , así como las relaciones y las consecuencias que este componente tiene con diversas actividades humanas. Luego, se presentan parte de las implicaciones en la economía y en la salud pública relacionadas con la pandemia por COVID-19.

## **1.2 Definición y relaciones económicas y de la salud del Ozono**

### **Troposférico**

Se ha definido que el  $O_3$  se forma principalmente a partir de reacciones entre  $NO_x$  y  $COV$  en presencia de luz solar, suelen ocurrir en áreas urbanas e industriales, donde las emisiones de  $NO_x$  y  $COV$  son altas debido al tráfico vehicular, la industria y otras actividades humanas (Ontiveros-Jiménez, 2019; Nguyen et al., 2022). El  $O_3$ , varía según la ubicación y las condiciones climáticas. Las concentraciones tienden a ser más altas en las áreas urbanas durante los meses de verano, cuando la radiación solar es más intensa. Este compuesto fue descubierto en 1840 el gas fue bautizado como "ozono" (el olor) por el químico Christian Friedrich Schönbein y puede llegar a ser explosivo en ciertas cantidades (Crutzen, 1988).

La concentración de  $O_3$  varía según la ubicación y las condiciones climáticas. Las concentraciones tienden a ser más altas en las áreas urbanas durante los meses de

verano, cuando la radiación solar es más intensa. La distribución de este gas no es homogénea, presentando mayores niveles en las capas más bajas de la troposfera, especialmente cerca de la superficie terrestre (Díaz et al., 2022).

El  $O_3$  ha sido gran importancia en la historia reciente, es decir, a lo largo del siglo XX y lo que va del XXI. Estimaciones por región a nivel global indican que en el periodo de 1980 a 2010, el sureste, el este y el sur asiático fueron los mayores generadores de  $O_3$  (Zhang et al., 2020).

En resumen, el  $O_3$  es un componente crítico de la contaminación atmosférica moderna. Su presencia y concentración están fuertemente influenciadas por las actividades humanas, y sus efectos adversos sobre la salud y el medio ambiente subrayan la necesidad de políticas eficaces para su control y reducción.

### **1.2.1 Ozono Troposférico y la Economía**

El  $O_3$  es un contaminante atmosférico cuya formación está estrechamente vinculada a las actividades económicas, particularmente a través de la industria. La economía, mediante sus diversos sectores industriales y actividades, juega un papel crucial en el aumento de las concentraciones de  $O_3$  en la atmósfera baja (Adler y Severnini, 2023).

Las industrias son grandes emisoras de  $NO_x$  y  $COV$ , los principales precursores del  $O_3$ . Los  $NO_x$  se generan principalmente en procesos de combustión a altas temperaturas, como los que ocurren en plantas de energía, fábricas y vehículos. Los  $COV$ , por su parte, se emiten durante la fabricación y uso de productos químicos, pinturas, solventes y combustibles fósiles (United States Environmental Protection Agency [EPA], 2020).

En áreas urbanas e industriales, las concentraciones de  $NO_x$  y  $COV$  tienden a ser elevadas debido a la alta densidad de actividades económicas y el tráfico vehicular. La luz solar cataliza las reacciones químicas entre estos compuestos, favoreciendo la formación de  $O_3$ . Durante los meses de verano, cuando la radiación solar es más

intensa, las concentraciones de  $O_3$  alcanzan niveles máximos, afectando la calidad del aire y la salud pública (Ontiveros-Jiménez, 2019; Anbani et al., 2022; Díaz-Torres et al., 2022; Nguyen et al., 2022).

El desarrollo económico y la expansión industrial, si bien son esenciales para el crecimiento económico y el bienestar social, tienen un costo ambiental significativo. Las emisiones de  $NO_x$  y  $COV$  no solo contribuyen al aumento de las concentraciones de  $O_3$ , sino que también tienen efectos negativos sobre la vegetación, reduciendo la productividad agrícola y forestal. El  $O_3$  daña las plantas al entrar por las estomas durante la fotosíntesis, afectando la capacidad de las plantas para crecer y producir alimentos (Intergovernmental Panel on Climate Change, 2013; Sachelli et al., 2021).

La relación entre la economía y el  $O_3$  subraya la necesidad de políticas y estrategias efectivas para reducir las emisiones de  $NO_x$  y  $COV$ . Esto incluye la implementación de tecnologías más limpias, el uso de combustibles menos contaminantes y la promoción de prácticas industriales sostenibles. La transición hacia una economía verde no solo contribuirá a la reducción de las concentraciones de  $O_3$ , sino que también promoverá un desarrollo económico más sostenible y resiliente (World Bank, 2019).

En resumen, la economía, a través de la industria y otras actividades, es un factor determinante en el incremento del  $O_3$ . Las políticas económicas y ambientales deben estar alineadas para abordar este desafío, promoviendo el crecimiento económico mientras se protege el medio ambiente y la salud pública.

### **1.2.2 Ozono Troposférico y la Salud**

El  $O_3$  tiene graves implicaciones para la salud humana. A diferencia del ozono estratosférico, que actúa como una barrera protectora contra los rayos ultravioleta del sol, el  $O_3$  es perjudicial cuando se encuentra a nivel del suelo (Anbani et al., 2022).

El  $O_3$  es un potente irritante respiratorio. Al inhalarse, este gas puede inflamar y dañar las vías respiratorias, causando síntomas como tos, irritación de garganta y dificultad

para respirar. Las personas con enfermedades respiratorias preexistentes, como el asma y la enfermedad pulmonar obstructiva crónica, son particularmente vulnerables a los efectos del  $O_3$ . Estudios han demostrado que la exposición al  $O_3$  puede aumentar la frecuencia y la gravedad de los ataques de asma, llevar a hospitalizaciones y, en casos extremos, causar la muerte (OMS, 2013; Anbani et al., 2022).

Además de sus efectos respiratorios, la exposición a largo plazo al  $O_3$  puede tener consecuencias cardiovasculares. La inflamación sistémica inducida por el  $O_3$  puede contribuir al desarrollo de enfermedades cardíacas, exacerbando condiciones como la hipertensión y aumentando el riesgo de eventos cardíacos adversos, incluidos infartos de miocardio (Environmental Protection Agency, 2021).

Los niños, los ancianos y las personas que pasan mucho tiempo al aire libre, ya sea por trabajo o actividades recreativas, también están en mayor riesgo. Los niños son particularmente susceptibles porque sus pulmones aún están en desarrollo, y tienden a ser más activos al aire libre, lo que incrementa su exposición al  $O_3$ . Los estudios han mostrado que la exposición al  $O_3$  durante la infancia puede afectar el crecimiento pulmonar y reducir la función pulmonar a lo largo de la vida (American Lung Association, 2020).

La calidad del aire, incluyendo los niveles de  $O_3$ , también tiene un impacto significativo en la salud pública a nivel comunitario. Las alertas de salud pública y los índices de calidad del aire ayudan a informar a la población sobre los niveles peligrosos de  $O_3$ , permitiendo que las personas tomen precauciones, como reducir la actividad física al aire libre durante los episodios de alta contaminación (OMS, 2013).

La reducción de las emisiones de precursores del  $O_3$ , como  $NO_x$  y  $COV$ , es crucial para disminuir las concentraciones de  $O_3$  y proteger la salud pública. Las políticas y regulaciones ambientales desempeñan un papel vital en este esfuerzo, promoviendo tecnologías más limpias y prácticas sostenibles en la industria y el transporte (Environmental Protection Agency, 2021).

Por su parte; en Europa se ha establecido el umbral de concentración de ozono en  $110\mu\text{g}/\text{m}^3$  ( $\approx 56.03\text{ppb}$ ), promediado en un período de 8 horas, para la protección de la salud humana. Este valor se fundamenta en la evidencia científica que demuestra los efectos adversos del ozono en concentraciones superiores a este umbral. Entre los efectos observados se incluyen dificultades respiratorias, disminución de la función pulmonar, y un aumento en la incidencia de síntomas respiratorios y reacciones inflamatorias en el pulmón (Agencia Europea de Medio Ambiente, 1998).

Diversos estudios epidemiológicos y análisis de datos hospitalarios han revelado que los días con concentraciones elevadas de ozono están correlacionados con un incremento en las admisiones hospitalarias por problemas respiratorios, en particular con poblaciones vulnerables como niños, ancianos, y personas con condiciones preexistentes (Agencia Europea de Medio Ambiente, 1998).

Por tanto, el establecimiento de este umbral se basa en la necesidad de mitigar estos riesgos para la salud pública, reduciendo la exposición de la población a niveles de ozono que puedan ser perjudiciales. Este límite, lejos de ser arbitrario, está respaldado por una sólida base de estudios científicos y de salud pública que justifican su implementación para proteger la salud humana (Agencia Europea de Medio Ambiente, 1998).

En resumen, la exposición a altas concentraciones de  $O_3$  está asociada con una variedad de efectos adversos en la salud, especialmente en los sistemas respiratorio y cardiovascular. Por lo anterior, el  $O_3$  representa una amenaza significativa para la salud humana. La implementación de estrategias efectivas para reducir las emisiones de precursores del  $O_3$  no solo mejorará la calidad del aire, sino que también tendrá un impacto positivo en la salud pública, reduciendo la incidencia de enfermedades respiratorias y cardiovasculares a nivel global.

### **1.3 Implicaciones Sociales, Económicas y de la Salud de la contingencia sanitaria por COVID-19**

La pandemia de COVID-19 y las consecuentes reducciones en la movilidad y en las actividades socioeconómicas tuvieron un impacto profundo en el mundo y por ende en la Ciudad de México durante el año 2020. Tales acciones desarrolladas por los gobiernos a escala global afectaron múltiples aspectos de la vida de sus habitantes, así como en las relaciones socioeconómicas que incentivaron el surgimiento de nuevas formas de comunicación social o de producción. En específico, la Organización Mundial de la Salud (OMS) apunta que las consecuencias económicas, sociales y de salud fueron particularmente severas en la CDMX, entre otros factores, por la elevada concentración y densidad poblacional que le caracteriza (OMS, 2020).

### **1.3.1 Implicaciones sociales**

Tomando en cuenta lo anterior, las implicaciones sociales más destacadas de la pandemia por COVID-19 pueden resumirse de la siguiente manera:

- **Desigualdad Social:** La pandemia agudizó las desigualdades sociales preexistentes. Las poblaciones más vulnerables, incluidas aquellas en situación de pobreza y las comunidades marginadas, enfrentaron mayores dificultades para acceder a servicios de salud y apoyo económico. Estas comunidades, que ya enfrentaban barreras significativas, vieron cómo el acceso a recursos esenciales se volvía aún más limitado, exacerbando las disparidades sociales y económicas (Comisión Económica para América Latina y el Caribe [CEPAL], 2020).

- **Educación:** El cierre de escuelas y la transición a la educación en línea plantearon desafíos significativos, especialmente para estudiantes de familias de bajos ingresos sin acceso adecuado a tecnologías digitales. Esta falta de acceso a dispositivos y conexión a internet de calidad dificultó la participación en las clases virtuales, contribuyendo a la ampliación de la brecha educativa y la deserción escolar. Según UNICEF (2020), muchos estudiantes quedaron rezagados en su aprendizaje debido a estas desigualdades tecnológicas.

- **Aislamiento Social y Hábitos Sociales:** El aislamiento social impuesto para frenar la propagación del virus tuvo profundos efectos en los hábitos y comportamientos sociales de los habitantes de la Ciudad de México. Las medidas de confinamiento

restringieron las interacciones cara a cara, obligando a las personas a depender de las tecnologías de comunicación digital para mantener el contacto con amigos y familiares. Aunque las videollamadas y las redes sociales permitieron cierto grado de conexión, no pudieron reemplazar completamente la interacción física, lo que resultó en sentimientos de soledad y aislamiento (Pew Research Center, 2020).

Por su parte, un estudio de Hosseinzadeh et al. (2022) analiza las profundas consecuencias sociales de la pandemia de COVID-19, destacando que las medidas de confinamiento y distanciamiento social generaron un malestar generalizado en la sociedad, alterando el estilo de vida, las dinámicas de trabajo y las interacciones sociales. La pandemia no solo afectó las relaciones humanas al incrementar la distancia social, sino que también agravó la situación de grupos vulnerables, como las familias con bajos ingresos, quienes enfrentaron mayores dificultades debido a la crisis sanitaria y económica (Hosseinzadeh et al., 2022).

- **Percepción Social:** Durante la pandemia de COVID-19, el uso de mascarillas y otras formas de cubrir el rostro modificó significativamente las dinámicas de interacción social. Un estudio de Calbi et al. (2021) muestra que la cobertura del rostro, ya sea con mascarillas o bufandas, afecta la forma en que las personas perciben las emociones expresadas por los demás, así como la distancia física y social que prefieren mantener. La presencia de una mascarilla reduce la claridad con la que se reconocen las emociones positivas, como la felicidad, y puede aumentar la percepción de amenaza o la necesidad de mantener una mayor distancia social frente a expresiones negativas, como la ira (Calbi et al., 2021).

El confinamiento también alteró los hábitos de consumo y recreación. Con la mayoría de los establecimientos de entretenimiento cerrados, las personas recurrieron a actividades dentro del hogar, como ver televisión, cocinar y realizar ejercicios en espacios limitados. Esta reducción en la movilidad y el cambio en los hábitos de vida tuvieron implicaciones tanto positivas como negativas para la salud mental y física de la población (International Labour Organization, 2020).

El comportamiento social durante el encierro reflejó una adaptación a las nuevas normas y restricciones. La adopción de medidas como el uso de mascarillas, el

distanciamiento social y la higiene constante de las manos se convirtió en parte de la vida cotidiana. Sin embargo, estas medidas también generaron tensión y ansiedad, especialmente cuando las normas no eran seguidas uniformemente por todos los miembros de la comunidad (OMS, 2020).

A pesar de esto, la pandemia por COVID-19 también fomentó un sentido de solidaridad y apoyo mutuo en muchas comunidades. Surgieron iniciativas de ayuda comunitaria y redes de apoyo para asistir a aquellos más afectados por la crisis, mostrando un aspecto positivo del comportamiento social en tiempos de adversidad (CEPAL, 2020).

En resumen, la pandemia de COVID-19 y las medidas de confinamiento impuestas en 2020 tuvieron efectos profundos y multifacéticos, evidenciando y exacerbando desigualdades sociales preexistentes y alterando significativamente la dinámica diaria de los habitantes. La transición a la educación en línea destacó una nueva brecha digital, afectando desproporcionadamente a los estudiantes de familias de bajos ingresos y ampliando la brecha educativa. El aislamiento social modificó los hábitos de interacción y consumo, introduciendo desafíos para la salud mental y física de la población. Sin embargo, también surgieron esfuerzos comunitarios de solidaridad y apoyo mutuo, demostrando la capacidad de resiliencia de las comunidades ante la adversidad. Estos cambios subrayan la necesidad de políticas integrales que aborden tanto las emergencias sanitarias como las inequidades estructurales, promoviendo un desarrollo más equitativo y sostenible para el futuro.

### **1.3.2 Implicaciones Económicas**

El aislamiento global provocado por la pandemia de COVID-19 en 2020 tuvo profundas consecuencias económicas. Las medidas de confinamiento y la reducción de la movilidad alteraron significativamente la actividad económica, afectando la productividad laboral, el consumo, la inversión y la estabilidad financiera a nivel mundial. Las repercusiones abarcaron diversas áreas, afectando tanto a individuos como a empresas y gobiernos. Entre las principales implicaciones económicas del encierro durante 2020 se encuentran:

- **Recesión Económica Global:** La mayoría de las economías del mundo experimentaron una contracción significativa del PIB debido a las medidas de confinamiento. El cierre de negocios, la interrupción de las cadenas de suministro y la disminución de la demanda de bienes y servicios provocaron una recesión global. Según el Fondo Monetario Internacional (FMI), la economía mundial se contrajo un 3.5% en 2020 (Fondo Monetario Internacional, 2021). Esta recesión afectó a todos los sectores económicos, llevando a una crisis económica sin precedentes. El análisis de Naseer et al. (2023) destaca que la recesión económica global afectó sectores clave como la manufactura, el turismo y la agricultura. Las medidas de confinamiento y las restricciones de movilidad llevaron a una interrupción significativa de las cadenas de suministro y a un aumento en el desempleo, lo cual, a su vez, contribuyó a una contracción del PIB mundial. El impacto económico de la pandemia ha sido tan extenso que muchas economías emergentes aún enfrentan dificultades para recuperar sus niveles de crecimiento previos (Naseer et al., 2023).

- **Desempleo y Pérdida de Ingresos:** Millones de personas perdieron sus empleos o vieron reducidas sus horas de trabajo debido al cierre de empresas y la disminución de la actividad económica. Sectores como el turismo, la hostelería, el entretenimiento y el transporte fueron particularmente afectados. Esta pérdida de ingresos aumentó la pobreza y la inseguridad alimentaria en muchas regiones (Organización Internacional del Trabajo, 2020). El desempleo generalizado exacerbó las desigualdades económicas y dejó a muchas familias sin recursos para cubrir sus necesidades básicas.

- **Impacto en las Pequeñas y Medianas Empresas (PYMES):** Las PYMES fueron especialmente vulnerables durante el encierro, ya que muchas no tenían los recursos financieros para sobrevivir a largos períodos sin ingresos. A pesar de los esfuerzos de los gobiernos para proporcionar ayudas y préstamos, muchas pequeñas empresas cerraron permanentemente. Esto no solo afectó a los propietarios de las empresas, sino también a los empleados que dependían de estos negocios para su sustento (Banco Mundial, 2020).

- **Digitalización y Teletrabajo:** La pandemia aceleró la adopción de tecnologías digitales y el teletrabajo. Muchas empresas implementaron políticas de trabajo remoto,

lo que tuvo implicaciones a largo plazo para la organización del trabajo y la demanda de bienes raíces comerciales. La digitalización permitió a algunas empresas mantener sus operaciones durante el confinamiento, pero también destacó la brecha digital, dejando atrás a aquellos sin acceso adecuado a la tecnología (OECD, 2020).

- **Restricciones de Movilidad:** Las restricciones de movilidad implementadas durante la pandemia de COVID-19 tuvieron importantes repercusiones económicas y sociales. Un análisis realizado por Bonaccorsi et al. (2020) sobre el caso de Italia muestra que estas medidas afectaron de manera desigual a diferentes regiones y municipios. Mientras que los municipios con mayor capacidad fiscal enfrentaron un impacto más significativo en términos de reducción de la movilidad, aquellos con ingresos más bajos y una alta desigualdad experimentaron una contracción aún más pronunciada en su actividad. Esto presentó un desafío para los gobiernos locales, que no solo vieron reducidos sus ingresos fiscales, sino que también debieron destinar recursos para apoyar a las poblaciones más vulnerables (Bonaccorsi et al., 2020).

- **Desempleo y Cierre de Negocios:** La implementación de medidas restrictivas para frenar la propagación del virus, como el cierre temporal de negocios no esenciales y la limitación de movilidad, resultó en una oleada de despidos y en el cierre permanente de muchas pequeñas y medianas empresas. Sectores como el turismo, la restauración y el comercio minorista fueron especialmente golpeados, ya que dependían en gran medida del flujo constante de personas (FMI, 2021).

- **Reducción del Ingreso Familiar:** El desempleo y la reducción de actividades económicas llevaron a una disminución significativa en los ingresos familiares. Muchas familias vieron afectada su capacidad para cubrir necesidades básicas como alimentación, vivienda y educación. Esta disminución en los ingresos tuvo un efecto dominó en el bienestar general de las familias, exacerbando las condiciones de pobreza y exclusión social (UNICEF, 2020).

- **Informalidad Laboral:** La economía informal, que representa una parte sustancial de la actividad económica en la Ciudad de México, se vio también gravemente afectada. La falta de redes de seguridad social para los trabajadores informales exacerbó la crisis económica en estos sectores, siendo gran parte de la población la

que salía durante el encierro para buscar sustento diario. Esto no solo aumentó la vulnerabilidad económica de estas personas, sino que también expuso a muchas a un mayor riesgo de contagio (Banco Mundial, 2020).

- Políticas de Contención y Modelos Epidemiológicos Económicos: Durante la pandemia de COVID-19, muchos gobiernos implementaron políticas de contención para limitar la propagación del virus, lo que incluyó restricciones de movilidad, cierres temporales de actividades económicas y medidas de distanciamiento social. Estas políticas, aunque necesarias para proteger la salud pública, tuvieron un impacto directo en la actividad económica, generando una reducción en el consumo y la inversión. Para evaluar y mitigar estos efectos, se utilizaron modelos epidemiológicos ajustados que incorporaban variables económicas, como el modelo SIR (Susceptible-Infectious-Recovered). Estos modelos permitieron a los tomadores de decisiones analizar el balance entre la salud pública y la economía, proyectando los impactos de diferentes estrategias de contención en el bienestar social y económico. La combinación de una menor actividad económica y un aumento en la demanda de liquidez por parte de los hogares fue clave para manejar los riesgos financieros durante la crisis. Sin embargo, el relajamiento prematuro de las medidas de contención, según las proyecciones de estos modelos, habría incrementado las tasas de contagio, lo que a su vez podría haber comprometido aún más la recuperación económica a largo plazo (Zhao, 2020).

En resumen, la pandemia de COVID-19 y el encierro global tuvieron repercusiones económicas profundas y multifacéticas que afectaron a todos los niveles de la sociedad. La recesión económica global, el desempleo masivo, la vulnerabilidad de las pequeñas y medianas empresas, y la aceleración de la digitalización y el teletrabajo son solo algunas de las consecuencias más destacadas. Estas circunstancias exacerbaron las desigualdades económicas y sociales preexistentes, dejando a muchas familias en una situación precaria. La crisis subraya la necesidad urgente de políticas económicas resilientes y adaptativas que puedan mitigar los efectos de futuras emergencias, proporcionando apoyo a los sectores más vulnerables y fomentando una recuperación económica sostenible y equitativa.

### 1.3.3 Implicaciones en la Salud

La pandemia de COVID-19 no solo tuvo un impacto devastador en el comportamiento social, sino que también ejerció una enorme presión sobre los sistemas de salud, exacerbando las desigualdades y resaltando la fragilidad de los servicios sanitarios. Además de la mortalidad, que fue realmente abrumadora, entre las implicaciones de la pandemia en la salud se destacan las siguientes:

- **Saturación del Sistema de Salud:** Los hospitales y clínicas enfrentaron una presión sin precedentes debido al alto número de casos de COVID-19. La falta de camas, ventiladores y personal médico adecuadamente protegido contribuyó a la crisis del sistema sanitario. El incremento en la demanda de atención médica sobrepasó la capacidad de respuesta del sistema de salud, provocando una saturación que afectó tanto a pacientes con COVID-19 como a aquellos con otras condiciones médicas urgentes, quienes en muchos casos debieron relegar su atención debido a la prioridad de los casos de COVID-19 (Organización Panamericana de la Salud, 2020).

- **Salud Mental:** El estrés, la ansiedad y la depresión aumentaron notablemente entre la población debido al aislamiento social, la incertidumbre económica y el miedo al contagio. Los servicios de salud mental, que ya eran insuficientes antes de la pandemia, se vieron desbordados. La necesidad de apoyo psicológico y psiquiátrico se incrementó, pero los recursos disponibles no fueron suficientes para atender a todos los afectados, lo que agravó la situación de salud mental en la población (World Health Organization, 2021). La pandemia de COVID-19 ha tenido un impacto profundo en la salud mental de la población. El aislamiento social y la incertidumbre llevaron a un incremento en los niveles de ansiedad, estrés y depresión, afectando especialmente a aquellos que se enfrentaron directamente al virus o perdieron a seres queridos. Estos efectos negativos en la salud mental resultan no solo del miedo al contagio, sino también de las restricciones prolongadas que limitaron la interacción social y generaron sentimientos de soledad y vulnerabilidad (Afrashtehfar et al., 2023). La interrupción de las rutinas diarias contribuyó al aumento de casos de ansiedad, depresión, insomnio y trastorno por estrés posttraumático (TEPT), destacando la necesidad de estrategias de intervención temprana por parte de los servicios de salud mental para mitigar los

efectos negativos de la pandemia y brindar apoyo a los grupos más vulnerables, incluyendo a los trabajadores de la salud y a quienes padecían trastornos mentales preexistentes (Ramírez-Ortiz et al., 2022).

- **Salud Mental en Niños:** Las medidas de aislamiento social y el cierre de escuelas generaron un aumento significativo en los síntomas de ansiedad y depresión entre niños y adolescentes. La falta de interacción social y la interrupción de las rutinas escolares afectaron especialmente a los más jóvenes, con consecuencias como el aumento de la inseguridad, el miedo y la sensación de aislamiento. Estos efectos fueron más pronunciados en aquellos con condiciones neuropsiquiátricas preexistentes, quienes mostraron una mayor vulnerabilidad durante la pandemia (Viola & Nunes, 2022).

- **Enfermedades No Transmisibles:** La atención sanitaria se concentró en combatir el COVID-19, lo que llevó a una disminución en la atención de otras enfermedades no transmisibles. Esto resultó en una desatención de enfermedades crónicas como diabetes, hipertensión y cáncer, lo que podría tener consecuencias a largo plazo para la salud de la población. Muchas personas con estas condiciones no recibieron el seguimiento médico adecuado, incrementando el riesgo de complicaciones y mortalidad asociada (World Health Organization, 2020).

- **Efectos Prolongados del COVID-19 (Long COVID):** El estudio de Atchison et al. (2023) resalta que, aunque la mayoría de los casos de COVID-19 son de corta duración, un número significativo de personas experimenta síntomas persistentes, conocidos como Long COVID, que pueden prolongarse por más de 12 semanas y, en algunos casos, hasta 52 semanas. Estos síntomas incluyen fatiga severa, dificultad para respirar y problemas cognitivos, lo cual afecta significativamente la calidad de vida y el bienestar de quienes los padecen. Los factores que aumentan el riesgo de síntomas persistentes incluyen el sexo femenino, la presencia de comorbilidades y la gravedad de los síntomas iniciales (Atchison et al., 2023).

- **Desequilibrios en los Sistemas de Prevención de la Salud:** La pandemia también provocó una interrupción en los programas de prevención y control de enfermedades,

incluyendo campañas de vacunación y detección temprana, lo que podría tener un impacto negativo en la salud pública a futuro (United Nations, 2020).

La respuesta del sistema de salud durante la pandemia subraya la necesidad de fortalecer la infraestructura sanitaria y aumentar los recursos destinados a la salud mental y la gestión de enfermedades crónicas. Una preparación más robusta y una capacidad de respuesta más flexible son esenciales para enfrentar futuras emergencias de salud pública.

En conclusión, la pandemia de COVID-19 dejó lecciones valiosas sobre la necesidad de un sistema de salud robusto y adaptable. Un enfoque holístico y bien coordinado es esencial para mitigar los efectos adversos en la salud pública y garantizar que la población esté mejor preparada para enfrentar desafíos similares en el futuro.

#### **1.4 Conclusiones del capítulo**

Este capítulo permitió establecer los conceptos clave de esta investigación: la dinámica del  $O_3$  y la pandemia de COVID-19, con un enfoque en su impacto en la CDMX y el mundo durante el año 2020. Se discutió cómo la pandemia afectó diferentes aspectos de la vida cotidiana, desde la economía hasta la salud pública y las interacciones sociales. Las medidas de confinamiento y las restricciones aplicadas resultaron en una disminución significativa de las actividades industriales y vehiculares, lo cual influyó en los niveles de  $O_3$  en la atmósfera.

Por un lado, la reducción de emisiones de precursores de ozono, consecuencia de la menor actividad económica, brindó una oportunidad única para estudiar el comportamiento del ozono bajo condiciones atípicas. Por otro lado, la crisis sanitaria intensificó las desigualdades sociales y puso a prueba la resiliencia de los sistemas de salud y la economía.

En términos de salud, se destacó la presión sobre los sistemas hospitalarios y el aumento de problemas de salud mental y enfermedades crónicas. En el ámbito económico, la pandemia provocó una recesión global, afectando especialmente a las

pequeñas y medianas empresas, y aceleró la transición hacia el teletrabajo y la digitalización, lo cual, a su vez, evidenció las brechas tecnológicas existentes.

Este análisis enfatiza la importancia de desarrollar políticas públicas que integren aspectos ambientales, económicos y de salud, diseñadas para mitigar el impacto de futuras crisis. La interrelación entre estos factores demuestra la necesidad de un enfoque integral y coordinado que promueva un desarrollo sostenible, mejorando la calidad del aire y la salud pública, a la vez que se fomenta la resiliencia económica y social.

La conclusión de este capítulo resume los aspectos más relevantes, integrando las distintas secciones y subrayando la importancia de políticas integradas para enfrentar futuros desafíos.

## **Capítulo 2. Discusión: El Ozono Troposférico en la Ciudad de México**

### **2.1 Introducción al capítulo**

Este capítulo se estructurará para proporcionar una visión integral sobre el  $O_3$  en la CDMX, abordando desde su comportamiento, hasta sus características, especificando en el contexto de la pandemia causada por COVID-19. La relevancia de este análisis radica en la necesidad de entender mejor este contaminante para poder implementar estrategias efectivas que mitiguen sus efectos negativos y mejoren la calidad de vida de los habitantes de la ciudad.

