



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

---

---

FACULTAD DE CIENCIAS

EFFECTOS DE LA METEOROLOGÍA Y LAS EMISIONES  
EN LA CONCENTRACIÓN DE CONTAMINANTES  
ATMOSFÉRICOS DURANTE LA CONTINGENCIA  
SANITARIA 2020.

T E S I S

QUE PARA OBTENER EL TÍTULO DE:

CIENCIAS DE LA TIERRA

P R E S E N T A :

NAIVY MONTSERRAT JIMENEZ QUITERIO

TUTOR

DR. ADOLFO VICENTE MAGALDI HERMOSILLO



CIUDAD UNIVERSITARIA, Cd. Mx., 2021



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

*Para mi familia, amigos y maestros.*

# Agradecimientos

A la Universidad Nacional Autónoma de México.

A la Facultad de Ciencias.

A mi mamá, mis hermanas Bibiana y Grisel y mi papá.

A mis tíos, Rodolfo, Yolanda, Javier, Everardo y mis primos Marian, Mariana, Moni, Irene y Alex.

A Dara y Adolfo por su paciencia y disposición a enseñarme.

A mis amigos.

A mis sinodales Harry, Abraham y Pablo.

# Resumen

Debido a la pandemia producida por el virus SARS-CoV-2 a finales de marzo del año 2020 se estableció un nuevo programa en México llamado quédate en casa, también denominado Jornada Nacional de Sana distancia, el cuál comenzó a implementarse con el fin de frenar la cantidad de contagios, este programa estableció el cierre de restaurantes, tiendas, centros comerciales, algunas industrias no esenciales así como escuelas. Un impacto de esta serie de medidas fue la reducción en la movilidad de los ciudadanos.

El objetivo de este trabajo es analizar el impacto que generaron estas medidas en las concentraciones de los siguientes contaminantes  $O_3$ ,  $PM_{2.5}$ ,  $NO$ ,  $NO_2$  y  $CO$ , medidos en la estación meteorológica ubicada en el Centro de Ciencias de la Atmósfera en la Ciudad Universitaria. Para considerar la influencia que tiene la meteorología, sobre la concentración de los contaminantes, se utilizó un modelo aditivo generalizado (GAM). Por otro lado, también se estudiaron las tendencias sobre las concentraciones obtenidos del modelo de los contaminantes descritos anteriormente durante los últimos 5 años, encontrando una tendencia negativa para  $O_3$ ,  $NO$ ,  $NO_2$  y  $CO$  mientras que el  $PM_{2.5}$  tuvo una tendencia positiva aunque muy moderada. De las salidas del modelo GAM, para el año 2020 tomando en cuenta cuatro periodos correspondientes a las Fases: 0, 1, 2 y 3, en donde la fase 0 corresponde al periodo previo al inicio de la pandemia y las fases 1,2 y 3 al programa quédate en casa (estas fases implicaron medidas más estrictas que restringían aún más la movilidad) y considerando el impacto de la meteorología, se pudo identificar que, el  $CO$  y el  $NO$  presentaron concentraciones menores comparando con años previos, debido a una disminución de emisiones, mientras que las concentraciones de  $PM_{2.5}$  mostraron aumento en las fases

1 y 2, sin embargo en la fase 3 se identificó una disminución debido a la contribución meteorológica y a una disminución de las emisiones. Finalmente el  $O_3$  mostró en las fases 1, 2 y 3 un aumento en las concentraciones.

# Índice general

<b>Agradecimientos</b>	<b>II</b>
<b>Resumen</b>	<b>III</b>
<b>1. Introducción</b>	<b>1</b>
<b>2. Marco Teórico</b>	<b>5</b>
2.1. Contaminantes criterios . . . . .	5
2.1.1. Ozono . . . . .	6
2.1.2. Óxidos de Nitrógeno . . . . .	6
2.1.3. Monóxido de Carbono ( <i>CO</i> ) . . . . .	7
2.1.4. Material Particulado ( <i>PM</i> ) . . . . .	8
2.2. Meteorología . . . . .	8
2.3. Modelo Aditivo Generalizado . . . . .	12
2.4. Tendencias . . . . .	14
<b>3. Metodología</b>	<b>16</b>
3.1. Área de estudio . . . . .	16
3.2. Filtrado y control de calidad . . . . .	17
3.3. Diagramas del flujo del programa . . . . .	18
<b>4. Resultados</b>	<b>21</b>
4.1. Selección de modelo . . . . .	21
4.2. Antecedentes del comportamiento de los contaminantes y meteorología	26