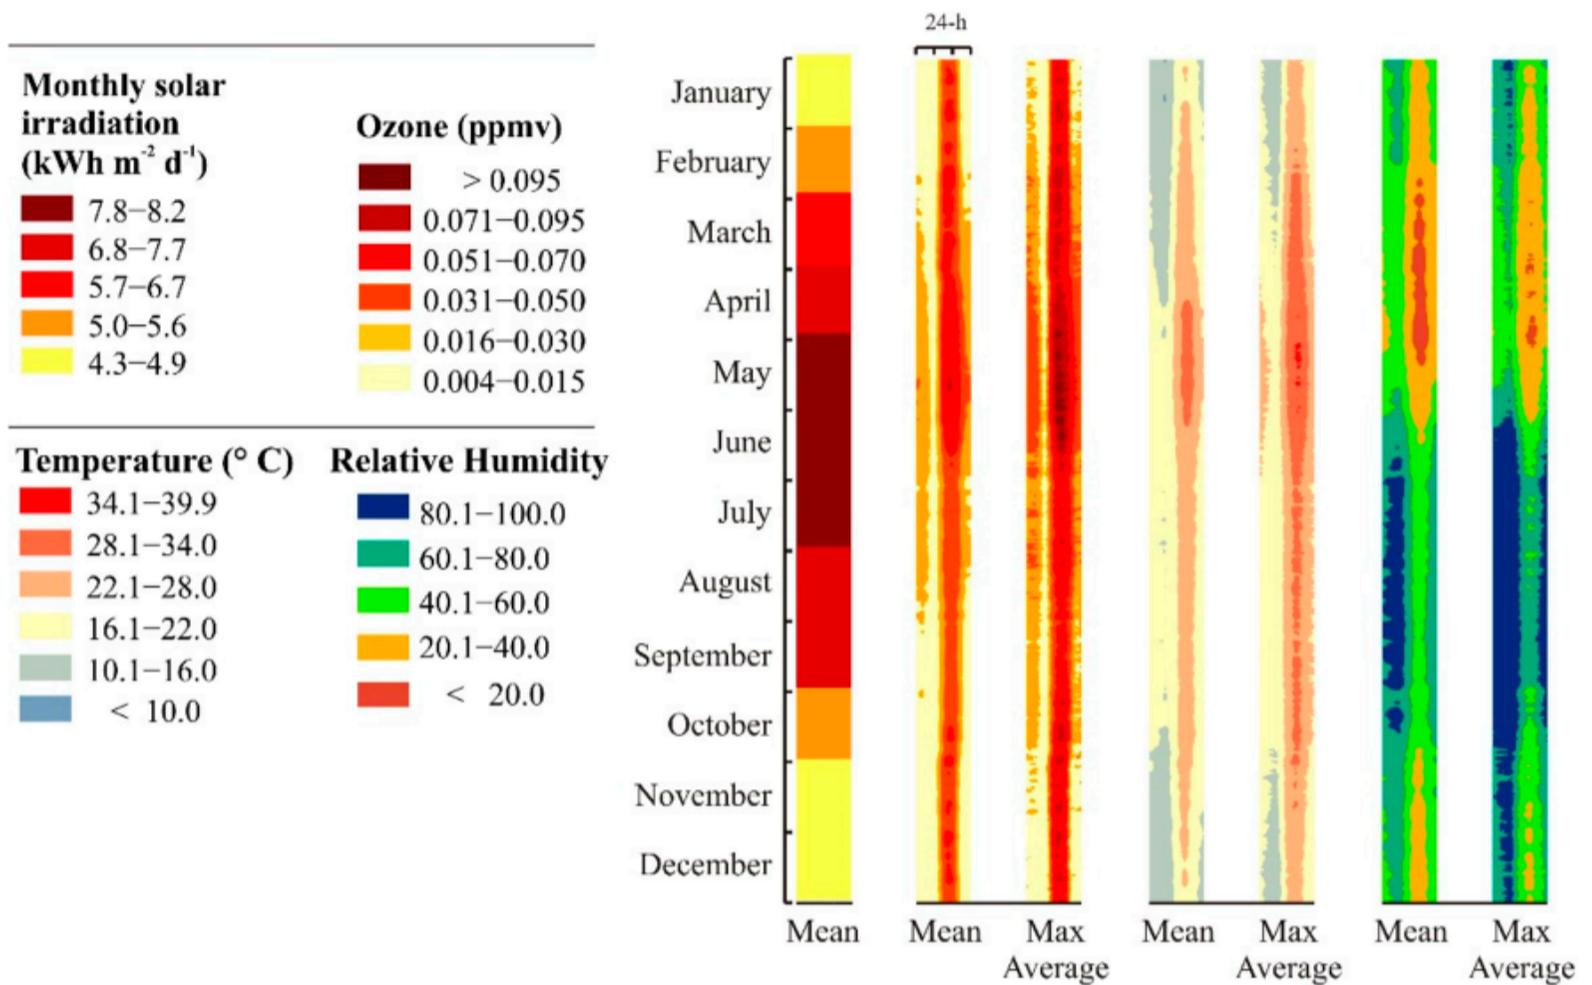
### **2.2 El análisis del Ozono Troposférico en México y en la Ciudad de México**

El  $O_3$  es uno de los principales contaminantes atmosféricos que afecta a las grandes ciudades de México, especialmente en la Zona Metropolitana del Valle de México (ZMVM). La elevada concentración de  $O_3$  en la Zona de dicho Valle se ha asociado con la alta densidad vehicular, la actividad industrial, y las condiciones climáticas que favorecen la formación y acumulación de ozono, tales como la alta radiación solar y la estabilidad atmosférica (Molina & Molina, 2004).

El estudio de las concentraciones de  $O_3$  en México ha sido una constante cuando se trata del estudio de los principales contaminantes. Por ejemplo, Díaz et al. (2022) realizaron un análisis detallado de las concentraciones normales de ozono en el área metropolitana de Guadalajara, México, comparando estos datos con la climatología de la temperatura y la humedad. Los resultados mostraron que las concentraciones de ozono son influenciadas significativamente por factores climáticos, con mayores tasas de formación de ozono durante la temporada seca y cálida, cuando las temperaturas alcanzan sus valores más altos y la humedad es mínima. Este comportamiento

estacional se ve acentuado por la alta irradiación solar característica de la región, especialmente durante los meses de marzo a junio.

Gráfico 2.1 Concentraciones normales de ozono y climatología de la temperatura y la humedad para el periodo de 1996 a 2019 comparada con la irradiación solar potencial media mensual.



Fuente: Recuperado de Díaz et al. (2022)

El gráfico 2.1 muestra la relación entre las concentraciones de  $O_3$  en ppm, la radiación solar mensual, la temperatura y la humedad relativa a lo largo de un año en el área metropolitana de Guadalajara. Se puede observar que las concentraciones más altas coinciden con los meses con mayor radiación solar y temperaturas más elevadas. Durante este período, las concentraciones de ozono superan frecuentemente los 0.095 ppmv, lo que está asociado con condiciones climáticas de alta temperatura y baja humedad relativa. Por otro lado, los meses de julio a diciembre, con menor irradiación solar y temperaturas más bajas, presentan concentraciones más bajas de ozono. La humedad relativa también muestra un comportamiento estacional, con valores más altos durante los meses de lluvia, lo que coincide con una reducción en las concentraciones de ozono. Este gráfico subraya la influencia significativa de los factores climáticos en la formación y acumulación de ozono en la atmósfera.

Otros estudios sobre el  $O_3$  en zonas o áreas de México han mostrado que, si bien no se identifica un modelo universal de pronóstico de los valores del ozono en zonas urbanas, datos de 1999 mostraban el aumento de los niveles del contaminante en la CDMX (Garfias Vázquez et al., 2004). En este sentido, Thompson et al (2008) identificaron que en con un elevado grado de urbanización como la CDMX, las variaciones en las mediciones de  $O_3$  se relacionan con la estacionalidad del año.

Por otra parte, Rodríguez y colaboradores (2016), analizaron las mediciones de  $O_3$  en la CDMX en el periodo 2001-2014. Los resultados de esta investigación muestran que, al menos en el periodo de estudio, los valores promedios máximos de  $O_3$  disminuyeron temporalmente. Sin embargo, Matias Gutierrez y colaboradores (2023) encontraron que en el periodo 2010-2018 el comportamiento de la concentración de  $O_3$  se relaciona con la estacionalidad siendo la primavera el periodo con mayores niveles del contaminante.

### **2.3 El Ozono Troposférico en el contexto de la pandemia por COVID-19**

Durante la pandemia por COVID-19, se hicieron estudios que informaron sobre la disminución de las concentraciones de  $O_3$  en ciertas regiones y bajo condiciones específicas. Especialmente en zonas donde la reducción de precursores fue significativa y las condiciones meteorológicas no favorecieron la formación de  $O_3$ .

Un estudio de Venter et al. (2020) analizó los cambios en la calidad del aire en 34 países y encontró que, en algunas regiones, los niveles de  $O_3$  disminuyeron durante los confinamientos iniciales. Esta disminución se atribuyó a la reducción drástica de emisiones de  $NO_x$  debido a la menor actividad vehicular y a la disminución de la producción industrial, en combinación con factores meteorológicos que no favorecieron la formación de ozono.

Menut et al. (2020) también reportó una disminución de las concentraciones de ozono en áreas rurales y suburbanas en Europa, donde la reducción de  $NO_x$  no se vio

contrarrestada por otros factores que aumentarían el ozono, como la mayor radiación solar o la disminución de aerosoles. Este comportamiento sugiere que la respuesta del  $O_3$  a los cambios en las emisiones durante la pandemia fue altamente dependiente de las condiciones locales, tanto en términos de fuentes de precursores como de las condiciones atmosféricas.

En un estudio realizado en la ciudad de Madrid, España, se observó una disminución significativa en los niveles de  $O_3$  durante el confinamiento estricto. Este fenómeno fue atribuido a la reducción masiva de emisiones de precursores del ozono debido a la disminución de la actividad vehicular y la reducción en la producción industrial. Este estudio sugiere que, en ciertas condiciones, la disminución de los precursores del ozono puede llevar a una reducción en las concentraciones de  $O_3$ , especialmente en áreas donde la formación de ozono está limitada por la disponibilidad de compuestos orgánicos volátiles (Sicard et al., 2020).

Pasando a México, un estudio de Peralta et al. (2021) en Monterrey reportó una disminución en los niveles de  $O_3$  durante los primeros meses del confinamiento. Este comportamiento se asoció con la reducción drástica de las emisiones vehiculares y las condiciones meteorológicas específicas de la región, que no favorecieron la formación de ozono a partir de los precursores presentes. Sin embargo, este estudio también destacó que la disminución no fue homogénea a lo largo del tiempo, subrayando la variabilidad en la respuesta del  $O_3$  a las reducciones de emisiones.

De igual forma en Jalisco, Suárez et al. (2021), analizó las concentraciones de ozono en Guadalajara. Aquí, los resultados mostraron una ligera disminución en los niveles de  $O_3$ , atribuida a una combinación de menores emisiones de precursores y condiciones atmosféricas que limitaban la formación de ozono. Sin embargo, los autores advirtieron que esta disminución podría no ser sostenible una vez que se levantaran las restricciones y se reanudaran las actividades normales. En general, los resultados han mostrado una tendencia compleja y en algunos casos contradictoria, dependiendo de la ciudad y de las condiciones atmosféricas locales.

Por su parte, durante la pandemia por COVID-19, se observó un fenómeno interesante en relación con el  $O_3$  en la Zona Metropolitana del Valle de México. A medida que las medidas de confinamiento redujeron drásticamente la actividad humana, particularmente la circulación vehicular y la producción industrial, se esperaba una disminución general en la contaminación atmosférica. Sin embargo, aunque se registró una reducción significativa en las concentraciones de  $NO_x$  y otros contaminantes primarios, el comportamiento del  $O_3$  no siguió una tendencia tan clara, e incluso en algunos casos, aumentó (Sicard et al., 2020). Esto se puede denotar específicamente en la CDMX en el mes de septiembre.

En la Ciudad de México, un estudio realizado por Rodríguez (2020) observó que, aunque las concentraciones de  $NO_x$  disminuyeron significativamente debido a la reducción en la actividad vehicular, los niveles de  $O_3$  no presentaron una disminución consistente, e incluso se observaron incrementos en ciertos días. Este fenómeno se atribuye a la disminución de  $NO_x$ , que normalmente actúan como precursores de  $O_3$ , lo que llevó a un decremento en las concentraciones de ozono en algunos periodos.

Particularmente, en la ZVMM se estudiaron los efectos del confinamiento por la COVID-19 en la calidad del aire en la ZMVM, enfocándose en la evolución de varios contaminantes durante los meses de confinamiento, con especial atención al  $O_3$  (Hernández-Paniagua et al., 2021). Los resultados de este trabajo mostraron cambios significativos en las concentraciones de  $O_3$ , que se vieron influenciados por las reducciones en las emisiones de precursores debido a la disminución de la actividad humana y vehicular. En forma específica, se observó que:

- I. Durante los primeros meses de confinamiento, entre marzo y abril de 2020, las concentraciones de  $O_3$  mostraron un aumento notable, con incrementos que oscilaron entre un 16% y un 40% en comparación con los años anteriores.
- II. Durante los meses posteriores, de abril a mayo de 2020, que correspondieron al confinamiento total, aunque las concentraciones de  $O_3$  fueron ligeramente más

bajas que en el período anterior, no se observaron reducciones significativas en comparación con los niveles de referencia de 2016-2019.

## 2.4 Conclusiones del capítulo

El análisis del  $O_3$  en la Ciudad de México revela la complejidad de su comportamiento en un entorno urbano con alta densidad poblacional y actividad vehicular intensa. A pesar de que las medidas de confinamiento por la pandemia de COVID-19 llevaron a una disminución en las emisiones de precursores del ozono, como los  $NO_x$ , los niveles de  $O_3$  no disminuyeron de manera consistente en la CDMX. De hecho, en ciertos momentos, incluso se observaron incrementos.

Este comportamiento aparentemente contradictorio se explica por la función dual de los  $NO_x$ , que actúan tanto como precursores en la formación de ozono como sumideros de este contaminante. La reducción significativa de  $NO_x$  durante el confinamiento pudo haber disminuido su capacidad de neutralizar el ozono, resultando en aumentos en las concentraciones de ozono en ciertas condiciones.

Además, la influencia de factores meteorológicos, como la irradiación solar y la estabilidad atmosférica, es crucial en la dinámica del  $O_3$ , lo que explica las variaciones observadas en diferentes ciudades y periodos durante la pandemia. Este capítulo subraya la importancia de un enfoque integral en la gestión de la calidad del aire, que considere tanto las emisiones de precursores como las condiciones climáticas locales, para abordar de manera efectiva la problemática del  $O_3$  en la CDMX.

## Capítulo 3. Metodología de investigación

### 3.1 Introducción al Capítulo

Esta investigación busca pronosticar la cantidad de  $O_3$  que hubiera sido captada por la CDMX de no haber sido por el fenómeno originado por el COVID-19. Dado lo anterior, el objetivo de este capítulo es presentar la Metodología de investigación de la tesis la cual se basa en el desarrollo de pronósticos probabilísticos de la cantidad de  $O_3$  en la CDMX.

El contenido del capítulo se presenta en cuatro apartados adicionales a esta introducción. En el apartado 3.2 se expone la fuente de datos y la muestra de análisis del proyecto, mientras que en el apartado 3.3 se presentan algunos conceptos sobre los procesos Series de Tiempo que es el enfoque analítico de la investigación. En el apartado 3.4 se desarrollan las técnicas de estimación que se basan en la metodología ARIMA propuesta por Box, Jenkins y Ljung (2016).

### 3.2 Fuente de Datos

Los datos del proyecto se basan en dos mediciones compiladas por la Dirección de la Calidad del Aire del Gobierno de la CDMX:

1. Mediciones en partes por millón de promedio móvil máximo de 8 horas de  $O_3$ , que para el pronóstico de esta tesis fueron obtenidos de la Dirección de la Calidad del Aire del Gobierno de la CDMX, los cuales están disponibles en: <http://www.aire.cdmx.gob.mx> [consulta actualizada el 4 de julio de 2024].; considerando un tiempo discreto debido a las mediciones mensuales. A su vez, de la misma fuente se obtuvieron los datos del resto del año 2020 para ser comparados con el pronóstico que será realizado. En adelante esta Base de Datos será denominada como “Conjunto de Datos 1”.

2. Medición 2 que son valores diarios, disponibles en: <https://datos.cdmx.gob.mx/dataset/red-automatica-de-monitoreo-atmosferico> [consulta actualizada el 4 de julio de 2024]. A diferencia de las mediciones del punto 1, estos valores comprenden el periodo de tiempo que va desde 2015 a 2020 con observaciones temporales discretas diarias. En adelante esta Base de Datos será denominada como “Conjunto de Datos 2”.

### **3.3 Conceptos Necesarios para definir la Metodología**

Previo a la exposición de las técnicas de estimación, es necesario que se proporcionen algunos conceptos sobre los principios del análisis de Series de Tiempo.

a) Tiempo Discreto: El tiempo discreto se refiere a puntos específicos en el tiempo en los cuales se realizan observaciones o se recopilan datos. A diferencia del tiempo continuo, donde las observaciones pueden ocurrir en cualquier momento, en el tiempo discreto las observaciones se toman en intervalos regulares y predefinidos (Box et al., 2016).

b) Serie de Tiempo: Una serie de tiempo es un conjunto de observaciones generadas secuencialmente a lo largo del tiempo. Las Series de Tiempo pueden tomar un tiempo continuo o discreto, expresadas matemáticamente como  $y_t$ , donde  $y$  representa la observación en el tiempo  $t$ . (Box et al., 2016).

c) Primer Retardo en una Serie de Tiempo: En Series de Tiempo, el primer retardo de una variable  $y_t$  es simplemente la observación dada en el tiempo  $t - 1$ , expresada como  $y_{t-1}$ . El primer retardo es esencial para construir modelos autorregresivos y de medias móviles, ya que ayuda a capturar la dependencia temporal entre las observaciones consecutivas en una serie de tiempo. Como se verá adelante, un principio fundamental de la definición de una ecuación de pronósticos es dependencia temporal de las observaciones del proceso (Box et al., 2016).

d) k-ésimo retardo con independencia y correlaciones no distinta a 0: Expresando el k-ésimo retardo como  $y_{t-k}$ , la observación de la variable aleatoria  $y_t$  en el tiempo  $t - k$ , las observaciones pueden tener correlaciones no nulas hasta cierto número de retardos, lo cual se expresa mediante la función de autocorrelación  $\rho_k$  (Box et al., 2016).

e) Procesos Estocásticos: Un proceso estocástico es un fenómeno estadístico que evoluciona en el tiempo según leyes probabilísticas. Las Series de Tiempo que se analizan pueden considerarse realizaciones particulares de un proceso estocástico subyacente debido a una periodicidad finita, pero sobre todo considerando que en  $k$  retardos incrementa la independencia estadística de las realizaciones del proceso (Box et al., 2016).

f) Raíz Unitaria: Una raíz unitaria en una serie de tiempo indica que el proceso es no estacionario y que las perturbaciones tienen efectos persistentes a lo largo del tiempo. Matemáticamente, un proceso tiene una raíz unitaria si uno de los valores propios del polinomio característico asociado al modelo autorregresivo es igual a uno. Este concepto es crucial en la prueba de raíces unitarias, como las pruebas de Dickey-Fuller aumentada (1979), para determinar la estacionariedad de la serie (Box, Jenkins, Reinsel, & Ljung, 2016).

g) Estacionariedad: La estacionariedad es un concepto fundamental en el análisis de Series de Tiempo, particularmente en la construcción y aplicación de modelos ARIMA. En términos simples, una serie de tiempo es estacionaria si sus propiedades estadísticas, como la media, la varianza y la autocorrelación, son constantes a lo largo del tiempo. Esta propiedad es crucial para los modelos ARIMA, ya que estos modelos asumen que la serie de tiempo a ser modelada es estacionaria (Box, Jenkins, Reinsel, & Ljung, 2016).

En el contexto de un modelo ARIMA, la estacionariedad es importante porque asegura que los patrones observados en los datos, como las fluctuaciones alrededor de la media o las relaciones entre los valores consecutivos, se mantendrán consistentes en el futuro. Esto es esencial para la precisión de las predicciones, ya que un modelo

ARIMA se basa en la premisa de que las relaciones pasadas entre los datos pueden extrapolarse para prever el comportamiento futuro (Box, Jenkins, Reinsel, & Ljung, 2016).

Cuando una serie de tiempo no es estacionaria, los valores pueden mostrar tendencias, cambios en la varianza o patrones cíclicos que varían con el tiempo. Para aplicar un modelo ARIMA en estos casos, es necesario transformar la serie para que se vuelva estacionaria, lo que a menudo se logra mediante el proceso de diferenciación (restando el valor anterior de cada observación). Esta transformación es lo que permite que el modelo ARIMA capture de manera efectiva las dinámicas subyacentes de la serie, proporcionando predicciones más fiables (Box, Jenkins, Reinsel, & Ljung, 2016).

h) Estacionalidad: La estacionalidad en una serie de tiempo se refiere a las fluctuaciones periódicas o patrones que se repiten a intervalos regulares a lo largo del tiempo, como las variaciones que ocurren en función de las estaciones del año, los días de la semana, o las horas del día. Este concepto es crucial en el análisis de Series de Tiempo, ya que permite identificar y modelar estos patrones recurrentes, lo cual es esencial para mejorar la precisión de las predicciones a futuro (Box, Jenkins, Reinsel, & Ljung, 2016).

En los modelos ARIMA, la estacionalidad se maneja mediante la extensión del modelo a SARIMA (Seasonal ARIMA), que incluye términos adicionales para capturar los efectos estacionales. Estos modelos no solo consideran la dependencia entre los valores observados en intervalos consecutivos, sino que también tienen en cuenta las relaciones entre valores separados por un período de tiempo que coincide con el patrón estacional (por ejemplo, un año o un mes). Esto permite que el modelo ARIMA se ajuste mejor a Series de Tiempo con componentes estacionales, proporcionando predicciones que reflejan no solo la tendencia general, sino también las fluctuaciones estacionales regulares (Box, Jenkins, Reinsel, & Ljung, 2016).

En resumen, la estacionalidad es un componente clave en el modelado de Series de Tiempo que presentan patrones recurrentes a intervalos regulares, y los modelos ARIMA son extendidos a SARIMA para capturar estos efectos, mejorando así la

precisión de las predicciones a lo largo del tiempo (Box, Jenkins, Reinsel, & Ljung, 2016).

i) Dependencia Lineal: La dependencia lineal en una serie de tiempo se refiere a la relación lineal entre las observaciones de la serie en diferentes puntos en el tiempo. En términos de modelos autorregresivos, la dependencia lineal se captura mediante los coeficientes autorregresivos que indican cómo una observación pasada influye en una observación futura, es decir, la influencia de  $t$  en  $t - k$  (time-series-2015).

j) Aleatoriedad y Ruido Blanco: El término aleatoriedad se refiere a la imprevisibilidad inherente en una serie de tiempo. El ruido blanco es un tipo especial de proceso aleatorio con media cero, varianza constante y sin autocorrelación. En los modelos ARIMA, el término de error  $\epsilon_t$  se asume como ruido blanco (Box, Jenkins, Reinsel, & Ljung, 2016).

### **3.4 Técnicas de Estimación**

En esta tesis se plantea el desarrollo de pronósticos probabilísticos de las concentraciones de  $O_3$  en la CDMX de acuerdo con el contraste de valores asumiendo escenarios de presencia o no de las restricciones por la pandemia del COVID-19. Entonces, para desarrollar esto, se propone la construcción de modelos Autorregresivos Integrados de Medias Móviles (ARIMA) que son propicios para el análisis de series de datos temporales como son las concentraciones de  $O_3$  que son objeto de estudio. Para definir un modelo ARIMA, es necesario comprender los Modelos Autorregresivos y los Modelos de Medias Móviles.

#### **3.4.1 Procesos ARMA**

##### **3.4.1.1 Procesos Autorregresivos**

Un proceso AR (autorregresivo) se define a partir de un tipo de modelo de serie de tiempo en el que el valor actual de la serie se expresa como una función lineal de valores pasados. El proceso autorregresivo de primer orden, AR(1), se define como un

modelo en el cual el valor presente de la serie de tiempo es una función lineal de su valor inmediatamente anterior más un término de error. Matemáticamente, se expresa como:

Ecuación 3.4.1.

$$Z_t = \phi Z_{t-1} + \epsilon_t$$

donde  $\phi$  es el parámetro autorregresivo y  $\epsilon_t$  es el término de error, que se asume es ruido blanco con media cero y varianza constante. Escalando el orden del modelo, el modelo AR de orden  $p$ , donde  $p$  se denota como AR( $p$ ) y puede escribirse de la siguiente manera:

Ecuación 3.4.2.

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_{t-p} Z_{t-p} + \epsilon_t$$

donde  $\phi_i$  son los parámetros del modelo y  $\epsilon_t$  es el término de error (Box et al., 2016), a su vez, es importante notar que es ruido blanco con media cero y varianza constante (González Casimiro, 2009).

Algunas de las propiedades importantes a notar:

- **Media:** En un proceso autorregresivo estacionario, la media de la serie temporal es constante a lo largo del tiempo. En un proceso autorregresivo de orden  $p$  se puede calcular la media a partir de la relación:  $\mu = \frac{c}{1 - \sum_{i=1}^p \phi_i}$ , donde  $c$  es una constante (el término de constante en la ecuación autorregresiva) y  $\phi_i$  son los coeficientes autorregresivos. Para un proceso AR(1) con  $c = 0$ , la media es  $E(Z_t) = 0$  si el proceso es estacionario (Hamilton, 1994; González Casimiro, 2009).

Ya establecido que la media no varía con el tiempo y permanece fija en su valor esperado  $E(Z_t) = \mu$ . Para un AR(1) estacionario con  $c = 0$ , la media será  $E(Z_t) = 0$  si la condición  $|\phi| < 1$  se cumple, lo que garantiza que el proceso es estacionario en media

- **Varianza:** La varianza de un proceso autorregresivo estacionario se obtiene resolviendo la ecuación para la varianza condicional en función de las varianzas

pasadas. Para un AR(1), la varianza se calcula:  $\sigma_Z^2 = \frac{\sigma_a^2}{1 - \varphi^2}$ , donde  $\sigma_e^2$  es la varianza

del término de error  $\epsilon_t$ . En general, para un proceso AR(p), la varianza requiere resolver un sistema de ecuaciones que incluye los coeficientes  $\varphi_i$  (Box et al., 2015)

- Covarianza: La covarianza entre  $Z_t$  y  $Z_{t-k}$  en un proceso autorregresivo estacionario se define por la función de autocovarianza, que depende únicamente del número de retardos  $k$ . En un proceso AR(1), la covarianza entre  $Z_t$  y  $Z_{t-k}$  es:  $\gamma(k) = \varphi^k \cdot \sigma_Z^2$ . Esto implica que la correlación entre observaciones decrece geoméricamente conforme el número de retardos  $k$  aumenta. En procesos AR(p) más complejos, las covarianzas se determinan resolviendo el sistema de ecuaciones de Yule-Walker, que relaciona las autocovarianzas con los coeficientes  $\varphi_i$  (González Casimiro, 2009). Para un AR(1), la autocovarianza de retardo  $k$  está dada por:  $\gamma(k) = \varphi^k \cdot \sigma_Z^2$  esto implica que la covarianza entre observaciones disminuye de manera geométrica conforme aumenta el retardo  $k$ . En procesos AR(p), la función de autocovarianza puede calcularse resolviendo las ecuaciones de Yule-Walker, lo que permite obtener las covarianzas para cualquier retardo  $k$  (González Casimiro, 2009).

- Estacionariedad: Un proceso autorregresivo es estacionario si las características estadísticas, como la media y la varianza, son constantes en el tiempo. Para un proceso AR(p), la estacionariedad se garantiza si las raíces del polinomio autorregresivo se encuentran fuera del círculo unidad, lo que asegura que las perturbaciones desaparezcan con el tiempo y que la serie no tenga comportamientos explosivos (Box et al., 2015; González Casimiro, 2009).

Es fundamental analizar las propiedades de media, varianza, covarianza y estacionariedad en los procesos autorregresivos, ya que estas características determinan la estabilidad del modelo y su capacidad predictiva. Un modelo autorregresivo estacionario asegura que las relaciones entre observaciones pasadas y futuras sean consistentes en el tiempo, lo cual es esencial para realizar predicciones confiables. Si el modelo no es estacionario, las propiedades de la serie temporal pueden cambiar de manera impredecible, dificultando la interpretación de los

resultados y comprometiendo la validez de las predicciones (Box et al., 2015; González Casimiro, 2009).

La función de autocorrelación parcial (PACF) mide la correlación entre las observaciones de la serie de tiempo que están separadas por un determinado número de periodos, eliminando el efecto de las observaciones intermedias. Matemáticamente, la PACF en el retardo  $k$  se define como  $\phi_{kk}$  que es la solución a las ecuaciones de Yule-Walker para  $k$ . A su vez la estimación de la PACF se realiza ajustando sucesivamente modelos autorregresivos de órdenes crecientes mediante mínimos cuadrados y extrayendo las estimaciones de los últimos coeficientes en cada etapa. Alternativamente, se pueden utilizar estimaciones aproximadas de Yule-Walker cuando los parámetros no están demasiado cerca de las fronteras no estacionarias.

La PACF estimada se obtiene sustituyendo las estimaciones empíricas de las autocorrelaciones en las ecuaciones de Yule-Walker. Así mismo, los errores estándar de las estimaciones de la PACF dependen de la varianza de las estimaciones de los coeficientes autorregresivos. Estos errores estándar son cruciales para determinar la significancia de las correlaciones parciales estimadas y suelen calcularse mediante métodos numéricos o fórmulas asintóticas (Box et al., 2016).

#### **3.4.1.2 Procesos Medias Móviles**

Un modelo de media móvil (MA) de orden  $q$ , denotado como MA( $q$ ), es un tipo de modelo de serie temporal en el que el valor actual de la serie se expresa como una combinación lineal de los términos de error actuales y pasados. Esto significa que los valores pasados de los errores afectan el valor presente de la serie. Matemáticamente, se expresa como:

Ecuación 3.4.3.

$$Z_t = a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}$$

Donde  $\theta_i$  son los parámetros del modelo y  $a_t$  es un término de error que sigue un proceso de ruido blanco con media cero y varianza constante (Box et al., 2016).

Algunas de las propiedades importantes a notar:

- **Media:** En un proceso MA(q), la media de la serie temporal depende únicamente del término de error  $a_t$ . Si el proceso no tiene una constante, la media del proceso MA es cero. Esto ocurre porque los términos de error  $a_t$  tienen media cero. Sin embargo, si se introduce un término de constante en el modelo, la media se desplaza por esa constante.

- **Varianza:** La varianza en un proceso MA depende de los términos de error  $a_t$  y de los parámetros  $\theta_i$ . En un proceso MA(1), por ejemplo, la varianza del proceso puede calcularse como:  $\sigma_Z^2 = \sigma_a^2 \cdot (1 + \theta_1^2)$ , donde  $\sigma_a^2$  es la varianza del término de error. Para procesos de orden mayor, la varianza se calcula considerando los parámetros  $\theta_i$ , lo que incrementa la complejidad conforme aumenta el orden del proceso (Box et al., 2016).

- **Covarianza:** La covarianza entre los valores de la serie  $Z_t$  y  $Z_{t-k}$  en un modelo MA depende únicamente de los parámetros del modelo para retardos inferiores al orden  $q$ . Para retardos mayores que  $q$ , la covarianza es cero, ya que los términos de error no están correlacionados más allá de ese punto. Por ejemplo, en un MA(1), la covarianza para un retardo  $k = 1$  es:  $\gamma(1) = \theta_1 \cdot \sigma_a^2$ . Para  $k > 1$ , la covarianza es  $\gamma(k) = 0$ . Esto refleja la estructura de dependencia limitada en los modelos MA, donde los valores de la serie están correlacionados solo hasta un cierto número de periodos (Box et al., 2016).

- **Estacionariedad:** A diferencia de los procesos autorregresivos, los procesos MA son siempre estacionarios por construcción, ya que los términos de error  $a_t$  son ruido blanco, lo que implica que las características estadísticas (media, varianza y covarianza) no varían con el tiempo. Esto significa que un proceso MA(q) es estacionario sin necesidad de condiciones adicionales sobre los parámetros del modelo (González Casimiro, 2009).

En resumen, los modelos de media móvil (MA) son herramientas poderosas para capturar la dependencia entre los términos de error en una serie temporal. Su principal ventaja radica en su simplicidad y en que, a diferencia de los modelos autorregresivos,

son siempre estacionarios. Esto los hace útiles en situaciones donde las perturbaciones pasadas tienen un impacto limitado en el presente. Sin embargo, debido a la naturaleza de los modelos MA, la varianza y la covarianza dependen directamente de los parámetros  $\theta_i$ , lo que restringe la influencia a un número finito de periodos pasados. De esta manera, los modelos MA proporcionan una forma eficiente de modelar series temporales que muestran fluctuaciones rápidas y cortas (Box et al., 2016; González Casimiro, 2009).

### 3.4.1.3 Procesos Autorregresivos y de Medias Móviles

Continuando con el modelo ARMA (ARIMA no integrado) combina las características de los modelos AR y MA. Un modelo ARMA(p, q) se define como:

Ecuación 3.4.4.

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_{t-p} Z_{t-p} + \epsilon_t + a_t + \theta_1 a_{t-1} + a_t + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}$$

Donde  $\phi_i$  y  $\theta_i$  son los parámetros del modelo, a su vez  $\epsilon_t$  y  $a_t$  es ruido blanco (Box et al., 2016).

El modelo general ARMA se describió en la tesis de Peter Whittle Hypothesis Testing in Time Series Analysis (1951), y en el libro de George E. P. Box y Gwilym Jenkins Time Series Analysis: Forecasting and Control (1970). La ecuación ARMA es una herramienta estadística fundamental en el análisis de Series de Tiempo, ampliamente utilizada en diversos campos. La selección del modelo ARMA se debe a su capacidad para capturar la dependencia temporal y las estructuras estocásticas presentes en los datos.

Dada una serie de tiempo de datos  $X_t$ , que es estacionaria; el modelo ARMA es una herramienta para entender y, predecir probabilísticamente los valores futuros de esta serie. La parte AR implica la regresión de la variable sobre sus propios valores

rezagados  $\left( \sum_{i=1}^p \phi_i X_{t-i} \right)$ .

La parte de MA implica la modelización del término de error como una combinación lineal de términos de error que se producen contemporáneamente y en varios

momentos del pasado  $\left( \sum_{i=1}^1 \theta_i \cdot \epsilon_{t-i} \right)$ . (Box, Jenkins, Reinsel, & Ljung, 2016). Una serie

de tiempo se considera estacionaria cuando su media y varianza permanecen constantes a lo largo del tiempo y no presenta una tendencia sistemática ( $\mu = E[X_t]$ ,  $\sigma_X^2 = E[(X_t - \mu)^2]$ ) (Box & Jenkins, 1970), implicando que las propiedades estadísticas de la serie, como la media y la varianza, no dependen del momento en el que se observen, permitiendo un análisis más consistente y predictivo a lo largo del tiempo.

Así, se pueden definir a la varianza:  $var[X] = \left(\frac{\gamma_0}{N}\right)(1 + 2 \sum_{(k=1)}^{\infty} \rho_k)$  y a la función de

autocorrelación  $c_k = (\gamma_k) = \frac{1}{N} \sum_{t=1}^{N-k} (X_t - X)(X_{t+k} - X)$ , como métodos de evaluación de la

estacionariedad de segundo orden del proceso. En el caso de la función de autocovarianza y autocorrelación,  $k$  expresa el retardo del proceso en el que se evalúa la covarianza entre  $X_{t-k}$ ,  $X_t$  con expresión negativa en el primer término dado que se trata de funciones simétricas (Box & Jenkins, 1970).

La estacionalidad en una serie de tiempo se refiere a patrones recurrentes o ciclos que se repiten a intervalos regulares  $X_{t+s}$ ,  $X_t$  donde  $s$  expresa el dominio de la estacionalidad.

Los modelos ARMA se estiman comúnmente mediante el método Box-Jenkins, una metodología sistemática que implica identificar, estimar y diagnosticar modelos de Series de Tiempo. Este método comienza con la identificación de la estructura del modelo mediante el análisis de funciones de autocorrelación simple y parcial, que ayudan a determinar los valores apropiados de  $p$  y  $q$ . Una vez identificada la estructura, los parámetros del modelo se estiman y se evalúa la calidad del ajuste del modelo a los datos históricos.

### 3.4.2 Procesos ARIMA

En el análisis de Series de Tiempo, el método Box-Jenkins no solo se limita a modelos ARMA, sino que también incluye modelos ARIMA. Definiendo los modelos ARIMA son

una extensión de los modelos ARMA que incluyen un componente de integración para manejar Series de Tiempo no estacionarias. Un modelo ARIMA se denota como ARIMA(p, d, q). La fórmula general de un modelo ARIMA(p, d, q) es:

Ecuación 3.4.4.

$$\nabla^d z_t = \phi_1 \nabla^d z_{t-1} + \phi_2 \nabla^d z_{t-2} + \dots + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}$$

donde:

- $p$  es el orden del componente autorregresivo (AR).
- $d$  es el grado de diferenciación necesaria para hacer estacionaria la serie de tiempo.
- $q$  es el orden del componente de media móvil (MA).

Donde,  $\nabla^d$  es el operador de diferencia de orden  $d$  que se aplica para eliminar la tendencia y lograr la estacionariedad. Los términos  $a$  representan el ruido blanco, que es una secuencia de errores aleatorios con media cero y varianza constante.

En resumen, los modelos ARIMA son utilizados para modelar y predecir Series de Tiempo que presentan comportamientos no estacionarios, permitiendo transformar dichas series en estacionarias mediante la diferenciación y luego aplicar componentes autorregresivos y de media móvil para capturar las dependencias temporales (Box, Jenkins, Reinsel, & Ljung, 2016).

### 3.4.2.1 Procesos Autorregresivos Integrados

Los modelos ARI son una simplificación de los modelos ARIMA que sólo incluyen los componentes autorregresivo e integrado. Se denotan como ARI(p,d) y son útiles cuando no se necesita un componente de media móvil para modelar adecuadamente la serie de tiempo (time-series-2015).

### 3.4.2.2 Procesos Autorregresivos Integrados y de Medias Móviles

Para determinar la adecuación de un modelo ARMA o ARIMA, se analizan las funciones de autocorrelación simple y parcial, que permiten estimar el orden de los parámetros de autocorrelación. Este análisis es fundamental para definir correctamente las ecuaciones

del modelo y garantizar que capture adecuadamente las características subyacentes de la serie de tiempo. Este análisis se basa en el estudio de las estructuras de autocorrelación basado en pruebas estadísticas que a continuación se describen.

La ecuación de la prueba DFA incluye términos de retardos adicionales de la variable dependiente para controlar la autocorrelación. La forma general de la ecuación es:

Ecuación 3.5.1.

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \delta_1 \Delta y_{t-1} + \delta_2 \Delta y_{t-2} + \dots + \delta_p \Delta y_{t-p} + \epsilon_t$$

donde:

- $\Delta y$  es la primera diferencia de la serie de tiempo ( $y_t$ ).
- $t$  es una variable de tendencia.
- $y_{t-1}$  es el valor rezagado de la serie.
- $\alpha$  es el intercepto.
- $\beta$  es el coeficiente de la tendencia.
- $\gamma$  es el coeficiente que se prueba (la raíz unitaria).
- $\delta_i$  son los coeficientes de los términos rezagados de la diferencia de la serie.
- $\epsilon_t$  es el término de error.

Si el valor estadístico de DFA es más negativo que el valor crítico, se rechaza la hipótesis nula y se concluye que la serie es estacionaria, en cambio, si no se rechaza la hipótesis nula, se concluye que la serie tiene una raíz unitaria y no es estacionaria (Dickey & Fuller, 1979).

Prueba de Estacionariedad Kwiatkowski-Phillips-Schmidt-Shin (KPSS). Es una prueba estadística utilizada para evaluar la estacionariedad en una serie temporal. A diferencia de muchas otras pruebas de raíces unitarias, la prueba KPSS toma como hipótesis

nula que la serie de tiempo es estacionaria en torno a una media constante o una tendencia determinista.

Descripción de la Prueba KPSS:

- Hipótesis Nula (H0): La serie de tiempo es estacionaria en torno a una media constante o una tendencia determinista.

- Hipótesis Alternativa (H1): La serie de tiempo no es estacionaria (tiene una raíz unitaria). La prueba KPSS se basa en el análisis de la suma acumulativa de los residuos de una regresión de la serie de tiempo sobre una constante (para estacionariedad alrededor de una media) o una tendencia (para estacionariedad alrededor de una tendencia). La ecuación general es:

Ecuación 3.5.2.

$$y_t = \alpha + \beta t + u_t$$

donde:

- $y_t$  es la serie de tiempo en el tiempo ( $t$ ).
- $\alpha$  es el intercepto.
- $\beta$  es el coeficiente de la tendencia.
- $u_t$  es el término de error.

La estadística de la prueba KPSS se calcula como:  $KPSS = \frac{1}{T^2} \sum_{t=1}^T S_t^2$ .

Si el valor estadístico de KPSS es menor que el valor crítico, no se rechaza la hipótesis nula y se concluye que la serie es estacionaria, en cambio, si el valor estadístico de KPSS es mayor que el valor crítico, se rechaza la hipótesis nula y se concluye que la serie no es estacionaria (Kwiatkowski, Phillips, Schmidt & Shin, 1992).

### 3.4.3 Componente estacional en una ecuación ARMA o ARIMA

El componente estacional en una ecuación ARMA o ARIMA se refiere a la parte del modelo que captura los patrones cíclicos recurrentes en una serie de tiempo que se

repiten a intervalos regulares, como cada mes, trimestre o año. Este componente es esencial cuando se trabaja con datos que muestran variaciones estacionales, ya que permite que el modelo refleje no solo las tendencias y la variabilidad general, sino también los ciclos específicos que ocurren en intervalos temporales consistentes (Box, Jenkins, Reinsel, & Ljung, 2016).

En un modelo ARIMA, el componente estacional se introduce mediante la diferenciación estacional y la inclusión de términos estacionales autorregresivos y de media móvil. Estos términos son similares a los términos no estacionales, pero se aplican a las observaciones que están separadas por un período igual al patrón estacional identificado. Por ejemplo, en una serie con estacionalidad anual, los términos estacionales se aplican a los datos separados por 12 meses (Box, Jenkins, Reinsel, & Ljung, 2016).

La inclusión de un componente estacional en un modelo ARMA o ARIMA es crucial porque permite capturar la estructura completa de la serie de tiempo, mejorando la capacidad del modelo para hacer predicciones precisas que reflejan tanto las tendencias a largo plazo como los ciclos estacionales. Sin este componente, las predicciones podrían ignorar importantes patrones cíclicos, lo que llevaría a estimaciones inexactas (Box, Jenkins, Reinsel, & Ljung, 2016).

#### **3.4.4 Evaluación de ecuaciones de pronóstico**

El correcto desarrollo de pronósticos probabilísticos está determinado por la ecuación definida, ARMA o ARIMA, la cual se evalúa de entre un conjunto finito de ecuaciones candidatas. Para lograr esto, en este proyecto se utilizan los criterios bayesianos de ajuste de Akaike (AIC) y de Schwartz (BIC) los cuales determinan la propiedad de una ecuación a partir del número de parámetros definidos. Así, es posible contrastar diferentes órdenes de polinomios autorregresivos y de medias móviles. A continuación, se describen en forma breve tales criterios.

##### **3.4.4.1 Criterios bayesianos de evaluación**

###### **a) Criterio Bayesiano de Ajuste de Akaike (AIC).**

El Criterio Bayesiano de Ajuste de Akaike (AIC) es una medida utilizada en la selección de modelos estadísticos, particularmente en el contexto de modelos de Series de Tiempo como los modelos ARMA o ARIMA. Este criterio proporciona una manera de comparar la calidad de diferentes modelos que han sido ajustados a los mismos datos, ayudando a seleccionar el modelo que mejor balancea la precisión del ajuste con la simplicidad del modelo (Box, Jenkins, Reinsel, & Ljung, 2016).

El AIC penaliza la complejidad del modelo al incluir un término que aumenta con el número de parámetros del modelo, lo que previene el sobreajuste. Específicamente, el AIC se calcula como:  $AIC = 2k - 2\ln(L)$  (Box, Jenkins, Reinsel, & Ljung, 2016).

donde  $k$  es el número de parámetros en el modelo y  $L$  es la función de verosimilitud del modelo ajustado. El modelo con el AIC más bajo se considera el mejor, ya que sugiere que el modelo proporciona el mejor ajuste con el menor número de parámetros, evitando el sobreajuste (Box, Jenkins, Reinsel, & Ljung, 2016).

En el contexto de ARIMA, el AIC es particularmente útil porque permite comparar modelos con diferentes combinaciones de términos autorregresivos, de media móvil y de diferenciación. Esto ayuda a seleccionar un modelo que no solo se ajuste bien a los datos observados, sino que también sea parsimonioso, lo que es crucial para hacer predicciones robustas y generalizables (Box, Jenkins, Reinsel, & Ljung, 2016).

### **b) Criterio Bayesiano de Ajuste de Schwartz (BIC).**

El Criterio Bayesiano de Schwartz (BIC) es otro criterio utilizado en la selección de modelos estadísticos, similar al Criterio AIC, pero con una penalización más fuerte por la complejidad del modelo. El BIC es particularmente útil en el análisis de Series de Tiempo y se utiliza para comparar modelos como ARMA o ARIMA, ayudando a identificar el modelo que no solo se ajusta bien a los datos, sino que también es lo suficientemente simple para evitar el sobreajuste. El BIC se calcula utilizando la fórmula:  $BIC = \ln(n)k - 2\ln(L)$  (Box, Jenkins, Reinsel, & Ljung, 2016).

Donde  $n$  es el número de observaciones,  $k$  es el número de parámetros en el modelo, y  $L$  es la función de verosimilitud del modelo ajustado. A diferencia del AIC, el

BIC incluye el término  $\ln(n)$ , lo que significa que a medida que el tamaño de la muestra aumenta, la penalización por el número de parámetros se vuelve más significativa. Esto hace que el BIC favorezca modelos más simples, especialmente cuando se trabaja con grandes conjuntos de datos (Box, Jenkins, Reinsel, & Ljung, 2016).

En el contexto de ARIMA, el BIC es particularmente valioso porque ayuda a seleccionar un modelo que es lo suficientemente complejo para capturar las dinámicas de la serie de tiempo, pero lo suficientemente simple para no sobreajustarse a los datos observados. Al igual que con el AIC, el modelo con el BIC más bajo se considera óptimo (Box, Jenkins, Reinsel, & Ljung, 2016).

#### **3.4.4.2 Análisis de residuos de la ecuación**

El correcto desarrollo de pronósticos probabilísticos está determinado por las propiedades de la ecuación definida. Para esto se recurre al estudio de las propiedades estadísticas de los residuos de estimación: independencia, normalidad y homocedasticidad.

##### a) Pruebas de independencia de residuos.

En cuanto a la prueba independencia lineal de las observaciones del proceso, se estima el estadístico de Ljung-Box.

Prueba de Independencia Ljung-Box. Es una prueba estadística utilizada para verificar si una serie de tiempo presenta autocorrelación en los residuos de un modelo ajustado. Esta prueba evalúa la hipótesis nula de que las observaciones en la serie de tiempo no están autocorrelacionadas hasta un cierto retraso  $m$ .

- Hipótesis Nula ( $H_0$ ): No hay autocorrelación significativa en los residuos de la serie de tiempo hasta el retraso  $m$ .

- Hipótesis Alternativa ( $H_1$ ): Hay autocorrelación significativa en los residuos de la serie de tiempo hasta el retraso  $m$ .

La prueba Ljung-Box utiliza el siguiente estadístico de prueba:

Ecuación 3.5.3.

$$Q = n(n + 2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{n - k}$$

donde:

- $n$  es el tamaño de la muestra.
- $m$  es el número de retardos que se están probando.
- $\hat{\rho}_k$  es la autocorrelación muestral en el retraso o retardo  $k$ .

Distribuida por una  $\chi$  con  $m$  grados de libertad bajo  $H_0$ .

Si el valor  $Q$  calculado es mayor que el valor crítico de la distribución, se rechaza la  $H_0$ , indicando que hay autocorrelación significativa, en cambio, si el valor  $Q$  calculado es menor o igual al valor crítico, no se rechaza la hipótesis nula, indicando que no hay evidencia suficiente de autocorrelación en los residuos (Ljung & Box, 1978).

b) Pruebas de normalidad de residuos.

En cuanto a la prueba normalidad asintótica de los residuos de estimación se desarrolla el estadístico de normalidad propuesto por Jarque y Bera (1980).

Prueba de Normalidad Jarque Bera. Es una prueba estadística utilizada para verificar si una muestra de datos tiene una distribución normal basándose en las medidas de asimetría y curtosis. Esta prueba es especialmente útil en el análisis de regresión y en la evaluación de modelos econométricos.

- Hipótesis Nula ( $H_0$ ): Los datos tienen una distribución normal.
- Hipótesis Alternativa ( $H_1$ ): Los datos no tienen una distribución normal.

La estadística de la prueba Jarque-Bera (JB) se calcula de la siguiente manera:

Ecuación 3.5.4.

$$JB = n \left( \frac{S^2}{6} + \frac{(K - 3)^2}{24} \right).$$

donde:

- $n$  es el tamaño de la muestra.

- $S$  es el coeficiente de asimetría de la muestra.
- $K$  es el coeficiente de curtosis de la muestra.

El coeficiente de asimetría mide la simetría de la distribución de los datos, mientras que el coeficiente de curtosis mide la “aplanamiento” de la distribución.

Si el valor de JB es mayor que el valor crítico de la distribución con 2 grados de libertad, se rechaza la hipótesis nula, indicando que los datos no siguen una distribución normal. Si el valor de JB es menor o igual al valor crítico, no se rechaza la hipótesis nula, indicando que no hay evidencia suficiente para concluir que los datos no son normales.

#### c) Pruebas de heterocedasticidad de residuos.

En cuanto a la homocedasticidad de los residuales de estimación se desarrolla el estadístico de Breusch-Pagan (1979). Este estadístico permite calcular la suficiencia de un estimador lineal para el cuadrado de los residuos de estimación.

Prueba de heterocedasticidad de Breusch y Pagan. Es una prueba estadística utilizada para verificar si una muestra de datos es heterocedástica. Esta prueba es especialmente útil para verificar que los residuos de estimación varían de forma constante.

- Hipótesis Nula (H0): Los datos no son heterocedásticos.
- Hipótesis Alternativa (H1): Los datos son heterocedásticos

La estadística de la prueba Breusch-Pagan (BP) se calcula de la siguiente manera:

Ecuación 3.5.5.

$$\widehat{u^2} = \gamma_0 + \gamma_1 x + \nu$$

Donde:

- $\widehat{u^2}$  es el cuadrado de los residuos de estimación
- $\gamma_0$  es el intercepto de una función lineal.
- $\gamma_1$  es la pendiente de la función lineal.

Si el valor de BP es mayor que el valor crítico de la distribución F, se acepta la hipótesis nula, indicando que los datos no son heterocedásticos.

### **3.5 Aplicación de la metodología propuesta**

Descrito anteriormente, la metodología a seguir en este proyecto es la propuesta por Box y Jenkins con lo cual pueden definirse modelos de pronósticos y posibles valores futuros de los indicadores de  $O_3$ . Dado que se tienen dos mediciones del contaminante:

1. Partes por millón de promedio móvil de 8 horas de  $O_3$ , 2. Los promedios diarios, se desarrollan modelos de pronósticos de serie de tiempo independientes a cada conjunto de datos. Es decir, se aplica la Metodología Box-Jenkins a cada conjunto de valores del  $O_3$  considerando siempre la presencia de estacionalidad en los indicadores que ya fue definida en la bibliografía consultada (Thompson et al., 2008; Matias Gutierrez et al., 2023).

#### **3.5.1 Aplicación de la metodología propuesta al Conjunto de Datos 1.**

Aplicando la metodología paso a paso:

##### **1. Recopilación de Datos (Conjunto de Datos 1)**

- Datos base: Se seleccionó el promedio móvil máximo de 8 horas de las concentraciones de  $O_3$ . Obtenidos de la Dirección de la Calidad del Aire del Gobierno de la Ciudad de México, con datos mensuales del periodo de 2015 a 2020.

##### **2. Análisis Exploratorio de los Datos:**

- Gráfico de la evolución temporal: Primero, se procede a graficar la evolución de la serie de tiempo para identificar posibles patrones de tendencia, estacionalidad, y fluctuaciones aleatorias en las concentraciones de ozono.

- Descomposición aditiva de la serie: Se aplica una descomposición aditiva para poder aislar los componentes de tendencia, estacionalidad y ruido de la serie de tiempo.

### 3. Evaluación de la Estacionariedad del Proceso

- Pruebas de raíz unitaria: Se realizan pruebas de raíz unitaria (ADF y KPSS) para verificar si la serie temporal es estacionaria.

- Transformación para estacionariedad: Se aplican diferencias estacionales a la serie de tiempo para eliminar la tendencia estacional, esto se corrobora en gráficos de autocorrelación y autocorrelación parcial tras las diferencias.

### 4. Identificación del Modelo ARMA Estacional

- Autocorrelación estacional y no estacional: Con los correlogramas obtenidos, se identifica el orden de los términos autorregresivos (AR), de medias móviles (MA) y de diferenciación (I) tanto para la parte no estacional como para la parte estacional del modelo.

- Selección del modelo: Con base en los correlogramas y las pruebas realizadas, se selecciona un modelo

### 5. Estimación del Modelo SARMA (1,0,2)(0,0,1)<sub>e</sub>

- Estimación de parámetros: Se estiman los parámetros del modelo seleccionado usando técnicas de máxima verosimilitud. Los resultados de las estimaciones se usan para validar la estructura del modelo.

- Análisis de residuos: Se evalúan los residuos del modelo para asegurarse de que estos no presenten autocorrelación, indicando que el modelo ha capturado correctamente la estructura de la serie de tiempo. Las pruebas Ljung-Box y Shapiro-Wilk ayudan a confirmar la independencia y normalidad de los residuos.

### 6. Pronósticos de las Concentraciones de Ozono con el Modelo SARMA

- Generación de pronósticos: Usando el modelo seleccionado, para generar pronósticos para las concentraciones de ozono troposférico para los meses restantes de 2020, suponiendo que la pandemia no hubiera ocurrido.

#### **3.5.2 Aplicación de la metodología propuesta al Conjunto de Datos 2.**

Aplicando la metodología paso a paso:

## 1. Recopilación de Datos (Conjunto de Datos 2)

- Fuente de datos: El segundo conjunto de datos se obtuvo de las mediciones diarias de las concentraciones de  $O_3$  en la Ciudad de México, disponibles en la plataforma de la Red Automática de Monitoreo Atmosférico del Gobierno de la Ciudad de México gracias a la Institución SEDEMA. Este conjunto de datos incluye observaciones diarias desde 2015 hasta 2020.

- Datos base: A diferencia del Conjunto de Datos 1 (mediciones mensuales), este segundo conjunto incluye mediciones diarias de  $O_3$ , lo que permite un análisis de Series de Tiempo diferente.

## 2. Análisis Exploratorio de los Datos

- Gráfico de la evolución temporal: Se grafica la evolución de la serie de tiempo con observaciones diarias para identificar patrones como tendencias a largo plazo, ciclos estacionales, y fluctuaciones diarias en las concentraciones de ozono.

- Descomposición de la serie: Se aplica una descomposición aditiva para poder aislar los componentes de tendencia, estacionalidad y ruido de la serie de tiempo.

## 3. Evaluación de la Estacionariedad del Proceso

- Pruebas de estacionariedad (ADF y KPSS): Se realizan las pruebas de raíz unitaria para verificar la estacionariedad de la serie.

- Diferencias para estacionariedad: Para asegurar la estacionariedad, se aplican diferencias tanto a nivel no estacional como estacional.

## 4. Identificación del Modelo ARIMA Estacional

- Correlogramas: Con los correlogramas de autocorrelación simple y autocorrelación parcial tras las diferencias, se identifica la estructura del modelo más adecuado para capturar la estacionalidad de la serie. Los picos significativos en ciertos rezagos indican los componentes AR y MA.

- Selección del modelo ARIMA estacional: Basado en los análisis de los correlogramas, se selecciona un modelo con mejor ajuste para el Conjunto de Datos 2.

## 5. Estimación del Modelo escogido

- Estimación de parámetros: Se procede a la estimación de los parámetros del modelo seleccionado utilizando máxima verosimilitud. Los coeficientes de los términos AR y MA.

- Análisis de residuos: Posteriormente, se analizan los residuos del modelo para asegurar que no presenten autocorrelación significativa, lo cual indicaría que el modelo capturó correctamente la dinámica de la serie de tiempo.

- Se aplican las pruebas Ljung-Box y Shapiro-Wilk confirman normalidad e independencia.

## 6. Pronósticos de las Concentraciones de Ozono con el Modelo seleccionado.

- Generación de pronósticos: Usando el modelo seleccionado, se generan pronósticos diarios para las concentraciones de ozono troposférico en la Ciudad de México durante los meses restantes de 2020.

### **3.6 Justificación de la Selección de la Metodología ARIMA**

La metodología ARIMA es ampliamente reconocida y utilizada en el análisis de Series de Tiempo debido a su capacidad para modelar datos dependientes en el tiempo y para generar pronósticos confiables en una amplia variedad de contextos. En el presente estudio, la elección de ARIMA como la metodología principal de pronóstico para las concentraciones de ozono troposférico en la Ciudad de México se justifica por varias razones clave:

#### 1. Capacidad para Manejar Datos No Estacionarios

- Uno de los desafíos principales al trabajar con Series de Tiempo, especialmente en el contexto ambiental, es la no estacionariedad de los datos, es decir, la tendencia a que las medias y varianzas cambien con el tiempo. Los modelos ARIMA son particularmente efectivos porque permiten aplicar transformaciones, como la diferenciación, para convertir una serie no estacionaria en estacionaria. Dado que las

concentraciones de ozono troposférico presentan una tendencia no estacionaria, tanto en sus niveles diarios como mensuales, la metodología ARIMA es adecuada porque puede transformar estas series y hacerlas aptas para el análisis predictivo.

## 2. Incorporación de Componentes Estacionales

- El comportamiento de las concentraciones de  $O_3$  está altamente influenciado por patrones climáticos y estacionales, como el aumento de la radiación solar en ciertos meses y las variaciones climáticas a lo largo del año. La versión estacional del modelo ARIMA, denominada SARIMA, permite la incorporación de componentes estacionales en el modelo, lo que es crucial para capturar estos ciclos recurrentes en la serie de tiempo.

- En este caso, la capacidad del modelo SARIMA para incluir términos estacionales (como los polinomios autorregresivos y de medias móviles estacionales). Este aspecto permite generar pronósticos precisos para los picos estacionales de  $O_3$ , ajustando correctamente las fluctuaciones regulares del contaminante.

## 3. Flexibilidad y Capacidad de Ajuste a Diferentes Dinámicas

- Los modelos ARIMA son extremadamente flexibles porque pueden ajustarse a diferentes tipos de Series de Tiempo mediante la combinación de términos AR y MA, y de diferenciación (I). Esta flexibilidad es crucial cuando se trabaja con Series de Tiempo ambientales, donde los patrones pueden variar significativamente de un año a otro debido a factores como las condiciones meteorológicas, las variaciones en las fuentes de emisiones, el incremento de cambio climático debido a el calentamiento global o los eventos extremos.

## 4. Herramientas de Validación y Análisis de Residuos

- Una de las fortalezas del enfoque ARIMA es su integración con herramientas de validación rigurosas, como los análisis de residuos y las pruebas de autocorrelación (Ljung-Box). Esto es especialmente importante en Series de Tiempo donde el ajuste del modelo debe ser evaluado cuidadosamente para asegurar que no quedan patrones sin modelar.

## 5. Comparación con Otros Modelos Alternativos

- Aunque existen otras metodologías de pronóstico de Series de Tiempo, como las redes neuronales recurrentes o los modelos de suavizamiento exponencial, el modelo ARIMA tiene varias ventajas sobre estos en términos de interpretabilidad y sencillez de implementación. La estructura del modelo ARIMA es transparente y permite una fácil interpretación de los coeficientes, lo que resulta útil para entender los factores que influyen en las concentraciones de ozono.

- Además, los modelos de ARIMA han sido extensamente probados en contextos ambientales y meteorológicos, y su simplicidad hace que sean computacionalmente eficientes, algo importante cuando se trabaja con grandes cantidades de datos como en este estudio.

## 6. Capacidad para Generar Pronósticos Confiables

- Finalmente, la principal razón para seleccionar ARIMA en este estudio es su capacidad probada para generar pronósticos confiables. Los pronósticos de Series de Tiempo con ARIMA son utilizados en diversas aplicaciones, y su robustez está bien documentada.

La metodología ARIMA fue seleccionada para este estudio debido a su capacidad para manejar Series de Tiempo no estacionarias, su flexibilidad para incorporar componentes estacionales, su robustez en la validación y análisis de residuos, y su eficacia probada para generar pronósticos confiables en el contexto ambiental. En un escenario donde las concentraciones de ozono son afectadas por múltiples factores, incluyendo la estacionalidad y la variabilidad climática, ARIMA se presenta como la herramienta más adecuada para capturar y predecir las fluctuaciones de este contaminante atmosférico en la Ciudad de México.

### **3.7 Conclusiones del capítulo**

En resumen, el análisis y modelado de Series de Tiempo utilizando técnicas como los modelos ARMA y ARIMA y el método Box-Jenkins es esencial para comprender las

estructuras temporales de los datos y hacer predicciones precisas. Estas metodologías se basan en la identificación y estimación de patrones recurrentes y dependencias en los datos históricos, permitiendo una mejor comprensión y proyección de comportamientos futuros. Los procedimientos descritos anteriormente se desarrollaron para el logro de los pronósticos de esta tesis.

## Capítulo 4. Análisis de los Niveles de Ozono Troposférico en la Ciudad de México durante 2020

### 4.1 Introducción al capítulo

El objetivo de este capítulo es desarrollar un modelo predictivo que permita pronosticar las concentraciones de  $O_3$  en la CDMX de acuerdo con los dos conjuntos de datos disponibles. Los modelos desarrollados ponen énfasis en el período de abril a diciembre de 2020, ya que este intervalo de tiempo coincide con los meses más afectados por las restricciones en la movilidad y actividades socioeconómicas de la emergencia sanitaria derivada de la pandemia de COVID-19. El análisis se centra en la construcción de un modelo robusto que capture las variaciones y tendencias en los niveles de  $O_3$ , con el fin de entender mejor el impacto de las restricciones de movilidad y otras medidas sanitarias dadas las condiciones atípicas de 2020.

Los pronósticos que se realizan buscan determinar si es que las reducciones en la actividad vehicular e industrial durante los confinamientos tuvieron un impacto significativo en la disminución de los niveles de  $O_3$ . Esta investigación busca aportar evidencia cuantitativa y cualitativa a esta hipótesis, ofreciendo una visión detallada del comportamiento del  $O_3$  bajo condiciones excepcionales.

En las subsecciones siguientes, se detallará la metodología empleada para el desarrollo del modelo predictivo, se presentarán los resultados obtenidos y se discutirán sus implicaciones. Este análisis proporcionará una base sólida para futuras investigaciones y para aportar elementos mínimos que contribuyan a la formulación de políticas públicas enfocadas a la mejora de la calidad del aire en entornos urbanos.

### 4.2 Metodología: Modelo Box-Jenkins

En esta sección, se describirán los pasos seguidos para el procesamiento de los datos, así como las técnicas empleadas para el desarrollo del modelo predictivo, es decir, se presenta el análisis descriptivo de los datos analizados. Se emplearon métodos de Series de Tiempo, específicamente la metodología Box-Jenkins, también conocida

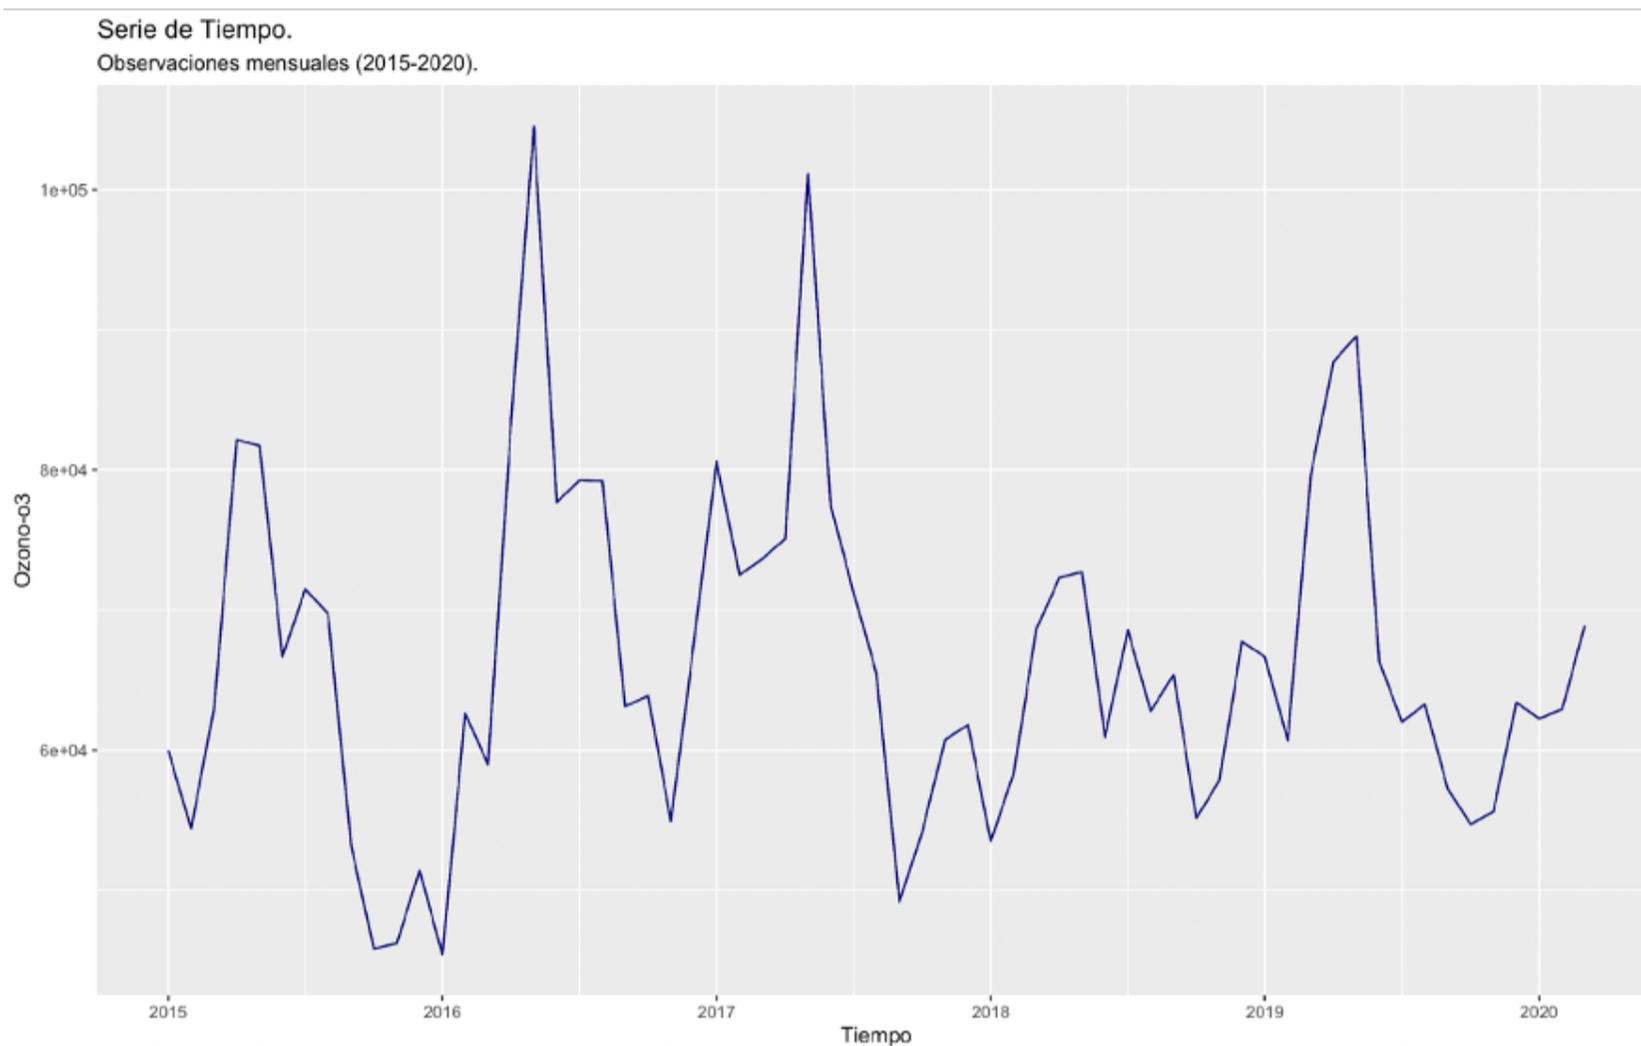
como la familia de modelos ARIMA dado que esta metodología permite construir pronósticos de un indicador con observaciones temporales. En adelante, la serie de observaciones de promedio de ocho horas se definen como Conjunto de Datos 1, mientras que las observaciones 2 se definen como Datos 2. En términos expositivos, primero se presenta el análisis y los pronósticos del Conjunto Datos 1 y luego, se pasa al conjunto Datos 2.

#### **4.2.1 Metodología Box-Jenkins: Conjunto de Datos 1.**

El gráfico 4.1 muestra las observaciones mensuales de las concentraciones de  $O_3$  en la CDMX durante el período comprendido entre 2015 y 2020. Este gráfico revela variaciones significativas en las concentraciones de  $O_3$  a lo largo del tiempo, con máximos notables en ciertos períodos, por otra parte, se observa una tendencia general de aumentos y disminuciones cíclicas en las concentraciones de ozono, lo que puede estar asociado con factores estacionales y cambios en las condiciones atmosféricas y en las actividades humanas.

Estos máximos pueden estar correlacionados con episodios de alta contaminación, posiblemente influenciados por condiciones climáticas desfavorables y aumentos en las emisiones vehiculares e industriales. Se muestra una variabilidad considerable en las concentraciones de  $O_3$  de un año a otro, indicando la influencia de múltiples factores sobre la calidad del aire.

Gráfico 4.1 Evolución de la serie de tiempo: Conjunto de Datos 1.



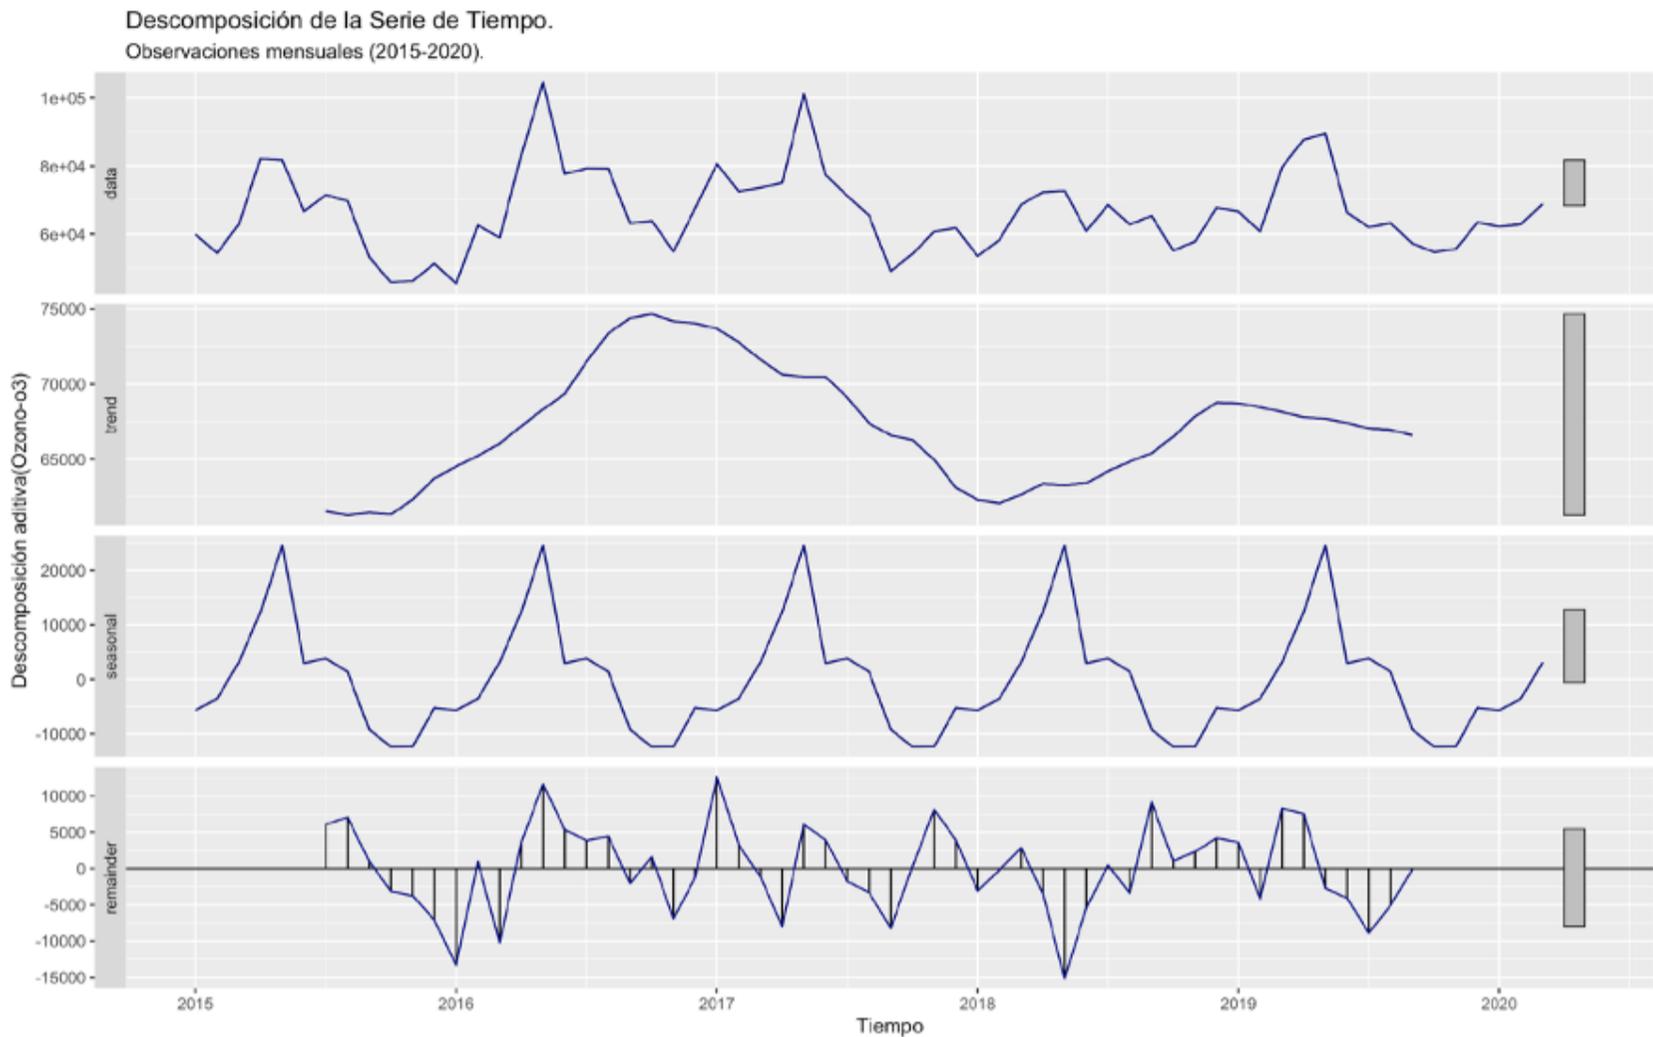
Fuente: Elaboración propia usando los datos del Gobierno de la Ciudad de México.

Observando el comportamiento de la serie, y en términos descriptivos, se realiza una descomposición de la serie de tiempo lo que permite tener una comprensión más profunda de los elementos constituyentes de la serie. Dada la presencia de aparente estacionalidad, se muestra el proceso de descomposición aditiva de la serie de tiempo.

La descomposición aditiva proporciona una visión clara de los diferentes componentes que influyen en las concentraciones de  $O_3$ , permitiendo una mejor comprensión de los factores subyacentes y se remarca el componente estacional confirma la fuerte influencia de los ciclos naturales del año en los niveles de ozono, mientras que los residuos indican la presencia de variaciones no explicadas por los otros componentes.

Este análisis es crucial para el desarrollo de modelos predictivos, ya que permite aislar y comprender mejor los diferentes factores que afectan la calidad del aire (Gráfico 4.2).

Gráfico 4.2 Descomposición Aditiva: Conjunto de Datos 1.



Fuente: Elaboración propia usando los datos del Gobierno de la Ciudad de México.

La descomposición aditiva divide la serie de tiempo original en tres componentes: tendencia, estacionalidad y residuo. A continuación, se describen tales componentes de acuerdo con lo observado en el gráfico anterior.

1. Tendencia: representa la dirección general de los datos a lo largo del tiempo, eliminando las variaciones estacionales y aleatorias, donde sugiere un incremento inicial en las concentraciones de ozono, seguido por un periodo de estabilización o reducción que podría estar vinculado a medidas de control de emisiones o a las restricciones impuestas por el gobierno capitalino.

2. Estacionalidad: Esta refleja los patrones recurrentes y predecibles en los datos que se repiten en intervalos regulares. Los máximos y mínimos en el componente estacional indican que las concentraciones de  $O_3$  siguen un patrón cíclico anual, con valores más altos en ciertos meses del año y más bajos en otros. Esto es coherente con la influencia de factores de las estaciones y otros entes naturales, como la

radiación solar y las temperaturas, que afectan la formación y descomposición del  $O_3$ . Se observa un patrón estacional claro, con picos pronunciados que suelen ocurrir en los meses de abril y mayo, antes de las lluvias que disipan los contaminantes incluyendo el  $O_3$ .

3. Residuos: muestra el componente residual que representa las fluctuaciones en los datos que no pueden ser explicadas por la tendencia o la estacionalidad. Estos residuos son los componentes aleatorios o ruidosos de la serie de tiempo, que, a su vez permiten evaluar la calidad del modelo de descomposición, ya que un buen modelo dejará residuos pequeños y sin patrones obvios. En el gráfico, los residuos fluctúan alrededor de cero, aunque se observan algunos máximos y mínimos notables, especialmente en los años 2016 y 2018, lo que indica eventos extraordinarios o cambios abruptos que no siguen los patrones de tendencia y estacionalidad.

#### **4.2.1.1 Análisis de la ecuación de Pronóstico: Conjunto de Datos 1.**

En esta subsección, se presentan los resultados del modelo ARIMA seleccionado para el pronóstico de las concentraciones de  $O_3$  en la CDMX del Conjunto de Datos 1 (mediciones de máximos diarios de 8 horas promediadas mensualmente). El modelo fue ajustado utilizando datos históricos de las concentraciones de  $O_3$ , y su desempeño fue evaluado mediante diversas métricas de error de pronóstico lo cual permite proporcionar estimaciones precisas de los niveles futuros de  $O_3$  para el período de abril a diciembre de 2020, permitiendo así una mejor planificación y gestión de la calidad del aire en la ciudad.

A su vez, se detalla el proceso de pronóstico, incluyendo la validación del modelo y la presentación de los resultados obtenidos. Se incluyen gráficos comparativos que muestren las predicciones del modelo en relación con las observaciones reales, así como un análisis de la precisión del modelo utilizando métricas como el Error Cuadrático Medio (MSE) y el Error Absoluto Medio (MAE). Además, se discutirán las implicaciones de los pronósticos en el contexto de las medidas sanitarias implementadas durante la pandemia de COVID-19 y su impacto en la calidad del aire.

En el apartado siguiente se presenta el análisis de estacionariedad del proceso que, establecido en el capítulo 3, es la base en el análisis y determinación de la ecuación ARMA o ARIMA subyacente al proceso en estudio.

#### 4.2.2.1 Estacionariedad del Proceso: Conjunto de Datos 1.

Para evaluar la estacionariedad de la serie de tiempo, se realizaron diversas pruebas de raíces unitarias y de estacionariedad en torno a nivel y tendencia. Las pruebas seleccionadas fueron la prueba de Dickey-Fuller Aumentada (DFA) y las pruebas de Kwiatkowski-Phillips Schmidt-Shin (KPSS) tanto para la estacionariedad en tendencia como en nivel.

Tabla 4.1 Pruebas de Estacionariedad en la Serie de Tiempo: Conjunto de Datos 1.

Prueba	Estadístico	Significancia	Conclusión
ADF	-4.049	0.019	Estacionario
KPSS (Tendencia)	0.054	$\geq 0.1$	Estacionario en torno a Tendencia.
KPSS (Nivel)	0.058	$\geq 0.1$	Estacionario en torno a Nivel.

Fuente: Elaboración propia usando los datos del Gobierno de la Ciudad de México.

Gracias a los datos de la Tabla 4.1, se puede notar:

- Los resultados de la prueba DFA indican que el valor de la probabilidad de error estadístico de tipo I es menor que el nivel de significancia de 0.05, lo que proporciona evidencia suficiente para rechazar la hipótesis nula de no estacionariedad. Por lo tanto, la serie temporal de las concentraciones de  $O_3$  puede ser considerada como estacionaria según esta prueba.
- Los resultados de la prueba KPSS en torno a la tendencia muestran que el valor estadístico de tipo I es mayor que el nivel de significancia de 0.1, indicando que no se puede rechazar la hipótesis nula de estacionariedad en tendencia. Por lo tanto, la

serie temporal de las concentraciones de  $O_3$  es estacionaria en torno a una tendencia lineal.

- Los resultados de la prueba KPSS en torno a Nivel muestran que el valor p es mayor que el nivel de significancia de 0.1, indicando que no se puede rechazar la hipótesis nula de estacionariedad en tendencia. Por lo tanto, la serie temporal de las concentraciones de  $O_3$  es estacionaria en torno a una tendencia.

Las pruebas DFA y KPSS proporcionan evidencia coherente de que la serie temporal de las concentraciones de  $O_3$  es estacionaria, tanto en torno a una tendencia como en un nivel constante. Estos resultados justifican el uso de modelos ARMA para el análisis y pronóstico de los niveles de  $O_3$ , permitiendo desarrollar ecuaciones que capturen adecuadamente las dinámicas de la serie de tiempo.

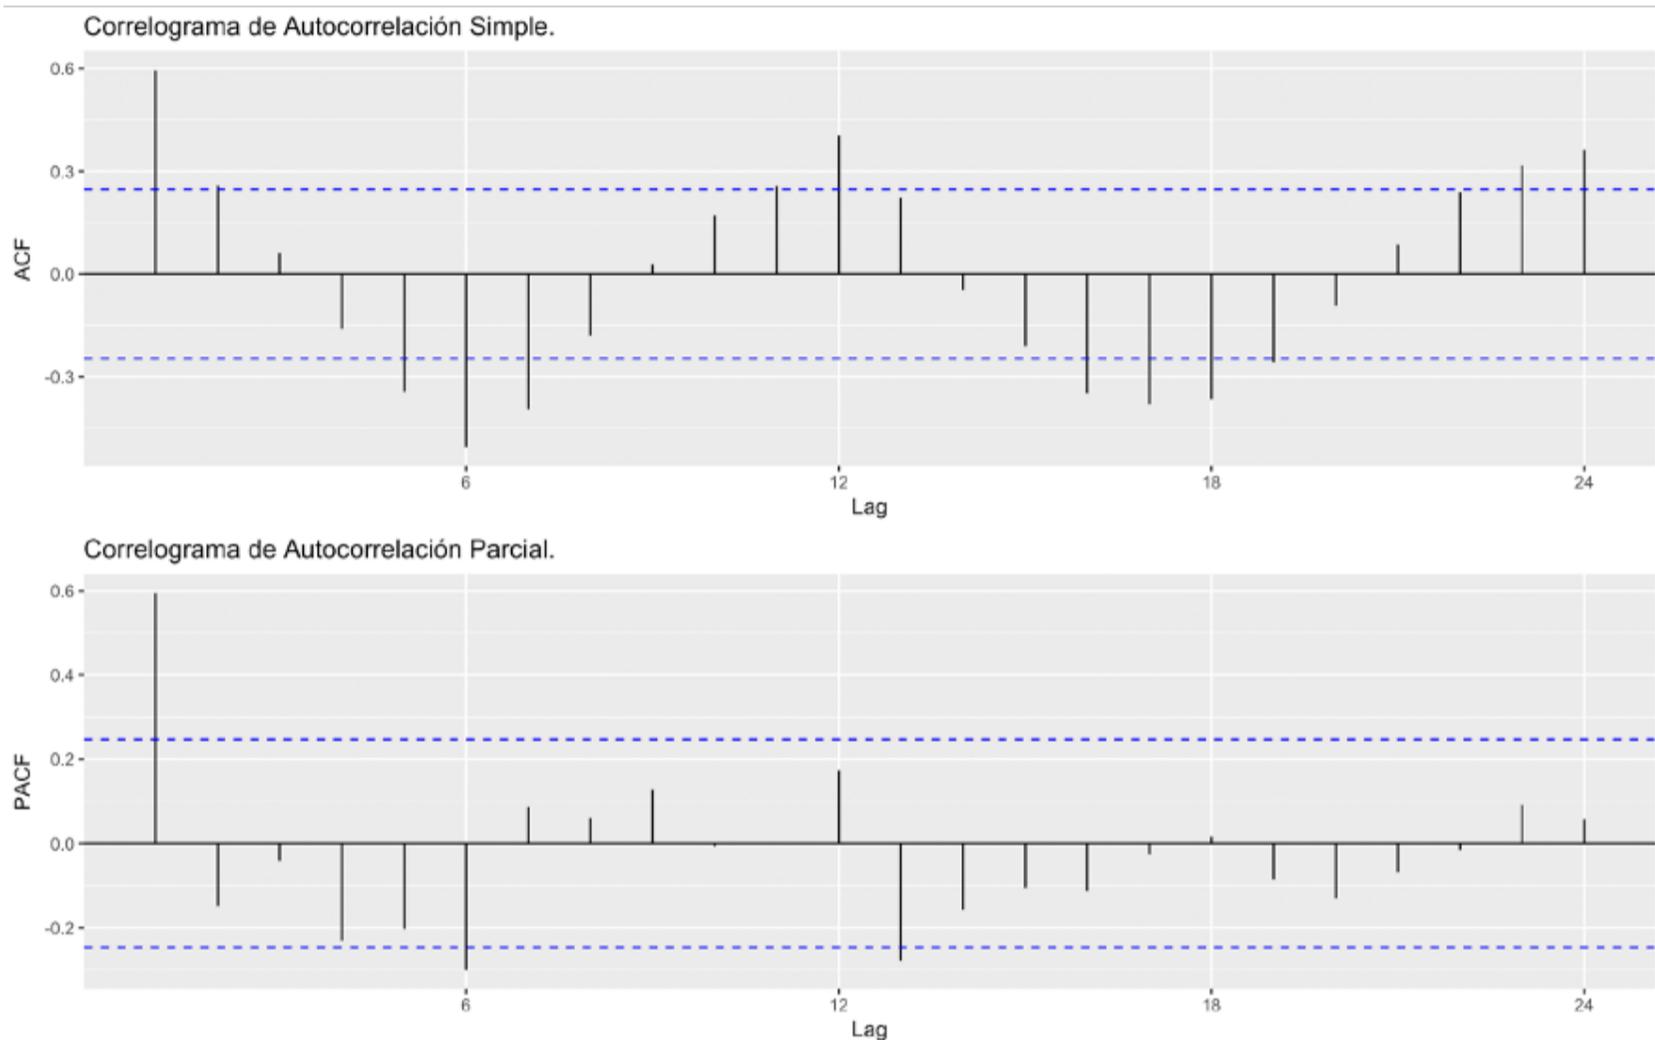
Siguiendo la propuesta en la metodología de Box-Jenkins, en el apartado siguiente se presenta el análisis de correlación. Este análisis permite determinar los componentes autorregresivos y de medias móviles subyacentes al proceso lo cual determina la ecuación no estacional de pronóstico. Es importante recordar que, de acuerdo con el análisis de descomposición del proceso en este se identifica un elemento de estacionalidad por lo que la ecuación final tendría una componente no estacional y una estacional.

#### **a) Análisis de Autocorrelación no estacional: Conjunto de Datos 1.**

Los correlogramas, que representan las funciones de autocorrelación (FAC) y autocorrelación parcial (FACP) de una serie temporal, son herramientas esenciales en la metodología Box-Jenkins para identificar la estructura adecuada de un modelo ARIMA. Estas herramientas permiten visualizar las dependencias temporales en los datos, proporcionando información crítica para la selección de los términos autorregresivos (AR), de diferenciación (I) y de medias móviles (MA). Recalcando que, si una serie de tiempo ya es estacionaria, se puede descartar un modelo ARIMA en favor de un modelo ARMA más simple, evitando la inclusión innecesaria de términos de diferenciación.

El Gráfico 4.3 contiene las FAC y las FACP. Estas funciones son herramientas fundamentales en la metodología Box-Jenkins para la identificación de los componentes del modelo ARIMA para conjunto de Datos 1.

Gráfico 4.4 Correlogramas de Autocorrelación Simple y Parcial: Conjunto de Datos 1.



Fuente: Elaboración propia usando los datos del Gobierno de la Ciudad de México.

Del gráfico anterior puede observarse lo siguiente:

- Gráfico de las FAC: mide la correlación entre los valores de la serie temporal y sus valores rezagados. Se procede a identificar la estructura de dependencia a lo largo del tiempo, en este caso, muestra picos significativos en los primeros rezagos, lo que indica una fuerte correlación entre los valores de la serie de tiempo y sus rezagos más recientes. Se observa que el primer rezago presenta una autocorrelación positiva significativa, mientras que en rezagos posteriores la autocorrelación disminuye y oscila alrededor de cero, con algunos rezagos mostrando autocorrelaciones negativas significativas. Esta estructura sugiere que un modelo que incluya términos AR y/o MA podría ser adecuado para capturar la dinámica de la serie de tiempo.

- Gráfico de la FACP: mide la correlación entre los valores de la serie temporal y sus rezagos, eliminando el efecto de los valores intermedios. Es particularmente útil para identificar el orden de los términos AR en el modelo ARIMA. La PACF muestra un pico significativo en el primer rezago, lo que sugiere la presencia de un componente autorregresivo de primer orden (AR (1)). Después del primer rezago, los valores de la PACF disminuyen rápidamente y no muestran autocorrelaciones significativas en rezagos posteriores. Este comportamiento es consistente con la identificación de un modelo ARIMA (1,0,0), indicando que un solo término autorregresivo sería suficiente para modelar la serie temporal.

Para la selección de un modelo los gráficos de las FAC y de las FACP son herramientas complementarias que ayudan a identificar la estructura apropiada para el modelo ARIMA. Basados en las observaciones:

I. La ACF sugiere la presencia de autocorrelaciones significativas en los primeros y últimos rezagos, apoyando la inclusión de términos AR y/o MA en el modelo.

II. La PACF, con un pico significativo en el primer rezago, indica que un modelo AR (1) sería adecuado.

La combinación de los resultados de las funciones de autocorrelación simple y parcial sugiere que un modelo ARIMA (1,0,0) es un buen punto de partida para el modelado de las captaciones de  $O_3$ . Este modelo capturaría las dependencias lineales entre los valores de la serie de tiempo, proporcionando una base sólida para el pronóstico de esta.

En el apartado anterior se definió la componente no estacional del proceso, en el apartado siguiente se presenta el estudio de la componente estacional del proceso.

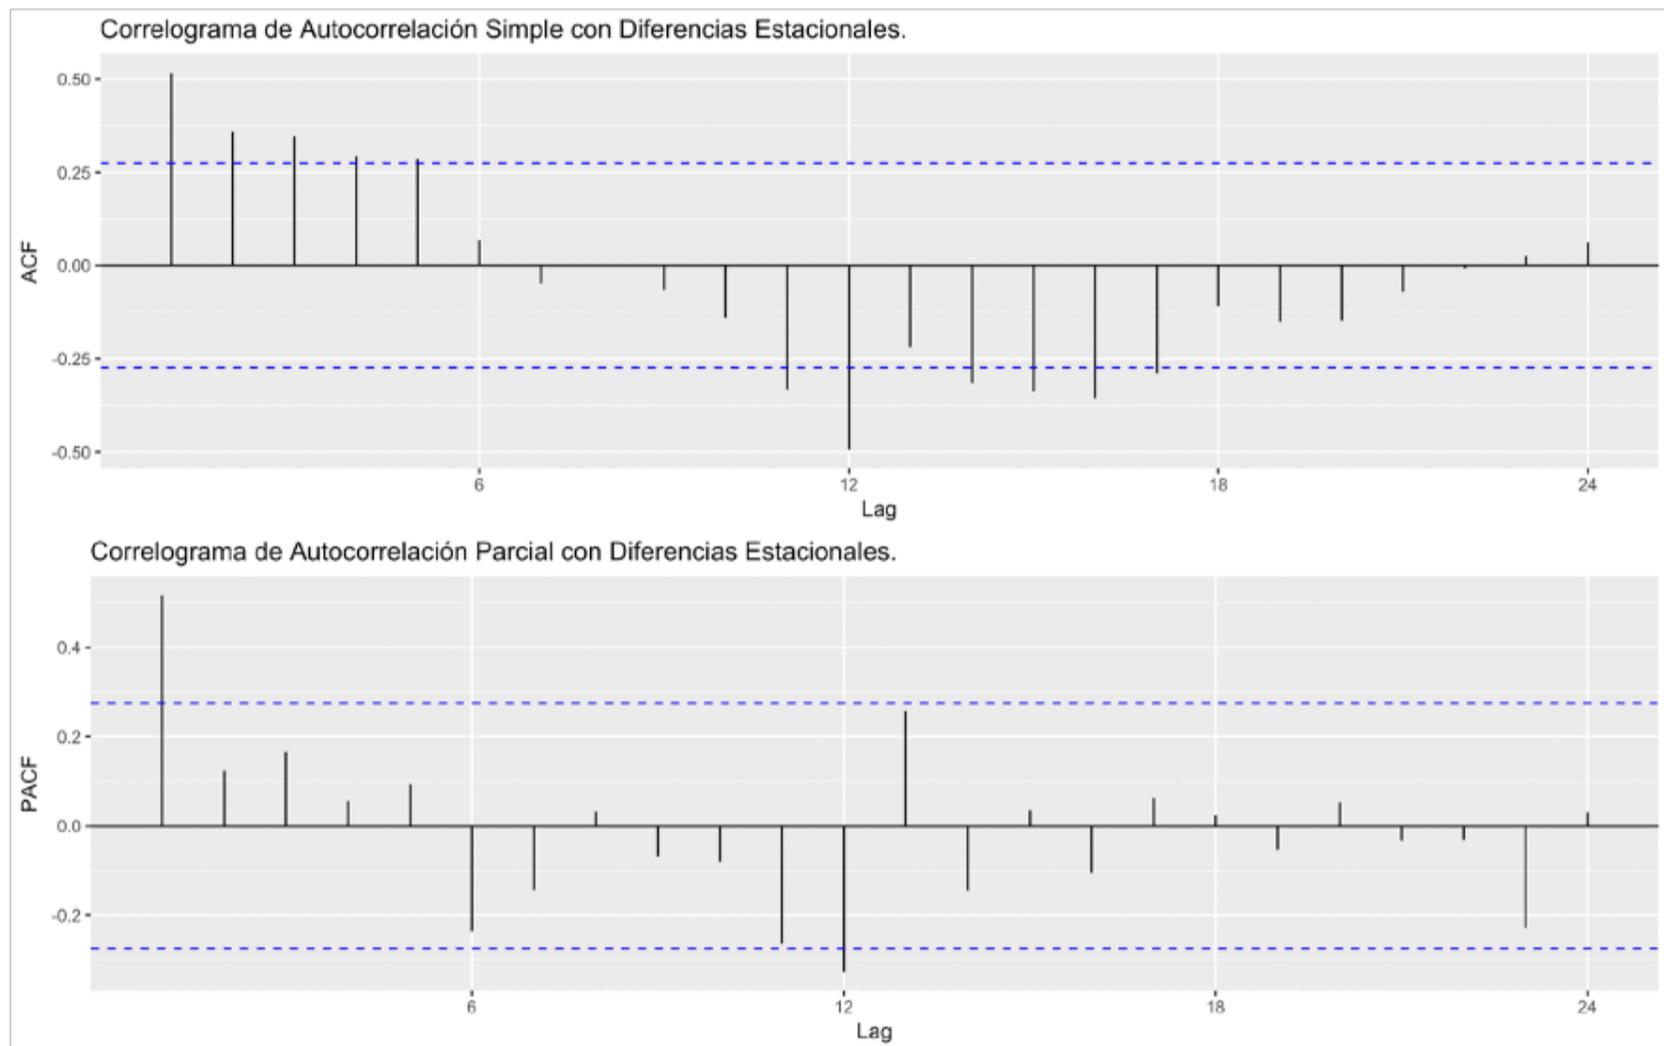
### **b) Análisis de Autocorrelación estacional: Conjunto de Datos 1.**

Reiterando que la inclusión de un componente estacional en una ecuación ARIMA es crucial para modelar Series de Tiempo que presentan patrones repetitivos a intervalos regulares, como es común en muchos fenómenos ambientales. Ya que estos componentes permiten capturar las variaciones que ocurren de manera cíclica debido a

factores estacionales, como cambios climáticos, horarios laborales, festividades, entre otros.

Por otra parte, añadiendo el análisis de la descomposición de la serie, se observa un alto índice de estacionalidad por lo cual se calculan y grafican las FAC y las FACP con diferencias estacionales.

Gráfico 4.5 Autocorrelación Simple y Parcial con Diferencias Estacionales: Conjunto de Datos 1



Fuente: Elaboración propia usando los datos del Gobierno de la Ciudad de México.

En el Gráfico 4.5 se puede denotar:

- Gráfico de las FAC: muestra picos significativos en los primeros rezagos, particularmente en el rezago 1, lo que indica una fuerte correlación entre los valores de  $O_3$  y sus rezagos más recientes. Se observa una disminución gradual en la autocorrelación conforme aumentan los rezagos, con algunos rezagos adicionales mostrando autocorrelaciones significativas, lo cual sugiere la presencia de una estructura MA, a su vez, la persistencia de autocorrelaciones significativas en

múltiples rezagos sugiere la necesidad de incluir términos estacionales en el modelo ARIMA para capturar adecuadamente la dinámica de la serie temporal. Concluyendo que sugiere la presencia de autocorrelaciones significativas en los primeros rezagos, apoyando la inclusión de términos MA y/o estacionales en el modelo.

- Gráfico de las FACP: muestra un pico significativo en el primer rezago, lo que sugiere la presencia de un componente autorregresivo de primer orden (AR (1)) o incluso (AR (2)) tomando el segundo pico. Prosiguiendo el primer rezago, los valores de la PACF disminuyen en forma acelerada y no muestran autocorrelaciones significativas en rezagos posteriores, indicando que un término autorregresivo de bajo orden podrá ser suficiente para modelar la serie de tiempo. Con un pico significativo en el primer rezago, indica que un modelo con un componente AR de primer orden es adecuado.

La combinación de los resultados de las funciones de autocorrelación simple y parcial, tras aplicar diferencias estacionales, sugiere que un modelo ARIMA estacional con componentes no estacionales de bajo orden es adecuado para capturar la dinámica de las concentraciones de  $O_3$ . Este modelo proporcionará una base sólida para el pronóstico y análisis de los niveles de  $O_3$ , permitiendo una mejor comprensión y gestión de la calidad del aire en la Ciudad de México.

### c) Pruebas de Estacionariedad en el proceso con Estacionalidad:

#### Conjunto de Datos 1.

Para pronosticar se debe volver a evaluar la Estacionariedad de la Serie de Tiempo con Diferencias Estacionales, se procede a realizar las pruebas de raíces unitarias y de estacionariedad en torno a nivel y tendencia. Se retoman las pruebas DFA y KPSS tanto para la estacionariedad en tendencia como en nivel.

Tabla 4.2 Pruebas en la Serie de Tiempo tras diferencias Estacionales: Conjunto de Datos 1.

Prueba	Estadístico	Significancia	Conclusión
ADF	-2.062	0.549	No Estacionario

KPSS (Tendencia)	0.128	0.083	Estacionario en torno a Nivel.
KPSS (Nivel)	0.209	$\geq 0.1$	Estacionario en torno a Tendencia.

Fuente: Elaboración propia usando los datos del Gobierno de la Ciudad de México.

Gracias a los datos de la Tabla 4.2, se puede notar:

- Los resultados de la prueba DFA indican que el valor del estadístico para determinar la presencia de un error estadístico de tipo I es mayor que el nivel de significancia de 0.050. Estos resultados no proporcionan evidencia suficiente para rechazar la hipótesis nula de no estacionariedad. Se concluye entonces, que la serie temporal de las concentraciones de  $O_3$  no es estacionaria según esta prueba.
- Los resultados de la prueba KPSS para la tendencia indican que no se puede rechazar la hipótesis nula de estacionariedad en tendencia dado que el valor de la significancia de la prueba es mayor que el nivel 0.100.
- En consonancia con lo anterior, los resultados de la prueba KPSS para el nivel indican que no se puede rechazar la hipótesis nula de estacionariedad en nivel dado que al valor de la significancia de la prueba fue mayor que 0.100.

A pesar de que la prueba DFA no mostró estacionalidad, debido a la cercanía de la significancia al valor 0.050, se prosigue con estacionariedad fundamentando en que las pruebas KPSS proporcionan evidencia coherente de que la serie de tiempo con diferencias estacionales de las concentraciones de  $O_3$  es estacionaria, tanto en torno a una tendencia como en un nivel constante. Estos resultados justifican el uso de modelos ARIMA estacionales para el análisis y pronóstico de los niveles de  $O_3$ , permitiendo desarrollar ecuaciones que capturen adecuadamente las dinámicas de la serie de tiempo.

Una vez que se definieron los componentes estacionales y no estacionales de la serie de tiempo con las concentraciones de  $O_3$ , en el apartado siguiente se presenta el estudio de las posibles ecuaciones de pronóstico considerando lo anterior.

#### 4.2.1.2 Polinomios Autorregresivos Estacionales e Integrados:

##### Conjunto de Datos 1.

Dada la Serie de Tiempo con Diferencias Estacionales se puede proseguir a seleccionar una ecuación dándole continuidad a la metodología Box-Jenkins. Un polinomio autorregresivo estacional se extiende sobre la base de los modelos ARIMA tradicionales, incorporando términos adicionales que reflejan las relaciones entre observaciones separadas por un periodo estacional fijo. Esto es particularmente relevante en el estudio de las concentraciones de  $O_3$ , donde factores estacionales como la radiación solar, las variaciones de temperatura y las precipitaciones desempeñan un papel crucial en la formación y dispersión del ozono.

La definición y aplicación de polinomios autorregresivos estacionales facilitan la captura de estas dinámicas complejas, mejorando la capacidad del modelo para realizar pronósticos precisos y robustos. En las secciones siguientes, se detallará la formulación matemática de estos polinomios, sus propiedades y cómo se integran en el modelo ARIMA estacional (SARIMA) para abordar los patrones de estacionalidad en los datos de Series de Tiempo. Retomando el análisis gráfico de los correlogramas se había propuesto tantas ecuaciones SARIMA con parámetros estacionales de primer y segundo orden.

A su vez, la necesidad de diferenciación es un aspecto clave que distingue los modelos ARIMA de los modelos ARMA. Mientras que los modelos ARIMA incluyen un componente de diferenciación para manejar la no estacionariedad, los modelos ARMA asumen que la serie temporal ya es estacionaria. Debido que los correlogramas de la serie de tiempo original muestran patrones que ya son estacionarios y confirmando con las pruebas ADF Y KPSS en torno a tendencia y nivel, un modelo ARMA es suficiente.

a) Elección de la Ecuación Autorregresiva y de Medias Móviles Estacional: Datos 1.

Para la elección de una ecuación pronóstico, en este caso SARMA, es imperativo la comparación de múltiples modelos. Argumentando con los siguientes motivos:

- Optimización del Ajuste: Al comparar diferentes ecuaciones, se puede identificar el modelo que proporciona el mejor ajuste a los datos históricos. Un buen ajuste es fundamental para capturar la estructura subyacente de la serie temporal y mejorar la precisión del pronóstico.

- Robustez del Modelo: Evaluar diversos modelos permite seleccionar aquel que no solo se ajusta de mejor manera a los datos de entrenamiento, sino que también generaliza mejor a datos no observados. Esto es crucial para asegurar que el modelo sea robusto y confiable en situaciones reales de pronóstico.

- Identificación de la Complejidad Necesaria: La comparación de modelos ayuda a determinar la complejidad necesaria para capturar la dinámica de la serie temporal. Modelos excesivamente complejos pueden causar un sobreajuste los datos y reducir la capacidad de pronóstico, mientras que modelos demasiado simples pueden no captar todas las características importantes de la serie.

La comparación sistemática de diferentes ecuaciones ARMA es fundamental para seleccionar el modelo más adecuado y mejorar la precisión del pronóstico. Utilizando criterios de información, pruebas de diagnóstico y métricas de precisión, se puede identificar el modelo que mejor capture la estructura de la serie temporal, proporcionando pronósticos más exactos y confiables. Este enfoque riguroso asegura que las decisiones basadas en estos pronósticos sean bien fundamentadas y efectivas. En este caso se utilizará el Criterio de Información Bayesiano AICc, el análisis de Residuos de la ecuación, la prueba Ljung-Box para independencia, la prueba Jarque-Bera de normalidad para el nivel de significancia que confirma normalidad en los residuos.

En la tabla 4.3 se presentan las diferentes ecuaciones de pronóstico propuestas, así como los valores del criterio estadístico bayesiano en cada caso.

Tabla 4.3 Comparación de las Ecuaciones Pronóstico: Datos 1.

Ecuación	Bayesiano AIC
(4,0,0) (1,1,1) e	1024.03
(3,0,0) (1,1,1) e	1021.17

(2,0,0) (1,1,1) e	1083.08
(1,0,0) (1,1,1) e	1080.74
(1,0,1) (1,1,1) e	1080.91
(1,0,2) (0,0,1) e	1340.31
(2,0,2) (0,0,1) e	1341.96
(3,0,2) (0,0,1) e	1342.13
(1,0,2) (0,0,2) e	1337.48
(2,0,1) (0,0,2) e	1339.00

Fuente: Elaboración propia.

Se escoge el AICc debido a que la muestra es de 63 datos, se utiliza para comparar diferentes modelos que han sido ajustados a la misma serie de tiempo. El modelo con el AICc más bajo se considera el mejor en términos de equilibrio entre ajuste y complejidad del modelo. El AICc más bajo indica que el modelo proporciona el mejor ajuste a los datos sin tener un sobreajuste, considerando la penalización adicional para tamaños de muestra pequeños, ya que la corrección introducida en el AICc lo hace más robusto y fiable en estudios con tamaños de muestra pequeños, asegurando que la selección del modelo sea menos sesgada y más representativa del verdadero proceso generador de datos.

La Tabla 4.3 nos proporciona que, utilizando el criterio de AICc, la ecuación con mayor ajuste sería (3,0,0)(1,1,1)e, aunque los correlogramas no mostraron suficiente evidencia para poder llegar a un factor autorregresivo de tercer orden, por lo que pierde credibilidad el criterio para este modelo en específico. Se proseguirá con las pruebas para las mismas 15 ecuaciones mostradas en la Tabla 4.3.

Una vez que se seleccionó una ecuación de pronóstico, se procede con el análisis de los principios de independencia y de normalidad de tal ecuación.

#### **4.2.1.3 Análisis de Residuos de la Ecuación de Pronóstico**

Se prosigue aplicando las pruebas Ljung-Box de independencia, Jarque Bera y Shapiro Wilk que confirman normalidad en los residuos con los siguientes resultados (ver Tabla 4.4).

Tabla 4.4 Pruebas de las Ecuaciones Pronóstico: Datos 1.

<b>Ecuación</b>	<b>Ljung-Box</b>	<b>Shapiro Wilk</b>
(4,0,0) (1,1,1) e	Residuos Independientes	Residuos no Normalemente distribuidos
(3,0,0) (1,1,1) e	Residuos Independientes	Residuos no Normalemente distribuidos
(2,0,0) (1,1,1) e	Residuos Independientes	Residuos no Normalemente distribuidos
(1,0,0) (1,1,1) e	Residuos Independientes	Residuos no Normalemente distribuidos
(1,0,1) (1,1,1) e	Residuos Independientes	Residuos no Normalemente distribuidos
(1,0,2) (0,0,1) e	Residuos Independientes	Residuos Normales
(2,0,2) (0,0,1) e	Residuos Independientes	Residuos no Normalemente distribuidos
(3,0,2) (0,0,1) e	Residuos no Independientes	Residuos no Normalemente distribuidos
(1,0,2) (0,0,2) e	Residuos Independientes	Residuos no Normalemente distribuidos
(2,0,1) (0,0,2) e	Residuos Independientes	Residuos no Normalemente distribuidos

Fuente: Elaboración propia.

La distribución de los residuos juega un papel crucial en la validación y efectividad del modelo. Los residuos, o errores, son las diferencias entre los valores observados y los valores predichos por el modelo. Para que un modelo SARMA sea considerado adecuado, es esencial que estos residuos sean normalmente distribuidos. Si los residuos son normalmente distribuidos, es más probable que el modelo SARMA haya capturado adecuadamente la estructura subyacente de la serie temporal, la normalidad de los residuos indica que no existen patrones no modelados en los datos, sugiriendo que el modelo ha explicado todas las dependencias sistemáticas presentes en la serie temporal.

A su vez, la normalidad de los residuos implica que la variabilidad no explicada por el modelo es aleatoria y sigue una distribución conocida. Esto mejora la precisión y la confiabilidad de los intervalos de pronóstico y las predicciones futuras. Si los residuos no son normalmente distribuidos, pueden existir factores estructurales o patrones en los datos que no han sido capturados por el modelo, reduciendo la precisión del pronóstico. Gracias a los resultados de la tabla 4.4, se puede concluir que la mejor Ecuación Pronóstico es la SARMA (1,0,2) (0,0,1) e, debido a que es la única que cumple con residuos normalmente distribuidos. A continuación, se presentan los resultados de las pruebas estadísticas de independencia y de normalidad (ver Tabla 4.5).

Tabla 4.5 Pruebas de las Ecuación SARMA (1,0,2)(0,0,1)e: Datos 1.

<b>Prueba</b>	<b>Estadístico</b>	<b>Significancia</b>
LJung-Box	Q* = 11.663	0.233
Shapiro Wilk	W = 0.963	0.055

Fuente: Elaboración propia.

Concluyendo así que la importancia de que los residuos sean normalmente distribuidos en una ecuación SARMA son de gran importancia para la pronosticación. La normalidad de los residuos asegura que el modelo haya capturado de manera efectiva todas las dependencias y patrones presentes en los datos, validando así la estructura del modelo y mejorando la precisión de los pronósticos. Un diagnóstico adecuado y la confirmación de la normalidad de los residuos son pasos críticos para garantizar que el

modelo SARMA sea robusto, confiable y útil para la toma de decisiones basada en datos.

#### 4.2.1.4. Pronósticos de las concentraciones de ozono troposférico:

Datos 1.

##### 4.2.1.4.1 Análisis de los pronósticos

Definida la ecuación SARMA(1,0,2)(0,0,1)e, se procede a pronosticar los valores de las concentraciones de  $O_3$  con los siguientes resultados. En la tabla 4.6 se exponen los resultados de los pronósticos obtenidos para el periodo comprendido entre el mes de abril y el mes de diciembre del año 2020. Se muestran los valores de los intervalos de confianza al 80 y 95 por ciento que respaldan el estudio de los pronósticos obtenidos.

Tabla 4.6 Pronóstico de las Ecuación SARMA (1,0,2) (0,0,1)e: Conjunto de Datos 1.

Mes-2020	Estimación	IC 80 %		IC 95 %	
		LI	LS	LI	LS
Abril	0.079	0.068	0.090	0.062	0.096
Mayo	0.091	0.077	0.105	0.070	0.112
Junio	0.070	0.057	0.082	0.051	0.088
Julio	0.070	0.057	0.083	0.051	0.090
Agosto	0.068	0.055	0.081	0.047	0.088
Septiembre	0.057	0.044	0.070	0.037	0.077
Octubre	0.054	0.041	0.067	0.034	0.074
Noviembre	0.054	0.041	0.068	0.033	0.075
Diciembre	0.061	0.047	0.076	0.039	0.084

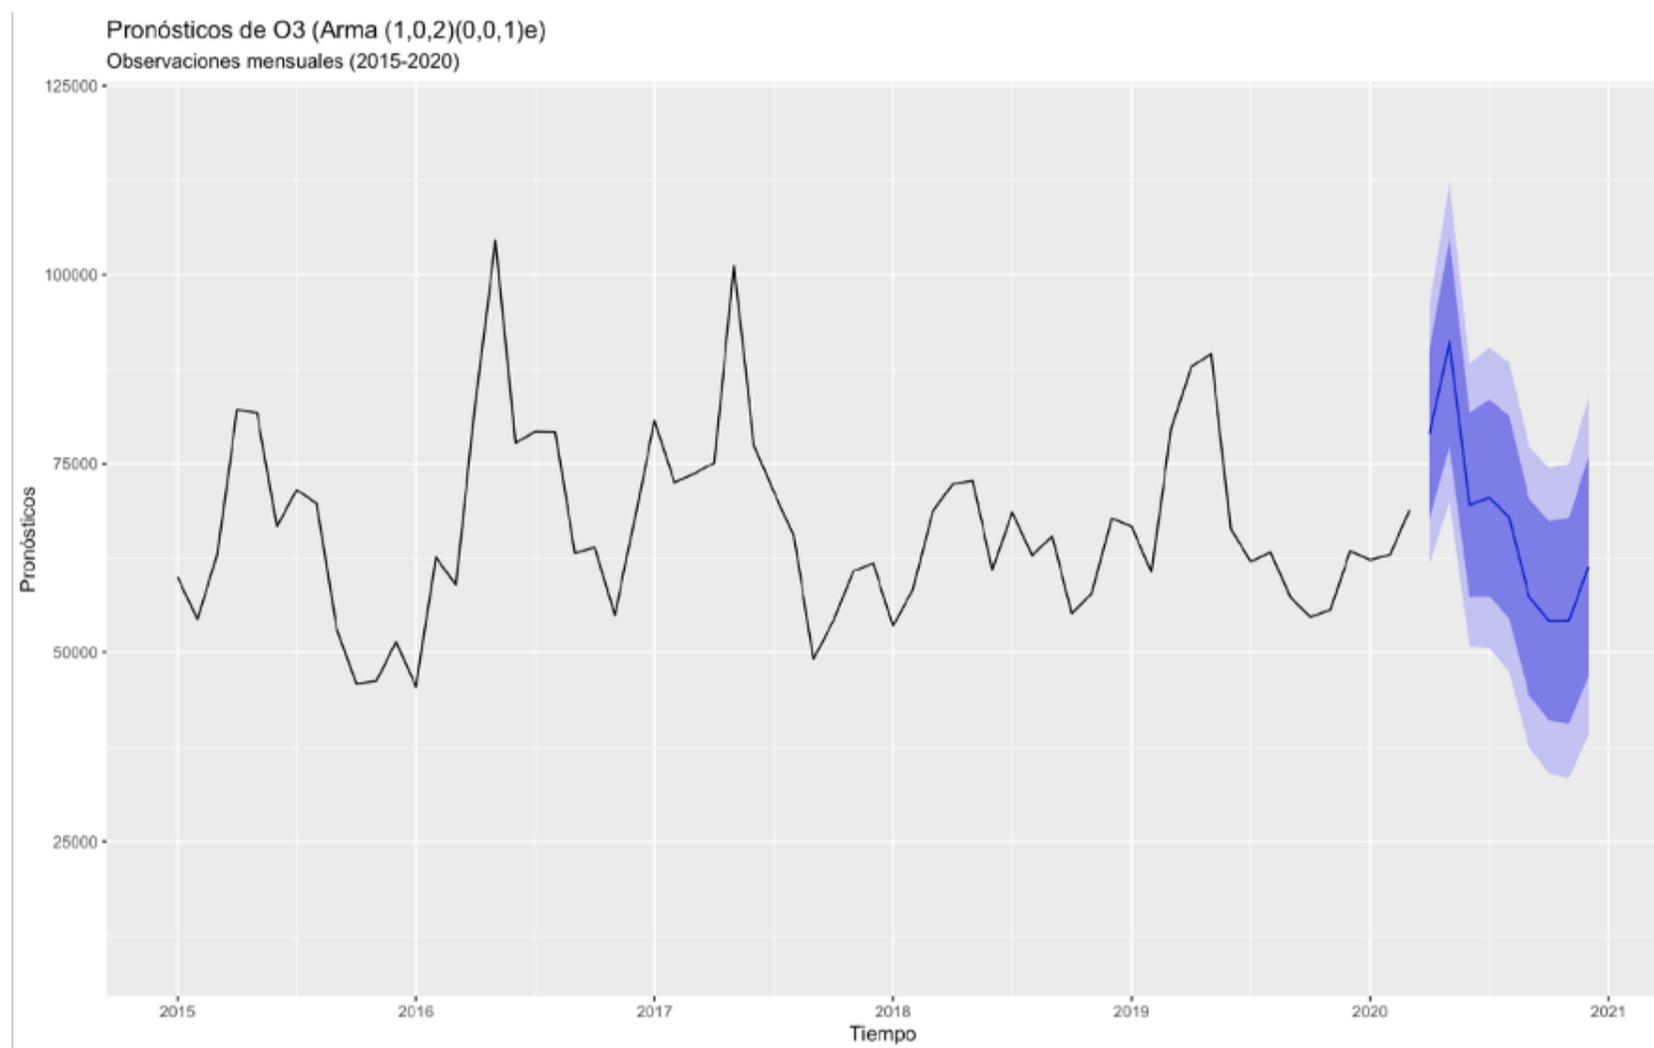
Notas: LI = Límite inferior; LS = Límite superior.

Fuente: Elaboración propia.

En la tabla 4.6 se muestran los resultados del Pronóstico con Intervalos de Confianza a 80% y 95%. El intervalo de confianza es una herramienta crucial en el pronóstico de Series de Tiempo utilizando modelos SARMA. Estos intervalos proporcionan una medida de la incertidumbre asociada con las predicciones del modelo, permitiendo

evaluar la fiabilidad de los pronósticos. Esto es esencial para la planificación y la gestión de riesgos, ya que proporciona una comprensión clara de las posibles variaciones y extremos en los niveles pronosticados (ver Gráfico 4.6).

Gráfico 4.6 Pronóstico de las Ecuación SARMA (1,0,2)(0,0,1)e: Datos 1.



Fuente: Elaboración propia.

Del Gráfico 4.6 se puede denotar lo siguiente:

1. Pronósticos y Tendencias: Los intervalos de confianza muestran una mayor incertidumbre en los primeros meses de pronóstico, lo que es común en las proyecciones a largo plazo. La incertidumbre disminuye gradualmente, reflejando una mayor confianza en los pronósticos a medida que se acerca el período actual.

2. Precisión del Modelo: El modelo SARMA (1,0,2) (0,0,1) e captura adecuadamente la estacionalidad y la variabilidad de las concentraciones de ozono observadas en los datos históricos. Los intervalos de confianza permiten evaluar la precisión y fiabilidad de los pronósticos. A su vez, la proximidad de la línea azul de los pronósticos a la línea negra de las observaciones históricas indica un buen ajuste del

modelo a los datos pasados, lo que sugiere que el modelo es robusto y adecuado para hacer predicciones.

Se puede concluir que el gráfico de pronósticos de las concentraciones de  $O_3$  utilizando un modelo SARIMA muestra una trayectoria esperada de los niveles de ozono con intervalos de confianza que reflejan la incertidumbre inherente a las predicciones. El modelo ajustado proporciona una herramienta útil y precisa para anticipar las variaciones futuras en la calidad del aire, facilitando la toma de decisiones informadas y la implementación de políticas efectivas de control de la contaminación.

#### 4.2.1.5. Comparación del Pronóstico del Conjunto de Datos 1 con los datos de 2020 en la Emergencia Sanitaria.

A continuación, se presenta una comparación detallada entre los pronósticos de las concentraciones de  $O_3$  obtenidos mediante el modelo SARIMA y los datos observados durante el año 2020, un periodo significativamente afectado por la emergencia sanitaria de COVID-19.

Tabla 4.7 Análisis del Pronóstico de las Ecuación: Datos 1.

Mes – 2020	Datos – 2020	Proyección – 2020	IC 95 %	
			LI	LS
Enero	45158.248	45158.248	-	-
Febrero	54371.188	54371.188	-	-
Marzo	65549.103	65549.103	-	-
Abril	73576.188	78940.580	61769.23	96111.93
Mayo	74861.332	91141.960	70056.9	112227.03
Junio	58340.349	69532.020	50847.960	88216.090
Julio	57461.498	70444.920	50560.830	90329.010
Agosto	50713.804	67928.040	47427.380	88428.700
Septiembre	49019.288	57349.820	37446.060	77253.590
Octubre	58714.694	54176.880	33999.510	74354.250

Noviembre	54010.343	54198.920	33412.340	74985.490
Diciembre	51969.355	61324.080	39054.290	83593.870
Promedio	57812.1158	64176.3132	-	-

Fuente: Elaboración propia.

La tabla proporcionada muestra los valores pronosticados, los intervalos de confianza al 95%, y las concentraciones reales de  $O_3$  para cada mes del año 2020. Es notable que los valores pronosticados están generalmente alineados con las concentraciones observadas, indicando que el modelo SARIMA ha capturado de manera efectiva la tendencia y la variabilidad de las concentraciones de  $O_3$  durante 2020.

Sin embargo, en algunos meses, especialmente en abril, mayo y junio, los datos observados superan los valores pronosticados, reflejando las posibles influencias de factores externos adicionales durante la pandemia.

Los intervalos de confianza al 95% proporcionan un rango dentro del cual se espera que caigan con probabilidad definida las concentraciones de  $O_3$ . Todos los datos observados se encuentran dentro de estos intervalos, confirmando la precisión del modelo.

El promedio de las concentraciones observadas de  $O_3$  (0.057) y el promedio de los valores pronosticados (0.064) muestran una diferencia relativamente pequeña, indicando que el modelo SARMA(1,0,2)(0,0,1)e ha proporcionado una estimación globalmente precisa de las concentraciones de  $O_3$  para el año 2020 y a su vez que a diferencia de las observaciones reales, la media de los valores pronosticados no se encuentra dentro de los estándares de la Comisión Europea para los niveles de  $O_3$ .

Los intervalos de confianza proporcionan una herramienta valiosa para evaluar la incertidumbre en los pronósticos y preparar medidas de gestión de la calidad del aire. La capacidad de prever rangos de posibles concentraciones de  $O_3$  permite a los responsables de políticas diseñar estrategias más robustas para mitigar la contaminación y proteger la salud pública ya que la emergencia sanitaria de COVID-19

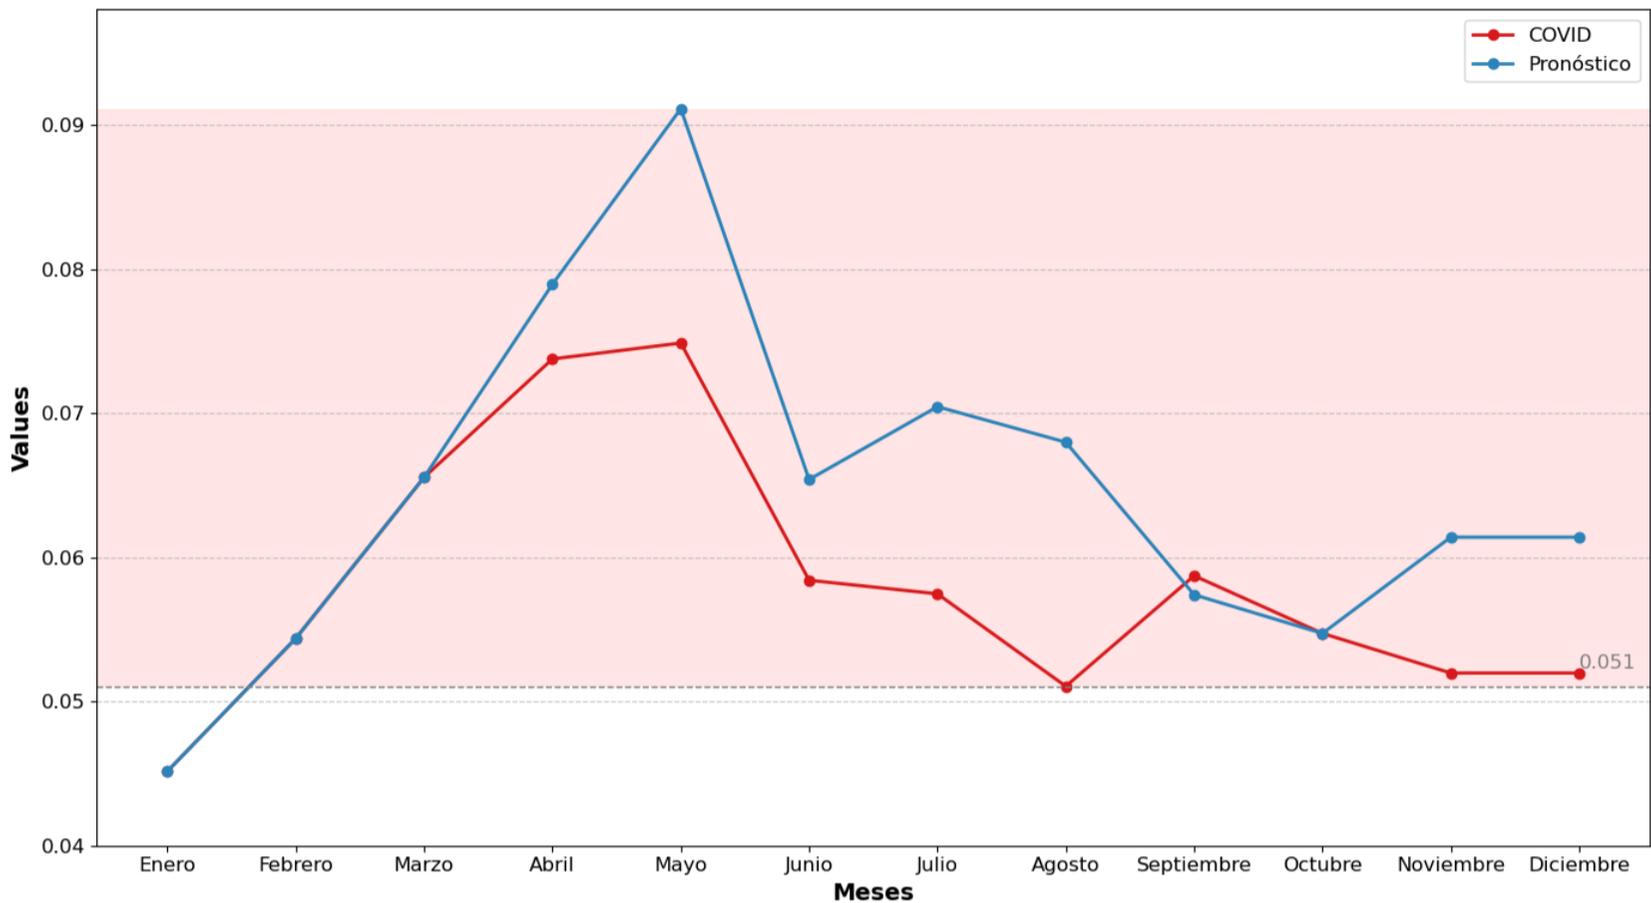
introdujo la adopción de actividades remotas que resultó en una notable reducción del tráfico vehicular y la actividad industrial, que son las principales fuentes de emisiones de precursores del  $O_3$ . Esta disminución en las emisiones contribuyó directamente a una reducción en la formación de  $O_3$ . Los datos de la tabla 4.7, muestran que las concentraciones mensuales de  $O_3$  en varios meses de 2020 fueron inferiores al límite de 0.051 ppm recomendadas según la Agencia Europea de Medio Ambiente (1998), destacando los efectos positivos de la reducción del tráfico.

Se puede concluir que la inclusión de actividades remotas durante la emergencia sanitaria de COVID-19 tuvo un impacto positivo en la reducción de las concentraciones de  $O_3$ , contribuyendo a mantener los niveles por debajo del pronóstico, aunque no por debajo de lo recomendado.

#### **4.2.1.6 Comparación del Pronóstico con los datos de 2020 y los límites para la Salud: Datos 1.**

En esta sección se presenta una comparación entre los pronósticos generados mediante el modelo SARIMA y las concentraciones reales de  $O_3$  captadas durante el año 2020, en el contexto de los límites recomendados para la salud pública. Según la Agencia Europea de Medio Ambiente (1998), el valor óptimo de  $O_3$  para la protección de la salud es de 0.051ppm, lo cual se utiliza como referencia en esta comparación. En el gráfico que se muestra a continuación, el área por encima de este valor está resaltada en rojo, indicando niveles potencialmente dañinos para la salud.

Gráfico 4.7 Comparación del pronóstico y los datos captados en 2020 contra la medida recomendada de Salud: Conjunto de Datos 1.



Fuente: Elaboración propia.

El gráfico 4.7 muestra la serie de tiempo de los valores pronosticados frente a las concentraciones reales de  $O_3$  durante los meses de abril a diciembre de 2020. Como puede observarse, el modelo SARIMA captura con precisión la tendencia general de las concentraciones de ozono, aunque se aprecian discrepancias significativas en algunos meses, especialmente durante abril y mayo. En estos meses, las concentraciones reales de  $O_3$  se mantuvieron por debajo de los valores pronosticados, aunque continúan situándose sobre el umbral recomendado de 0.051 ppm (Comisión Europea, 2008). En dicho gráfico se han omitido los intervalos de confianza en este análisis para centrar la comparación exclusivamente en los valores pronosticados y las captaciones reales. Esto se justifica por la necesidad de evaluar directamente la precisión del modelo en relación con los límites de salud, sin agregar la complejidad adicional de los intervalos de confianza. El enfoque se mantiene en la comparación directa de los datos, proporcionando una visión más clara de cómo se comportaron las concentraciones reales de  $O_3$  frente a las predicciones bajo las condiciones extraordinarias de la pandemia de COVID-19.

Se puede concluir que el Gráfico 4.7 resalta cómo, a pesar de las restricciones sanitarias que redujeron significativamente la actividad vehicular e industrial y por ende las concentraciones de  $O_3$  en general, dichas concentraciones superaron el valor óptimo para la salud. A su vez, es notable que, en los meses de verano, cuando normalmente se esperaría un aumento de las concentraciones debido a factores estacionales, los valores reales se mantuvieron bajos, lo que subraya la influencia positiva de las medidas de reducción de emisiones durante la pandemia.

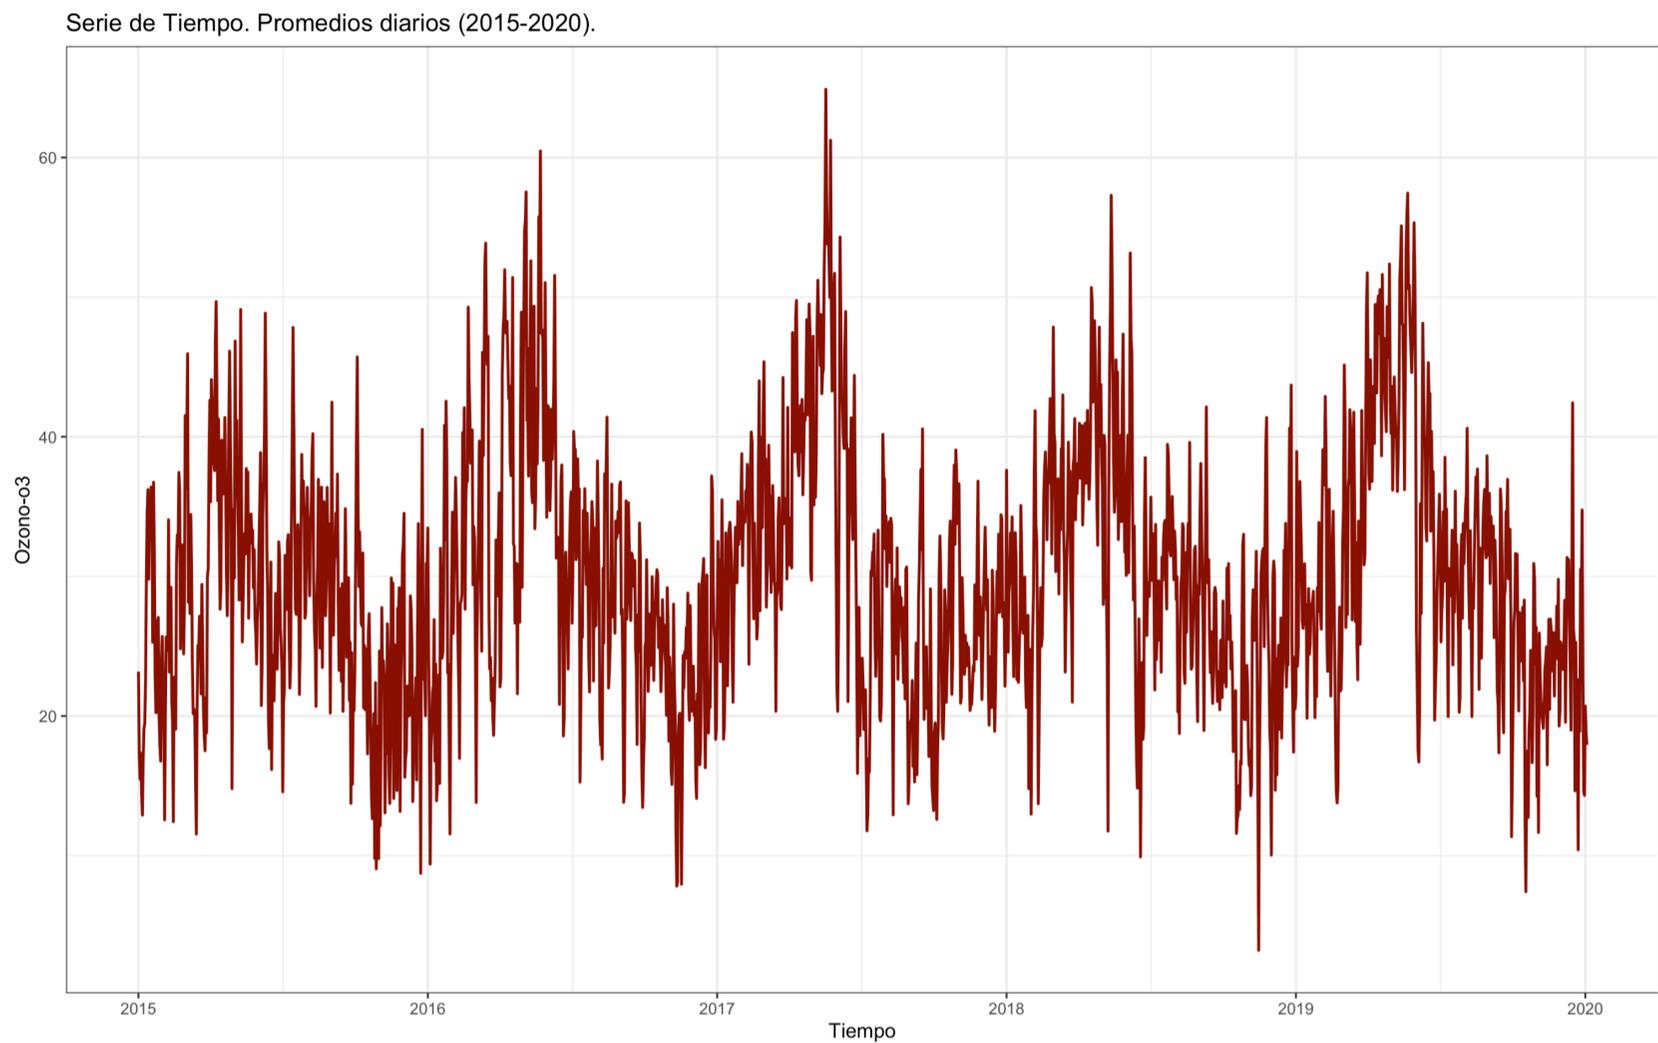
Una vez concluido el estudio de la serie temporal y los pronósticos para el Conjunto Datos 1, en adelante se presentan los procedimientos para el Conjunto Datos 2.

#### **4.2.2 Metodología Box-Jenkins: Conjunto de Datos 2.**

En esta sección, se emplea la misma metodología Box-Jenkins (ARIMA) utilizada previamente en el Conjunto de Datos 1, pero con la diferencia de que el análisis se aplicará ahora a los promedios diarios de las concentraciones de  $O_3$ . Esto permitirá una evaluación más detallada de las variaciones a corto plazo, capturando patrones diarios que podrían no ser evidentes en el análisis de promedios mensuales.

El Gráfico 4.8 presenta las observaciones de los promedios diarios de las concentraciones de  $O_3$  en la Ciudad de México para el período comprendido entre enero de 2015 y marzo de 2020. De manera similar al Conjunto de Datos 1, se observan fluctuaciones significativas a lo largo del tiempo, que muestran patrones cíclicos. Las concentraciones de  $O_3$  tienden a aumentar en ciertos periodos del año, probablemente influenciadas por factores estacionales como la radiación solar y las condiciones meteorológicas. Estos picos suelen aparecer de manera recurrente en la temporada de mayor radiación, antes de la temporada de lluvias, cuando los contaminantes tienden a dispersarse más fácilmente.

Gráfico 4.8 Evolución de la serie de tiempo: Conjunto de Datos 2.



Fuente: Elaboración propia.

A diferencia del análisis con promedios mensuales, aquí se evidencia una mayor variabilidad diaria, con fluctuaciones más abruptas. Esto es especialmente visible en las estaciones secas, donde los máximos son más frecuentes y prolongados.

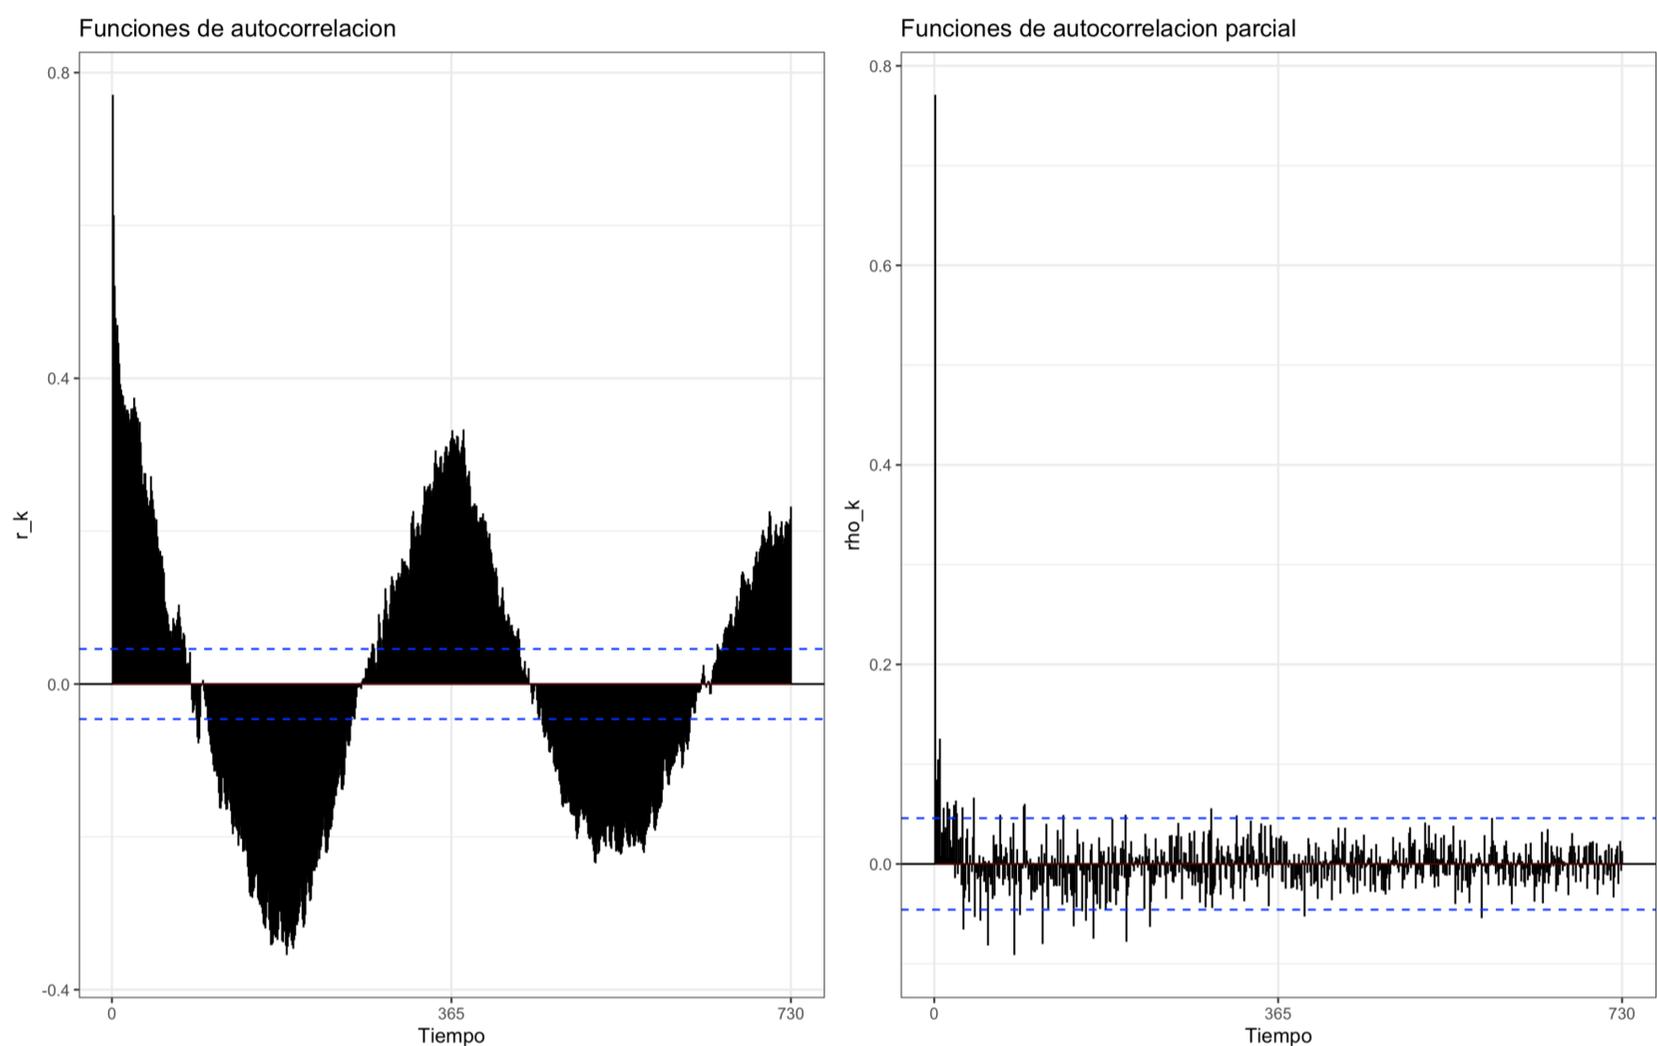
La metodología Box-Jenkins aplicada a este conjunto de datos seguirá las mismas etapas, comenzando por el análisis de autocorrelación para identificar la estacionalidad y las dependencias a corto plazo. El proceso permitirá la construcción de un modelo que capture no solo las tendencias generales, sino también las variaciones diarias y estacionales.

#### 4.2.2.1 Análisis de la ecuación de Pronóstico: Conjunto de Datos 2.

Para aplicar de manera efectiva un modelo ARIMA en la predicción de las concentraciones diarias de  $O_3$ , es esencial verificar si la serie temporal es estacionaria. La estacionariedad es un requisito fundamental en la metodología Box-Jenkins, ya que

implica que las propiedades estadísticas de la serie (como la media y la varianza) se mantienen constantes en el tiempo. En esta subsección, se analizará la estacionariedad del Conjunto de Datos 2 a través de diversas pruebas estadísticas y el análisis de autocorrelación.

Gráfico 4.9 Análisis de Autocorrelación Estacional y no estacional: Conjunto de Datos 2.



Fuente: Elaboración propia.

#### 4.2.2.2 Estacionariedad del Proceso: Conjunto de Datos 2.

El análisis de autocorrelación simple (FAC) presentado en el Gráfico 4.9 muestra una clara estacionalidad en los datos, con picos repetidos aproximadamente cada 365 días. Esto refleja las fluctuaciones anuales típicas de las concentraciones de  $O_3$ . Los primeros rezagos muestran autocorrelaciones significativas, lo que sugiere que la serie temporal presenta dependencias a corto plazo que deben ser modeladas mediante términos autorregresivos o de medias móviles.

Este patrón indica que los datos no pueden considerarse como una serie completamente aleatoria, sino que están influenciados por factores estacionales que generan ciclos anuales repetitivos.

#### **a) Análisis de Autocorrelación no estacional: Conjunto de Datos 2.**

El análisis de autocorrelación simple (FAC) presentado en el Gráfico 4.9 revela una estacionalidad clara en los datos, con picos repetidos cada 365 días. Esto refleja las fluctuaciones anuales típicas de las concentraciones de  $O_3$ . Los primeros rezagos muestran autocorrelaciones significativas, lo que sugiere que la serie temporal presenta dependencias a corto plazo que deben ser modeladas mediante términos autorregresivos o de medias móviles.

Este patrón también indica que los datos no se pueden considerar como una serie completamente aleatoria, sino que están influenciados por factores estacionales que generan ciclos anuales repetitivos.

#### **b) Análisis de Autocorrelación estacional: Conjunto de Datos 2.**

El componente estacional de la serie queda aún más claro al observar la función de autocorrelación parcial (FACP). En el Gráfico 4.9, la FACP muestra un único pico significativo en el primer rezago, lo que apunta a un componente autorregresivo de primer orden (AR(1)). Este patrón se repite en los rezagos anuales, indicando que la estacionalidad puede ser capturada adecuadamente mediante términos estacionales en un modelo SARIMA.

Dado que la serie muestra una estacionalidad marcada y los rezagos fuera del primer pico no presentan correlaciones parciales significativas, un término autorregresivo de bajo orden (AR(1)) y un componente estacional parecen ser suficientes para modelar la serie.

#### **c) Pruebas de Estacionariedad en el proceso con Estacionalidad:**

##### **Conjunto de Datos 2.**

Para proseguir con el análisis, se realizaron las siguientes pruebas:

- Prueba de Ljung-Box: El Test de Ljung-Box, aplicado a los primeros 10 rezagos, tiene un valor  $\chi^2$  de 4735.8 con un valor p extremadamente bajo ( $p < 2.2e^{-16}$ ). Este resultado indica que la serie temporal tiene una fuerte dependencia temporal y que los residuos no son independientes. Esto justifica la necesidad de incluir términos autorregresivos y de medias móviles en el modelo para capturar estas dependencias y mejorar el ajuste del modelo predictivo.

- Prueba de Estacionariedad KPSS: La prueba de raíz unitaria KPSS (con un test de tipo mu) fue utilizada para evaluar la estacionariedad de la serie en torno a la media. El valor del estadístico de prueba es 0.2153, lo que está por debajo de los valores críticos para los niveles de significancia de 10%, 5%, 2.5% y 1%. Esto proporciona evidencia suficiente para aceptar la hipótesis nula de que la serie es estacionaria en torno a un nivel. A diferencia de muchas Series de Tiempo que requieren diferenciación, este conjunto de datos no parece necesitar una diferenciación adicional para estabilizar la media.

Siguiendo los resultados obtenidos en los correlogramas y las pruebas de estacionariedad, se han ajustado varios modelos ARIMA para determinar cuál ofrece el mejor ajuste.

#### **4.2.2.3 Polinomios Autorregresivos Estacionales e Integrados:**

##### **Conjunto de Datos 2.**

En esta sección se ajustaron y evaluaron varios modelos SARIMA (ARIMA estacional) para capturar las dependencias a corto plazo y los ciclos estacionales presentes en los promedios diarios de concentraciones de  $O_3$ . El modelo SARIMA extiende el modelo ARIMA tradicional al incorporar un componente estacional, expresado como  $ARIMA(p,d,q)(P,D,Q)[s]$ , donde los parámetros P, D y Q representan los órdenes autorregresivos, de diferenciación y de medias móviles para el componente estacional, y s indica el número de períodos en cada ciclo estacional, que en este caso es anual (365 días).

Se ajustaron tres configuraciones de modelos SARIMA con diferentes órdenes para los componentes autorregresivos y de medias móviles no estacionales, manteniendo un componente estacional fijo (1,0,1)[365] basado en la clara estacionalidad anual observada en la serie temporal. Los resultados de tres modelos escogidos se presentan en la Tabla 4.8. Cada modelo fue evaluado en función de sus Criterios Bayesianos de información (AIC, AICc y BIC), que permiten comparar la calidad del ajuste penalizando la complejidad del modelo.

Tabla 4.8 Pruebas de las Ecuaciones Pronóstico: Datos 2.

<b>Ecuación</b>	<b>AIC</b>	<b>AICc</b>	<b>BIC</b>
(3,0,1)(1,0,1)	19287.16	19287.19	19323.34
(2,0,1)(1,0,1)	19296.57	19296.59	19326.73
(1,0,1)(1,0,1)	19443.57	19443.59	19467.69

Fuente: Elaboración propia.

Dados los Resultados de la Tabla 4.8, se puede concluir:

- Modelo ARIMA(3,0,1)(1,0,1): Este modelo tiene el valor más bajo de AIC (19287.16) y AICc (19287.19), lo que sugiere que ofrece el mejor equilibrio entre precisión del ajuste y complejidad del modelo. Además, presenta la varianza residual más baja ( $\sigma^2 = 31.05$ ), lo que indica una mayor precisión en la predicción de las concentraciones diarias de  $O_3$ . Sin embargo, incluye tres términos autorregresivos, lo que lo hace más complejo.

- Modelo ARIMA(2,0,1)(1,0,1): Este modelo también ofrece un buen ajuste con un AICc de 19296.59, muy cercano al modelo anterior. Si bien la diferencia en AICc es pequeña, este modelo es ligeramente más simple que el modelo de orden 3, lo que podría hacerlo más manejable en ciertas situaciones.

- Modelo ARIMA(1,0,1)(1,0,1): El modelo más simple, con solo un término autorregresivo, tiene un AICc significativamente más alto (19443.59) y una mayor varianza residual ( $\sigma^2 = 32.70$ ), lo que sugiere que no captura las dependencias en los datos tan bien como los otros dos modelos.

Tras evaluar los modelos, el modelo ARIMA(3,0,1)(1,0,1) es el que presenta el mejor ajuste según el criterio AICc y la menor varianza residual. Este modelo, aunque más complejo que los otros, captura de manera efectiva tanto las dependencias no estacionales como los ciclos estacionales anuales presentes en los datos de concentraciones diarias de  $O_3$ . Por tanto, será seleccionado para su uso en los pronósticos y análisis posteriores.

#### **4.2.2.4. Análisis de Residuos de la Ecuación de Pronóstico: Conjunto de Datos 2.**

Una parte fundamental de la metodología Box-Jenkins es evaluar la calidad de los modelos ajustados a través del análisis de los residuos. Un buen modelo ARIMA debe producir residuos que sean ruido blanco, es decir, que no contengan correlación significativa entre ellos y presenten una distribución normal con media cero y varianza constante.

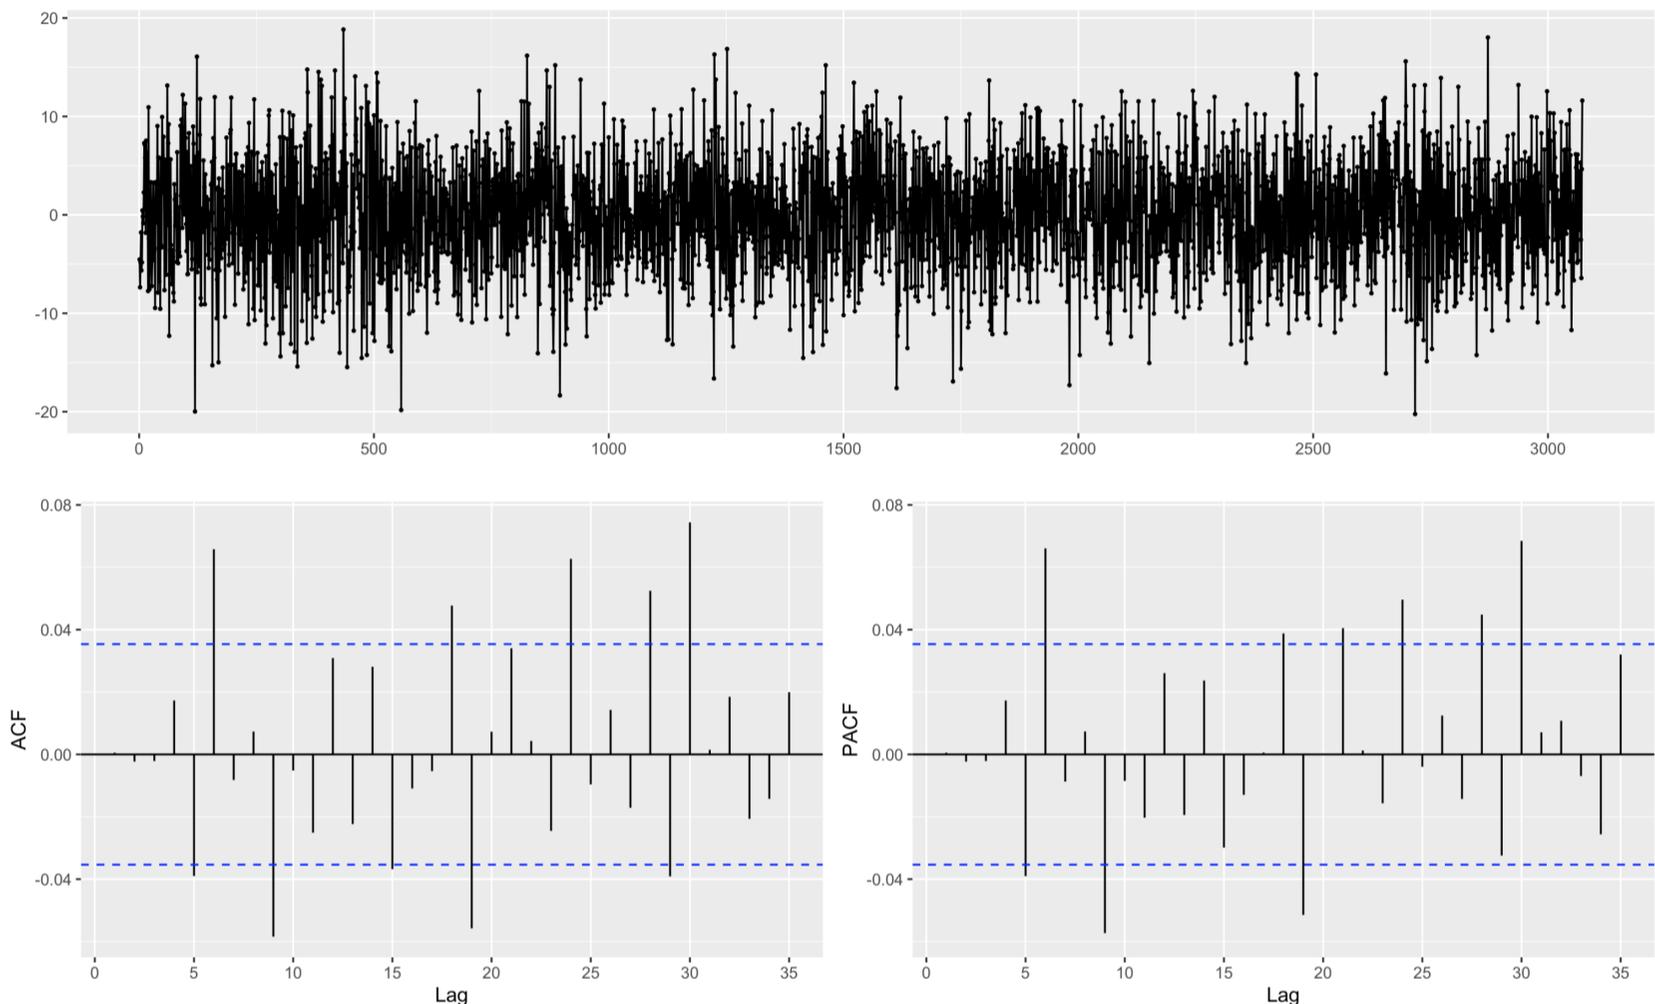
En esta sección, se evalúa el Gráfico 4.10 el cual fue seleccionado previamente como el que mejor ajusta los datos de concentraciones diarias de  $O_3$ . Los gráficos presentados a continuación muestran los residuos, así como las funciones ACF y PACF de los mismos.

- Gráfico superior: Muestra los residuos del modelo ARIMA(3,0,1)(1,0,1). A simple vista, los residuos parecen oscilar alrededor de cero, lo que indica que el modelo ha capturado adecuadamente la tendencia de los datos. Además, no se observan patrones evidentes que sugieran la presencia de autocorrelación en los residuos.

- Gráfico de ACF (inferior izquierdo): La función de autocorrelación simple de los residuos confirma que no existen correlaciones significativas entre los rezagos. Ninguno de los valores de ACF supera los límites de significancia, lo que indica que los residuos se comportan como ruido blanco y que el modelo ha capturado correctamente la estructura de las dependencias temporales en los datos.

- Gráfico de PACF (inferior derecho): Similarmente, la función de autocorrelación parcial muestra que no hay correlaciones significativas en los primeros rezagos, lo que refuerza la idea de que no queda autocorrelación no modelada en los datos.

Gráfico 4.10 Análisis de Residuos del Modelo ARIMA(3,0,1)(1,0,1): Conjunto de Datos 2.



Fuente: Elaboración propia.

El análisis de los residuos del modelo ARIMA(3,0,1)(1,0,1) sugiere que el modelo es apropiado para los datos de concentraciones diarias de  $O_3$ . Los residuos se comportan como ruido blanco, lo que indica que el modelo ha capturado correctamente las dependencias temporales y estacionales presentes en los datos. Esto valida el uso de este modelo para realizar pronósticos precisos sobre los niveles futuros de  $O_3$ .

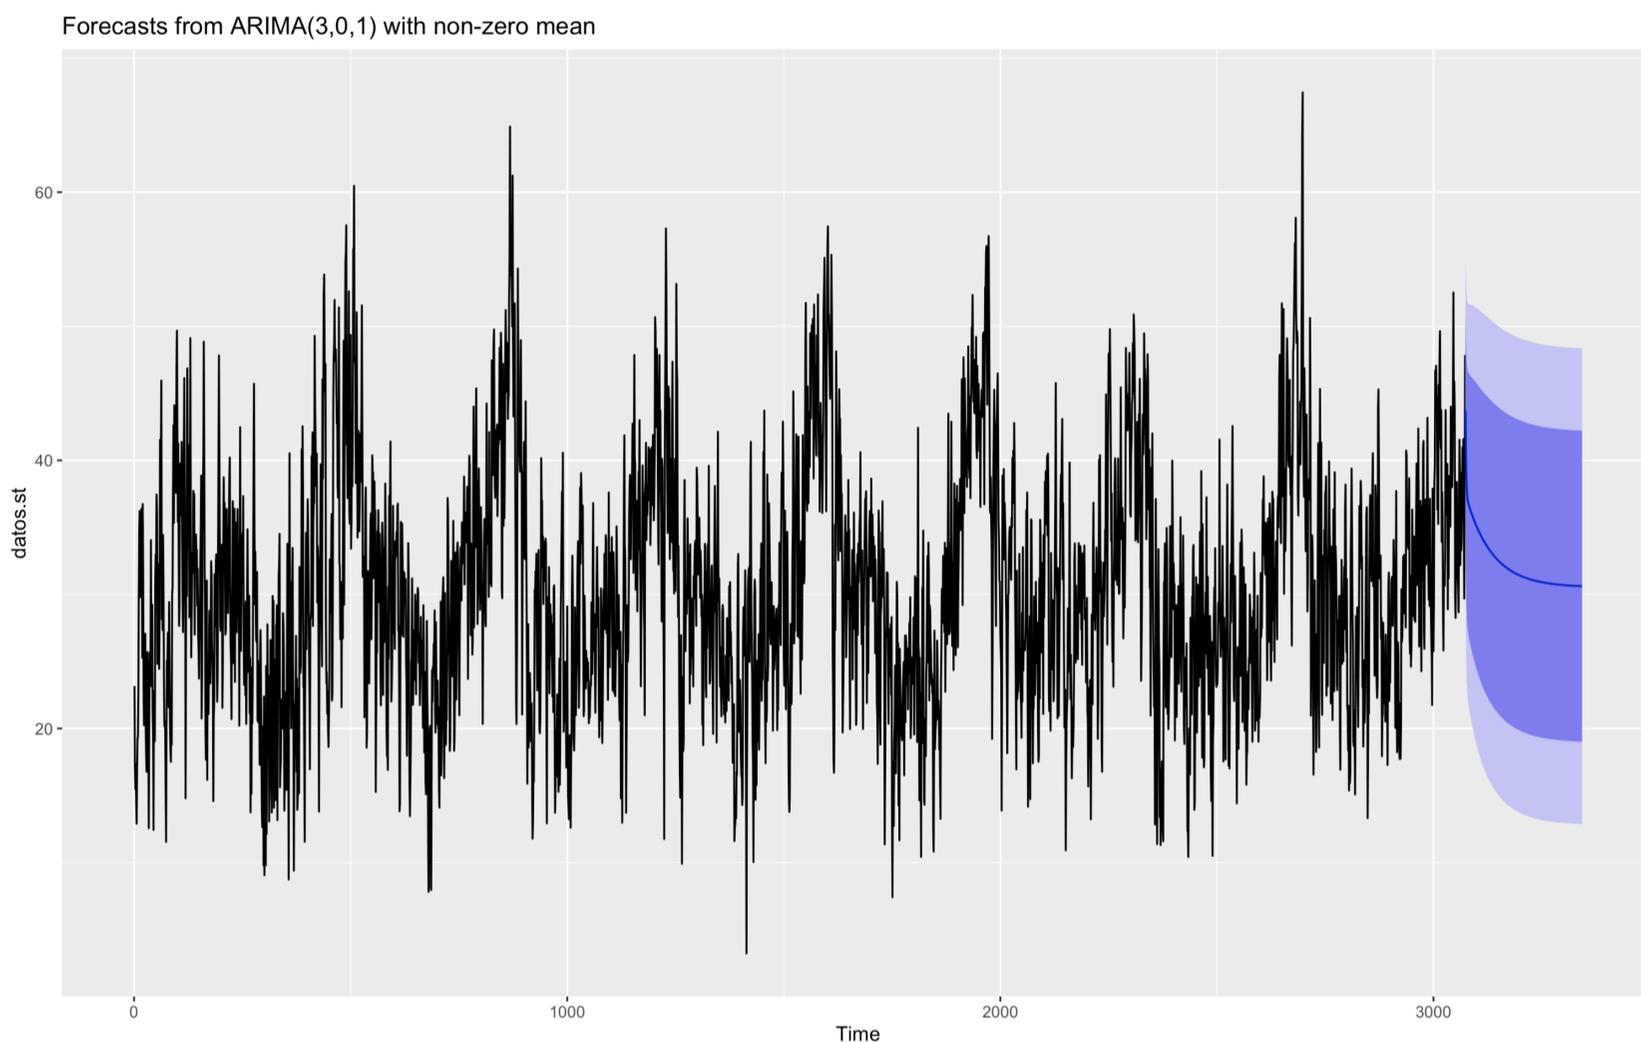
#### 4.2.2.5 Pronósticos de las concentraciones de ozono troposférico:

##### Conjunto de Datos 2.

Una vez ajustado el modelo ARIMA(3,0,1)(1,0,1) y verificado que cumple con las condiciones de ruido blanco en los residuos, se procedió a realizar un pronóstico de las

concentraciones diarias de  $O_3$  en la Ciudad de México para un horizonte extendido de 270 días. Este pronóstico busca capturar las variaciones futuras del ozono, incluyendo las fluctuaciones estacionales y las tendencias observadas previamente.

Gráfico 4.11 Pronóstico de la ecuación ARIMA(3,0,1)(1,0,1): Conjunto de Datos 2.



Fuente: Elaboración propia.

En el Gráfico 4.11, se observa el pronóstico a 270 días generado a partir del modelo ARIMA(3,0,1)(1,0,1). La línea negra continua muestra los datos históricos de  $O_3$ , mientras que la línea azul proyecta los valores predichos para los próximos 270 días. Las bandas sombreadas en diferentes tonos de azul representan los intervalos de confianza del 80% y 95%, los cuales indican la incertidumbre asociada a las predicciones.

El pronóstico proyectado para los 270 días mantiene una tendencia relativamente consistente con los patrones observados en los datos históricos. Las concentraciones de  $O_3$  previstas oscilan dentro de rangos previamente registrados, mostrando fluctuaciones típicas de los ciclos estacionales anuales. La amplitud de las bandas de

confianza aumenta conforme se avanza hacia el futuro, lo que es esperado debido a la creciente incertidumbre en las predicciones a largo plazo.

Las concentraciones de ozono tienden a incrementarse durante los meses de mayor radiación solar, lo cual queda reflejado en el pronóstico. Las fluctuaciones proyectadas sugieren que podría haber picos moderados en las concentraciones de  $O_3$  durante los meses futuros, aunque dentro de los límites históricos registrados.

Si bien el modelo  $ARIMA(3,0,1)(1,0,1)$  captura adecuadamente la dinámica estacional y a corto plazo de las concentraciones de ozono, es importante tener en cuenta que factores externos, como las condiciones meteorológicas, las políticas de control de emisiones y otros eventos no incluidos en el modelo, podrían influir en las concentraciones reales de  $O_3$ .

Los intervalos de confianza permiten un margen de error, ofreciendo una referencia útil para la gestión de la calidad del aire en escenarios futuros. Las proyecciones obtenidas son herramientas valiosas para planificar estrategias preventivas y mitigar los posibles efectos de la contaminación por ozono en la salud pública y el medio ambiente.

### **4.3 Conclusiones del capítulo**

El presente estudio ha desarrollado y evaluado modelos  $ARIMA$  y  $SARIMA$  para pronosticar las concentraciones de  $O_3$  en la Ciudad de México durante el año 2020, un periodo significativamente afectado por la emergencia sanitaria de COVID-19. Se utilizaron dos conjuntos de datos, y a lo largo del análisis se han abordado múltiples aspectos críticos, desde la identificación y validación del modelo hasta la comparación de pronósticos con datos observados y la evaluación de diferentes escenarios futuros.

#### **1. Desarrollo y Validación del Modelo:**

- Utilizando la metodología Box-Jenkins, se identificaron y ajustaron modelos  $ARIMA(3,0,1)(1,0,1)$  y  $SARIMA(1,0,2)(0,0,1)$ , siendo este último el que mejor captura

tanto las dependencias a corto plazo como las estacionalidades presentes en las concentraciones de  $O_3$ .

- Las pruebas de raíces unitarias (ADF y KPSS) confirmaron la estacionariedad de ambas Series de Tiempo, y los correlogramas de ACF y PACF permitieron determinar los componentes autorregresivos y de medias móviles más adecuados para cada conjunto de datos.

- Si bien el modelo ARIMA utilizado en el Conjunto de Datos 2 ofrece una buena precisión para pronósticos a corto plazo, se observó que el modelo SARIMA aplicado al Conjunto de Datos 1 proporciona un mejor ajuste al capturar de manera más efectiva las fluctuaciones estacionales anuales típicas de las concentraciones de  $O_3$ . La capacidad del modelo SARIMA para integrar tanto las variaciones estacionales como no estacionales lo hace más robusto en el contexto de datos ambientales, que están sujetos a ciclos climáticos.

## 2. Pronósticos y Comparación con Datos Observados:

- Los pronósticos generados por ambos modelos (ARIMA y SARIMA) mostraron una buena concordancia con los datos observados, aunque algunos meses durante la pandemia presentaron discrepancias debido a factores externos no modelados, como condiciones meteorológicas (Thompson et al., 2008) y cambios en las actividades humanas.

- Mientras que el modelo ARIMA proporcionó resultados satisfactorios en los primeros meses del pronóstico, el modelo SARIMA mostró una mayor precisión al capturar las estacionalidades a lo largo del año. Los intervalos de confianza fueron útiles en ambos modelos para medir la incertidumbre en las proyecciones, permitiendo una evaluación más clara de la fiabilidad de los pronósticos.

## 3. Impacto de las Actividades Remotas:

- La adopción masiva de actividades remotas durante la pandemia resultó en una reducción de las emisiones de precursores del ozono, como  $NO_x$  y  $COV$ , lo que condujo a menores concentraciones de  $O_3$ . Sin embargo, bajo las consideraciones de

salud europeas previamente mencionadas, no se alcanzó el nivel óptimo para la salud, mostrando la complejidad del sistema atmosférico.

- El análisis con ambos modelos (ARIMA y SARIMA) confirma que, aunque hubo una disminución significativa en las concentraciones de  $O_3$ , los niveles no alcanzaron estándares recomendados. No obstante, esta reducción tuvo efectos positivos en la calidad del aire y la salud pública, reduciendo la incidencia de enfermedades respiratorias y cardiovasculares.

#### 4. Evaluación de Escenarios de Pronóstico:

- Se evaluaron diferentes escenarios futuros para las concentraciones de ozono, considerando variaciones en las políticas de emisión y la adopción de medidas sostenibles. Tanto los modelos ARIMA como SARIMA permitieron prever estas tendencias bajo distintos supuestos.

- Los escenarios optimistas y sostenibles mostraron una tendencia a la disminución de las concentraciones de  $O_3$ , mientras que el escenario pesimista indicó un posible aumento debido a la intensificación de actividades emisoras de contaminantes. Aquí, el modelo SARIMA destacó por su capacidad para proyectar con mayor precisión las fluctuaciones estacionales bajo diferentes escenarios futuros.

En resumen, aunque el modelo ARIMA aplicado al Conjunto de Datos 2 mostró un rendimiento sólido en la predicción a corto plazo, el modelo SARIMA ajustado al Conjunto de Datos 1 es superior en su capacidad para capturar tanto las dependencias no estacionales como las estacionalidades en los datos de  $O_3$ . El uso combinado de ambos modelos permitió comprender de manera integral las dinámicas de las concentraciones de ozono en la Ciudad de México durante un periodo tan excepcional como el de la emergencia sanitaria. Estos resultados ofrecen una base sólida para la planificación de políticas ambientales y la toma de decisiones en futuras emergencias o cambios en los patrones de actividad humana.

## Capítulo 5: Discusión y Conclusiones

El análisis de los niveles de  $O_3$  en la CDMX durante el año 2020 ha revelado hallazgos importantes, principalmente vinculados a la emergencia sanitaria provocada por el COVID-19. Se observó que las restricciones a la movilidad, el cierre de actividades económicas y la disminución de las emisiones vehiculares e industriales llevaron a cambios significativos en las concentraciones de  $O_3$ . Aunque la expectativa inicial era una disminución generalizada de los niveles de este contaminante, los resultados fueron más complejos de lo previsto. En algunos periodos, como los meses de confinamiento total (marzo a mayo de 2020), se registraron aumentos inesperados en las concentraciones de ozono, probablemente debido a la reducción en la presencia de los precursores como los  $NO_x$  que, en condiciones normales, contribuyen también a la eliminación de ozono en la atmósfera.

Por otro lado, durante los meses posteriores a las restricciones más severas, hubo una tendencia general hacia la normalización de los niveles de ozono, con una ligera disminución en comparación con años anteriores. Este fenómeno subraya la influencia de factores meteorológicos y geográficos, que junto con la actividad humana, condicionan la dinámica de este contaminante en áreas urbanas como la Ciudad de México.

### 5.1 Discusión con la Bibliografía Seleccionada

Los resultados obtenidos en esta investigación, presentados en los capítulos 4, revelan comportamientos complejos en las concentraciones de ozono troposférico en la Ciudad de México durante el confinamiento por la pandemia de COVID-19. Estos hallazgos son consistentes con estudios previos mencionados en el capítulo 2, que analizan cómo los cambios en las emisiones de precursores del ozono y las condiciones meteorológicas influyeron en las concentraciones de este contaminante en distintas regiones del mundo.

En primer lugar, se observó que las condiciones climáticas y la presencia de precursores del ozono desempeñaron un papel crucial en la formación de este contaminante, lo cual coincide con los hallazgos de Díaz et al. (2022), quienes indicaron que las concentraciones de  $O_3$  en Guadalajara aumentaron durante los periodos cálidos y secos, debido a la mayor irradiación solar. En esta investigación, se confirma que, durante el confinamiento en la Ciudad de México, la reducción de emisiones vehiculares y de actividades industriales no resultó en una disminución uniforme de las concentraciones de ozono. Por el contrario, en algunos meses, como se observó en el verano, se registraron aumentos en los niveles de este gas, favorecidos por la alta radiación solar y las condiciones atmosféricas específicas de la ciudad. Este comportamiento anómalo está en línea con lo reportado por Garfias Vázquez et al. (2004), quien identificó que en la Ciudad de México las condiciones topográficas y meteorológicas contribuyen significativamente a la acumulación de ozono.

Asimismo, en comparación con otras ciudades globales, los efectos del confinamiento en las concentraciones de ozono no fueron homogéneos. Según el estudio de Venter et al. (2020), en algunos países se observó una disminución en los niveles de ozono como resultado de la reducción de emisiones de precursores, principalmente  $NO_x$  y  $COV$ . Sin embargo, este estudio también enfatizó que la respuesta del ozono a las reducciones de emisiones dependió de las condiciones locales. En el caso de la Ciudad de México, los resultados obtenidos en este estudio muestran que las concentraciones de ozono no disminuyeron de forma consistente, lo cual refleja la complejidad de las interacciones entre precursores, la química atmosférica local y las condiciones meteorológicas. Este hallazgo es comparable al reportado por Sicard et al. (2020) en Madrid, donde, a pesar de la reducción de la actividad vehicular, se observaron aumentos en las concentraciones de ozono debido a la disminución de los aerosoles, que normalmente actúan como sumideros de este contaminante.

El análisis local para la Zona Metropolitana del Valle de México también mostró comportamientos que coinciden con los estudios previos citados en el capítulo 2. Rodríguez (2020), por ejemplo, destacó que aunque se observó una reducción

significativa en las concentraciones de  $NO_x$  durante el confinamiento, los niveles de ozono no disminuyeron de manera consistente. De hecho, en algunos momentos del año se registraron incrementos en las concentraciones, lo que se atribuye a la disminución de  $NO_x$  como un posible sumidero de  $O_3$ . Los resultados de este estudio refuerzan esta observación, ya que durante los primeros meses de confinamiento se registraron aumentos en las concentraciones de ozono, a pesar de la reducción en las emisiones de precursores.

Finalmente, en relación con los estudios globales, como el de Menut et al. (2020), que informó de una disminución en las concentraciones de ozono en áreas rurales y suburbanas de Europa debido a la menor formación de ozono, los resultados de este estudio para la Ciudad de México contrastan notablemente. Esto subraya la importancia de considerar las particularidades locales al analizar el comportamiento de los contaminantes atmosféricos, ya que la alta irradiación solar y las condiciones geográficas específicas de la ZMVM influyeron en que las concentraciones de ozono no siguieran las tendencias observadas en otras regiones.

En conclusión, los resultados presentados en esta investigación confirman que la dinámica del ozono troposférico en la Ciudad de México durante 2020 fue altamente influenciada por factores meteorológicos locales y la presencia de precursores. A pesar de las expectativas iniciales de una reducción generalizada en los niveles de ozono debido a la disminución de la actividad humana durante el confinamiento, los resultados mostraron que las condiciones locales jugaron un papel clave en la evolución de este contaminante. Estos hallazgos complementan la literatura existente y subrayan la importancia de un enfoque local en la gestión de la calidad del aire en zonas urbanas densamente pobladas.

Por otra parte, los resultados de este estudio, además de ayudarnos a comprender más sobre la dinámica del  $O_3$  en la CDMX durante el confinamiento por la pandemia de COVID-19, tienen importantes implicaciones en las esferas sociales, de salud y económicas, las cuales se alinean con las investigaciones previas presentadas en el capítulo 2.

### **5.1.1 Discusión con la Bibliografía Seleccionada en aspectos Sociales**

La pandemia de COVID-19 exacerbó las desigualdades sociales preexistentes, tal como se menciona en el estudio de la Comisión Económica para América Latina y el Caribe (CEPAL, 2020), donde se resalta que las comunidades más vulnerables, como aquellas en situación de pobreza y las marginadas, enfrentaron dificultades desproporcionadas para acceder a servicios de salud y apoyo económico. Los resultados de este estudio muestran cómo la calidad del aire durante el confinamiento no mejoró de manera uniforme, lo cual tiene implicaciones directas en la población más expuesta y con menores recursos. Estas comunidades, que ya padecen desventajas sociales y económicas, pueden haber estado más expuestas a los efectos del ozono troposférico, lo que aumenta las disparidades en salud y calidad de vida.

La disminución de actividades sociales y económicas durante el confinamiento no solo impactó la dinámica económica, sino que también afectó la interacción social, según lo señalado por Pew Research Center (2020). El confinamiento condujo a un cambio en los hábitos de las personas, quienes adoptaron nuevos patrones de consumo y ocio en el hogar. Sin embargo, la reducción en la movilidad y las actividades sociales no se tradujo en una mejora sostenida en la calidad del aire en la Ciudad de México, lo que implica que, a pesar de los sacrificios sociales, los beneficios ambientales fueron limitados.

### **5.1.2 Discusión con la Bibliografía Seleccionada en aspectos de Salud**

El impacto del  $O_3$  en la salud humana es un tema ampliamente documentado en la literatura, como lo menciona Hua et al. (2024), quien destaca que la exposición a altas concentraciones de ozono está asociada con una variedad de problemas de salud, desde enfermedades respiratorias hasta afecciones cardiovasculares. Los resultados de este estudio muestran que, las concentraciones de  $O_3$  en la CDMX no disminuyeron significativamente durante los meses de confinamiento, e incluso aumentaron en algunos periodos, lo que implica un riesgo continuo para la salud pública, especialmente para grupos vulnerables como los niños, los ancianos y aquellos con enfermedades respiratorias preexistentes.

Estos resultados refuerzan la necesidad de políticas públicas que no solo se centren en la reducción de las emisiones de contaminantes, sino también en la protección de la salud de la población durante eventos de crisis. Como mencionó Rodríguez (2020) en su estudio sobre la Ciudad de México, la reducción de las emisiones de  $NO_x$ , un precursor clave del ozono, no fue suficiente para mitigar completamente los efectos negativos del ozono en la atmósfera. En consecuencia, este estudio subraya la importancia de adoptar medidas adicionales para proteger a las poblaciones vulnerables frente a los contaminantes atmosféricos, incluso en situaciones excepcionales como el confinamiento.

### **5.1.3 Discusión con la Bibliografía Seleccionada en aspectos**

#### **Económicos**

El confinamiento global debido a la pandemia de COVID-19 también tuvo profundos efectos económicos. El Fondo Monetario Internacional (2021) reportó que la economía global se contrajo un 3.5% en 2020, afectando todos los sectores, y especialmente a las pequeñas y medianas empresas (PYMES), que sufrieron cierres masivos y pérdidas de ingresos. En el contexto de la Ciudad de México, los resultados de este estudio muestran que, a pesar de la reducción de las actividades industriales y comerciales durante el confinamiento, las concentraciones de ozono no se redujeron de manera significativa. Esto sugiere que los costos económicos del confinamiento, en términos de pérdida de empleo e ingresos, no estuvieron acompañados de beneficios proporcionales en la calidad del aire.

El estudio refuerza lo señalado por Suárez et al. (2021), quienes también observaron una ligera disminución en los niveles de ozono en Guadalajara durante el confinamiento, pero advirtieron que estos cambios podrían no ser sostenibles una vez que las actividades económicas se reanuden. En la Ciudad de México, las implicaciones económicas de los resultados obtenidos en este estudio sugieren que es crucial encontrar un equilibrio entre la recuperación económica y la implementación de políticas que promuevan una mejora a largo plazo en la calidad del aire, sin depender únicamente de la reducción de la actividad económica.

## **5.2 Contribución al conocimiento**

Este estudio contribuye de manera significativa a la comprensión de cómo eventos disruptivos, como la pandemia de COVID-19, pueden afectar los niveles de contaminantes atmosféricos en ciudades densamente pobladas por lo cual puede sostenerse que la hipótesis de esta tesis se cumple. A diferencia de otros estudios que se han centrado principalmente en los niveles de partículas suspendidas o dióxido de carbono, este trabajo se enfoca en el  $O_3$ , un contaminante secundario que ha sido menos analizado en el contexto de la pandemia.

La investigación ofrece un análisis detallado de los efectos temporales en la calidad del aire de la CDMX, utilizando modelos ARIMA que permiten generar pronósticos comparativos entre los niveles reales de ozono y los que habrían sido observados sin las restricciones por la emergencia sanitaria. Esto proporciona una base sólida para futuras investigaciones y políticas públicas orientadas a la mejora de la calidad del aire en la ciudad.

## **5.3 Implicaciones para las políticas públicas**

Los resultados de este estudio tienen importantes implicaciones para el diseño de políticas públicas. La pandemia ha demostrado que la reducción en las actividades humanas puede llevar a mejoras significativas en la calidad del aire, lo que sugiere que las autoridades locales deberían considerar la implementación de políticas permanentes de movilidad sostenible. Estas podrían incluir la promoción del teletrabajo, la inversión en infraestructura para el transporte público eléctrico, la ampliación de las ciclovías y la adopción de vehículos eléctricos tanto en el transporte público como privado.

Asimismo, es fundamental que se continúe promoviendo el uso de energías limpias y la reducción de las emisiones industriales. El confinamiento mostró que la disminución en la actividad industrial tiene un impacto directo en la reducción de ciertos contaminantes,

lo que refuerza la necesidad de transitar hacia un modelo de desarrollo urbano más verde y sostenible.

#### **5.4 Recomendaciones para futuras investigaciones**

Este trabajo ha sentado las bases para el estudio del impacto de eventos disruptivos en los niveles de  $O_3$ , pero es necesario continuar explorando el comportamiento de este contaminante en diferentes contextos. Se recomienda realizar investigaciones a largo plazo para analizar si las reducciones observadas en 2020 se mantuvieron una vez que las actividades económicas regresaron a la normalidad.

Otra área de investigación futura podría centrarse en la relación entre la reducción de otros contaminantes, como las partículas finas (PM10 y PM2.5), y el comportamiento del ozono. Además, sería útil estudiar los impactos directos en la salud pública, no solo en términos de enfermedades respiratorias, sino también en otras afecciones relacionadas con la exposición a altos niveles de ozono.

#### **5.5 Reflexión sobre las limitaciones del estudio**

Este estudio ha presentado una visión comprensiva de los efectos de la pandemia en los niveles de ozono, sin embargo, es importante reconocer algunas limitaciones. Una de ellas es la dependencia exclusiva en los datos de 2020, lo que impide hacer una comparación más robusta con tendencias históricas a largo plazo. Además, el uso del modelo ARIMA, aunque eficaz para pronosticar Series de Tiempo, puede estar limitado por su capacidad para capturar complejidades como la variabilidad en las condiciones meteorológicas o cambios abruptos en las emisiones.

A medida que nuevas metodologías y conjuntos de datos estén disponibles, sería recomendable incorporar técnicas de modelado más avanzadas que consideren factores adicionales como los cambios climáticos, las variaciones estacionales y las interacciones entre diferentes contaminantes.

## **5.6 Cierre reflexivo**

La pandemia de COVID-19 ofreció una oportunidad única para observar cómo las reducciones abruptas en la actividad humana pueden influir en la calidad del aire. Este estudio demuestra que la relación entre las emisiones contaminantes y la calidad del aire es compleja y está sujeta a múltiples factores, pero también refuerza la idea de que los cambios en los patrones de movilidad y actividad económica pueden tener un impacto positivo en el medio ambiente.

Estos hallazgos invitan a reflexionar sobre la necesidad urgente de adoptar prácticas sostenibles de manera permanente, más allá de eventos excepcionales como la pandemia. Las ciudades deben repensar sus modelos de desarrollo urbano para ser más resilientes y sostenibles, priorizando la salud pública y la calidad del aire como elementos clave para el bienestar de sus habitantes. Esta crisis ha demostrado que un aire más limpio es posible, y ahora corresponde a las autoridades, los científicos y la sociedad en su conjunto trabajar juntos para hacerlo una realidad duradera.

## Bibliografía

- Adler, D. y Severnini, E. (2023). Timing matters: Intra-day shifts of economic activity and ambient ozone concentrations. *Journal of Public Economics*, 223, 104905. <https://www.sciencedirect.com/science/article/pii/S0047272723000877>
- Afrashtehfar, K. I., Jurado, C. A., Al-Sammarraie, A., y Saeed, M. H. (2023). Consequences of COVID-19 and Its Variants: Understanding the Physical, Oral, and Psychological Impact. *International Journal of Environmental Research and Public Health*, 20(4), 3099. <https://doi.org/10.3390/ijerph20043099>
- Agencia Europea de Medio Ambiente. (1998). “Ozono troposférico”. En: *El medio ambiente en Europa: Segunda evaluación*. European Environment Agency. Disponible en: <https://www.eea.europa.eu/es/publications/92-9167-087-1/page002.html#4>
- American Lung Association. (2020). Health Effects of Ozone and Particle Pollution. Recuperado de <https://www.lung.org/clean-air/outdoors/what-makes-air-unhealthy/ozone>
- Atchison, C.J., Davies, B., Cooper, E., Lound, A., Whitaker, M., Hampshire, A., Azor, A., Donnelly, C. A., Chadeau-Hyam, M., Cooke, G. S., Ward, H. y Elliott, P. (2023). Long-term health impacts of COVID-19 among 242,712 adults in England. *Nature Communication*, 14, 6588. <https://doi.org/10.1038/s41467-023-41879-2>
- Banco Mundial. (2020). The impact of COVID-19 on small and medium-sized enterprises. Recuperado de <https://www.worldbank.org/en/topic/sme/finance>
- Bell, M. L., Zanobetti, A., y Dominici, F. (2014). Who is more affected by ozone pollution? A systematic review and meta-analysis. *American Journal of Epidemiology*, 180(1), 15-28. <https://doi.org/10.1093/aje/kwu115>
- Bergmann, E., Bender, J., y Weigel, H. J. (2016). Impact of tropospheric ozone on terrestrial biodiversity: A literature analysis to identify ozone sensitive taxa. *Journal of Applied Botany and Food Quality*, 90, 83-105. <https://doi.org/10.5073/JABFO.2017.090.012>
- Biswas, A. K. (1984). “Integrated Water Management: Some International Dimensions”. En A. K. Biswas (Ed.). *Integrated Water Management: International Experiences and Perspectives* (pp. 1-21). Springer. [https://doi.org/10.1007/978-94-009-2913-5\\_1](https://doi.org/10.1007/978-94-009-2913-5_1)
- Bonaccorsi, G., Pierri, F., Cinelli, M., y Pammolli, F. (2020). Economic and social consequences of human mobility restrictions under COVID-19. *Economic Sciences*, 117(27), 15530-15535. <https://doi.org/10.1073/pnas.2007658117>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., y Ljung, G. M. (2016). *Time Series Analysis: Forecasting and Control* (5ta., edición). John Wiley & Sons.

- Calbi, M., Langiulli, N., Ferroni, F, Montalti, M., Kolesnikov, A., Gallese, V. y Umiltá, M. A. (2021). The consequences of COVID-19 on social interactions: an online study on face covering. *Scientific Reports*, 11, 2601. <https://doi.org/10.1038/s41598-021-81780-w>
- Centro Nacional de Prevención de Desastres. (2019). El Ozono como contaminante de Aire y Riesgo para la salud. México. Recuperado de: <https://www.gob.mx>
- Chu, I. Y-H., Alam, P., Larson, H. J., y Lin, L. (2020). Social consequences of mass quarantine during epidemics: a systematic review with implications for the COVID-19 response, *Journal of Travel Medicine*, 27(7), taaa192. <https://doi.org/10.1093/jtm/taaa192>
- Comisión Económica para América Latina y el Caribe. (CEPAL). (2020). Los impactos sociodemográficos de la pandemia de COVID-19 en América Latina y el Caribe. Santiago de Chile. Recuperado de: <https://www.cepal.org/es/publicaciones/47922-impactos-sociodemograficos-la-pandemia-covid-19-america-latina-caribe>
- Comisión Europea. (s. f.). EU air quality standards. Medio Ambiente. Recuperado de: <https://environment.ec.europa.eu>
- Consejo Nacional de Humanidades, Ciencias y Tecnologías. (ONAHCYT). (2024). Covid-19 México. Recuperado de: <https://datos.covid-19.conacyt.mx/>
- Contreras, M. G., y Manrique, J. J. (2019). Retos en la administración del agua en México: Una revisión sobre la escasez y la gestión del recurso hídrico. *Gestión y Política Pública*, 28(3), 239-272. <https://doi.org/10.29265/gypp.v28i3.734>
- Crutzen, P. J. (1988). Tropospheric Ozone: An Overview. <https://link.springer.com/book/10.1007/978-94-009-2913-5>
- D'Agostino, G., Scala, A., y Zaccaria, A. (2022). Urban Scaling and Growth in Europe. *Journal of Urban Management*, 11(2), 148-158. <https://doi.org/10.1016/j.jum.2022.08.001>
- Díaz-Torres, J. J., Ojeda-Castillo, V., Hernández-Mena, L., Vergara-Sánchez, J., Saldarraga-Noreña, H. A. y Murillo-Tovar, M. A. (2022). Análisis a Largo Plazo del Ozono Troposférico en el Área Urbana de Guadalajara, México: Una Nueva Perspectiva de un Criterio Alternativo. *Atmosphere*, 13(2), 152. <https://www.mdpi.com/2073-4433/13/2/152>
- Fondo Monetario Internacional. (2021). World Economic Outlook: Managing Divergent Recoveries. Recuperado de <https://www.imf.org/en/Publications/WEO>
- García-Reynoso, A., Jazcilevich, A., Ruiz-Suárez, L. G., Torres-Jardón, R., Suárez Lastra, M., y Reséndiz Juárez, N. A. (2009). Ozone weekend effect analysis in México City. *Atmósfera*, 22(3), 281-297. Disponible en: [https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S0187-62362009000300004](https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0187-62362009000300004)
- Gobierno de México. (2020). Datos Covid-19. Recuperado el 10 de octubre de 2023 de: <https://coronavirus.gob.mx/>

- Gobierno de la Ciudad de México. (2022). Consultas de Aire y Salud. Recuperado el 10 de octubre de 2023 de: <http://www.cdmx.gob.mx/>
- Gobierno de la Ciudad de México. (n.d.). Red automática de monitoreo atmosférico. Datos CDMX. Recuperado el 12 de mayo de 2024 de: <https://datos.cdmx.gob.mx/dataset/red-automatica-de-monitoreo-atmosferico>
- Gobierno de los Estados Unidos de América. Environmental Protection Agency. (2013). Report on the 2013 U.S. Environmental Protection Agency (EPA) International Decontamination Research and Development Conference. Research Triangle Park, NC, November 05 - 07, 2013. U.S. Environmental Protection Agency, Washington, DC. EPA/600/R-14/210.
- \_\_\_\_\_. United States Environmental Protection Agency. (2020). Nitrogen Oxides (NO<sub>x</sub>) Control Regulations. Recuperado de <https://www.epa.gov/no2-pollution>
- González-Casimiro, M. P. (2009). Análisis de series temporales: modelos ARIMA. Facultad de Ciencias Económicas y Empresariales. Universidad del País Vasco. ISBN: 978-84-692-3814-1.
- Grulke, N. E., y Heath, R. L. (2019). Ozone effects on plants in natural ecosystems. *Plant Biology*, 12(51),12-37. <https://doi.org/10.1111/plb.12971>
- Hamilton, J. D. (1994). *Time Series Analysis*. Princeton University Press.
- Hosseinzadeh, P., Zareipour, M., Baljani, E., & Moradali, M. R. (2022). Social Consequences of the COVID-19 Pandemic. A Systematic Review. *Investigación y Educación en Enfermería*, 40(1), e10. <https://doi.org/10.17533/udea.iee.v40n1e10>
- Hua, Q., Meng, X., Gong, J., Qiu, X., Shang, J., Xue, T., y Zhu, T. (2024). Ozone exposure and cardiovascular disease: A narrative review of epidemiology evidence and underlying mechanisms. *Fundamental Research*, In Press, Journal Pre-proof. <https://www.sciencedirect.com/science/article/pii/S2667325824001213>
- IDEAM. (s.f.). Definición y características del ozono troposférico. Recuperado de <http://www.ideam.gov.co/web/contaminacion-y-calidad-ambiental/ozono-troposferico>
- Instituto Nacional de Estadística y Geografía. (INEGI). (2020). Número de habitantes por entidad federativa. Recuperado de: <https://cuentame.inegi.org.mx>
- International Labour Organization. (2020). COVID-19 y el mundo del trabajo. Recuperado de <https://www.ilo.org/resource/brief/ilo-monitor-covid-19-and-world-work-7th-edition>
- Intergovernmental Panel on Climate Change. (2013). *Climate Change 2013: The Physical Science Basis*. Recuperado de <https://www.ipcc.ch/report/ar5/wg1/>
- Kim, S. Y., Kim, E., y Kim, W. J. (2020). Health Effects of Ozone on Respiratory Diseases. *Tuberculosis and Respiratory Diseases*, 83(Supple 1), S6–S11. <https://doi.org/10.4046/trd.2020.0154>
- Le, T. T., y Wang, P. K. (2020). Impact of COVID-19 on Air Pollution in Vietnam. *Geophysical Research Letters*, 47(22), e2020GL089184. <https://doi.org/10.1029/2020GL089184>

- Li, S., Courbet, G., Ourry, A., y Ainsworth, E. A. (2019). Elevated Ozone Concentration Reduces Photosynthetic Carbon Gain but Does Not Alter Leaf Structural Traits, Nutrient Composition or Biomass in Switchgrass. *Plants (Basel, Switzerland)*, 8(4), 85. <https://doi.org/10.3390/plants8040085>
- McKibbin, W., y Fernando, R. (2023). The global economic impacts of the COVID-19 pandemic. *Economic Modelling*, 129, 106551. <https://doi.org/10.1016/j.econmod.2023.106551>
- Miyazaki, K., Bowman, K., Sekiya, T., Takigawa, M., Neu, J. L., Sudo, K., Osterman, G., y Eskes, H. (2021). Global tropospheric ozone responses to reduced NO<sub>x</sub> emissions linked to the COVID-19 worldwide lockdowns. *Science Advances*, 7(24), eabf7460. <https://doi.org/10.1126/sciadv.abf7460>
- Molina, L. T., y Molina, M. J. (2004). Improving air quality in megacities: Mexico City case study. *Annals of the New York Academy of Sciences*, 1023(1), 142-158. <https://doi.org/10.1196/annals.1319.006>
- Mukherjee, A., Yadav, D. S., Agrawal, S. B., y Agrawal, M. (2021). Ozone a persistent challenge to food security in India: Current status and policy implications. *Current Opinion in Environmental Science and Health*, 19, 100220. <https://doi.org/10.1016/j.coesh.2020.10.008>
- Naseer, S., Khalid, S., Parveen, S., Abbass, K., Song, H. y Achim, M. V. (2023). COVID-19 outbreak: Impact on global economy. *Frontiers in Public Health*, 10(29), 1009393. <https://doi.org/10.3389/fpubh.2022.1009393>
- Nguyen, D-H. (2022). Tropospheric ozone and NO<sub>x</sub>: A review of worldwide variation and meteorological influences. *Environmental Technology Innovation*, 28, 102809. <https://www.sciencedirect.com/science/article/pii/S2352186422002784>.
- Oliva-Sánchez, P. F., López-Landeros, S., Velázquez-Trejo, D. A., Brenner-Muslera, E., Martínez-Kobeh, J. P., González-Reyes, D., Guasque-Gil, I., y Vadillo-Ortega, F. (2022). Asociación de la exposición a contaminantes atmosféricos con indicadores epidemiológicos de morbilidad y mortalidad por Covid-19 en el Valle de México. *Salud Pública de México*, 64(5, sept-oct), 453–463. <https://doi.org/10.21149/13814>
- Ontiveros, M. (2019). Análisis de la eficacia, eficiencia y equidad de los programas para reducir las emisiones de ozono troposférico en la Ciudad de México. *Economía UNAM*, 16(48), 239-265. <https://doi.org/10.22201/fe.24488143e.2019.48.498>
- Organización para la Cooperación y el Desarrollo Económico. (OECD en inglés). (2020). The impact of COVID-19 on digitalisation. Recuperado de <https://www.oecd.org/coronavirus/policy-responses/the-impact-of-covid-19-on-digitalisation-and-digitaltransformation-617f62b6/>
- Organización Mundial de la Salud. (OMS). (2020a). Coronavirus. Recuperado de: <https://www.who.int/es/health-topics/coronavirus>.
- \_\_\_\_\_. (2020b). Contaminación del Aire. Recuperado de: [https://www.who.int/es/news-room/fact-sheets/detail/ambient-\(outdoor\)-air-quality-and-health](https://www.who.int/es/news-room/fact-sheets/detail/ambient-(outdoor)-air-quality-and-health)

- \_\_\_\_\_. (2020). El impacto de la pandemia de COVID-19 en los recursos y servicios de enfermedades no transmisibles. Recuperado de: <https://www.who.int/publications/i/item/ncds-covid-rapid-assessment>
- \_\_\_\_\_. (2021). Salud mental y COVID-19. Recuperado de <https://www.who.int/teams/mental-health-and-substance-use/mental-health-and-covid-19>
- Organización de las Naciones Unidas. (ONU). (2020). Informe de Política: COVID-19 and the Need for Action on Mental Health. Recuperado de [https://www.un.org/sites/un2.un.org/files/un\\_policy\\_briefcovid\\_and\\_mental\\_health\\_final.pdf](https://www.un.org/sites/un2.un.org/files/un_policy_briefcovid_and_mental_health_final.pdf)
- Organización Panamericana de la Salud. (OPS). (2020). La COVID-19 afectó el funcionamiento de los servicios de salud para enfermedades no transmisibles en las Américas. Recuperado de <https://www.paho.org/es/noticias/17-6-2020-covid-19-afecto-funcionamiento-servicios-salud-para-enfermedades-no>
- \_\_\_\_\_. (2020). Policy Brief: COVID-19 y la necesidad de actuar en materia de salud mental. Recuperado de [https://www.un.org/sites/un2.un.org/files/un\\_policy\\_briefcovid\\_and\\_mental\\_health\\_final.pdf](https://www.un.org/sites/un2.un.org/files/un_policy_briefcovid_and_mental_health_final.pdf)
- Pew Research Center. (2020). How the Coronavirus Outbreak Has – and Hasn’t – Changed the Way Americans Work. Recuperado de <https://www.pewresearch.org/social-trends/2020/12/09/howthe-coronavirus-outbreak-has-and-hasnt-changed-the-way-americans-work/>
- Piketty, T., y Zucman, G. (2023). Inequality and Economic Growth: The Role of Social Structures. *Journal of Economic Inequality*, 21(1), 63-82. <https://doi.org/10.1016/j.jeconine.2023.01.001>
- Ramírez-Ortiz, J., Castro-Quintero, D., Lerma-Córdoba, C., Yela-Ceballos, F., y Escobar-Córdoba, F. (2020). Consequences of the COVID-19 pandemic in mental health associated with social isolation. In *SciELO Preprints*. <https://doi.org/10.1590/SciELOPreprints.303>
- Sacchelli, S., Carrari, E., Paoletti, E., Anav, A., Hoshika, Y., Sicard, P., Screpanti, A., Chirici, G., Coccozza, C., y De Marco, A. (2021). Economic impacts of ambient ozone pollution on wood production in Italy. *Scientific Reports*, 11(1), 154. <https://doi.org/10.1038/s41598-020-80516-6>
- Sicard, P., De Marco, A., Agathokleous, E., Feng, Z., Xu, X., Paoletti, E., Rodriguez, J. J. D., y Calatayud, V. (2020). Amplified ozone pollution in cities during the COVID-19 lockdown. *The Science of the Total Environment*, 735, 139542. <https://doi.org/10.1016/j.scitotenv.2020.139542>
- Smith, D. M., y Jones, A. L. (2022). The Role of Vaccination in Reducing COVID-19 Transmission: A Review of Current Literature. *Frontiers in Public Health*, 10, Article 9676228. <https://doi.org/10.3389/fpubh.2022.9676228>
- United Nations International Children’s Emergency Fund. (UNICEF). (2020a). COVID-19 and education: Reimagine Education in Latin America and the Caribbean. Recuperado de <https://www.unicef.org/lac/en/reimagine-education-latin-america-and-caribbean>
- \_\_\_\_\_. (2020b). The socio-economic impact of COVID-19 on children and families. Recuperado de <https://www.unicef.org/reports/socio-economic-impact-covid-19-children-and-families>

- Wendt-Viola, T., y Lahorgue-Nunes, M. (2022). Social and environmental effects of the COVID-19 pandemic on children. *Jornal de Pediatria*, 98, (Supplement 1), S4-S12, <https://doi.org/10.1016/j.jpmed.2021.08.003>
- Whittle, P. (1951). *Hypothesis Testing in Time Series Analysis*. Cambridge. Almqvist & Wiksells.
- Wilkinson, S., Mills, G., Illidge, R., y Davies, W.J. (2012). How is ozone pollution reducing our food supply? *Journal of Experimental Botany*, 63(2), 527–536. <https://doi.org/10.1093/jxb/err317>
- World Bank. (2019). *World Development Report 2019: The Changing Nature of Work*. Recuperado de <https://www.worldbank.org/en/publication/wdr2019>
- Zhang, J.J., Wei, Y., y Fang, Z. (2019). Ozone Pollution: A Major Health Hazard Worldwide. *Frontiers in Immunology*, 10, 2518. <https://doi.org/10.3389/fimmu.2019.02518>
- Zhao, B. (2020). COVID-19 pandemic, health risks, and economic consequences: Evidence from China. *China Economic Review*, 64, 101561. <https://doi.org/10.1016/j.chieco.2020.101561>
- Zheng, B., Geng, G., Ciais, P., Davis, S. J., Martin, R. V., Meng, J. y Wu, L. (2020). Satellite-Based Estimates of Decline and Recovery in Pollution Emissions During COVID-19: A China Case Study. *Scientific Reports*, 10(1), 21625. <https://doi.org/10.1038/s41598-020-80516-6>