<i>ÍNDICE GENERAL</i>	VI
4.3. Estadística descriptiva del modelo . . . . .	32
4.3.1. Relación de los contaminantes con las variables meteorológicas.	37
4.4. Modelo y observaciones . . . . .	41
4.5. Tendencia obtenida . . . . .	44
4.6. Análisis de las concentraciones por fases. . . . .	44
<b>5. Conclusiones</b>	<b>55</b>
<b>A. Meteorología 2020</b>	<b>64</b>



# Índice de figuras

2.1. Modelos de regresión y su vinculación (Ravindra et al., 2019) . . . . .	14
3.1. Estación Centro de Ciencias de la Atmósfera (Google-Earth, SF). . .	16
3.2. Diagrama de flujo del programa que permite generar las bases de datos.	20
3.3. Diagrama del flujo para el modelo GAM. . . . .	20
4.1. a) MDA8 para la estación CCA del 2015 al 2019, b) Ciclo anual del MDA8 del 2015-2019. . . . .	27
4.2. a) Promedio diario (CCA de 2015 al 2019, b) Ciclo anual del promedio diario del 2015-2019. . . . .	27
4.3. a) Promedio diario de $CO$ para la estación CCA del 2015 al 2019, b) Ciclo anual de $CO$ del 2015-2019. . . . .	28
4.4. a) Promedio diario de $PM_{2.5}$ para la estación CCA del 2015 al 2019, b) Ciclo anual de $PM_{2.5}$ del 2015-2019. . . . .	28
4.5. a) Promedio diario de $NO$ para la estación CCA del 2015 al 2019, b) Ciclo anual de $NO$ del 2015-2019. . . . .	28
4.6. a) Promedio diario de $NO_2$ para la estación CCA del 2015 al 2019, b) Ciclo anual de $NO_2$ del 2015-2019. . . . .	29
4.7. a) Máximo diario de $NO_2$ para la estación CCA del año 2015 al año 2019, b) Ciclo anual de $NO_2$ del periodo 2015-2019. . . . .	29
4.8. a) Promedio diario de Temperatura del 2015-2019. b) Ciclo anual de temperatura con promedio diario del 2015-2019. . . . .	30

4.9. a) Promedio diario de Radiación del 2015-2019. b) Ciclo anual de Radiación con promedio diario del 2015-2019. . . . .	31
4.10. a) Promedio diario de Presión del 2015-2019. b) Ciclo anual de Presión con promedio diario del 2015-2019. . . . .	31
4.11. a) Promedio diario de la velocidad del viento del 2015-2019. b) Ciclo anual de la velocidad del viento con promedio diario del 2015-2019. . . . .	31
4.12. a) Promedio diario de humedad relativa del 2015-2019. b) Ciclo anual de humedad relativa con promedio diario del 2015-2019. . . . .	32
4.13. a) Precipitación acumulada del 2015-2019. b) Ciclo anual de precipitación acumulada diaria del 2015-2019. . . . .	32
4.14. Gráficos de residuales del modelo para MDA8 de Ozono. . . . .	34
4.15. Gráficos de residuales del modelo para promedio diario de Ozono. . . . .	34
4.16. Gráficos de residuales del modelo para promedio diario de $CO$ . . . . .	35
4.17. Gráficos de residuales del modelo para promedio diario de $PM_{2.5}$ . . . . .	35
4.18. Gráficos de residuales del modelo para promedio diario de $NO$ . . . . .	36
4.19. Gráficos de residuales del modelo para promedio diario de $NO_2$ . . . . .	36
4.20. Gráficos de residuales del modelo para valores máximos diarios de $NO_2$ . . . . .	37
4.21. Variables explicativas para promedio diario de $O_3$ . . . . .	39
4.22. Variables explicativas para MDA8 de $O_3$ . . . . .	39
4.23. Variables explicativas para $CO$ . . . . .	40
4.24. Variables explicativas para $PM_{2.5}$ . . . . .	40
4.25. Variables explicativas para $NO$ . . . . .	40
4.26. Variables explicativas para promedio diario de $NO_2$ . . . . .	41
4.27. Variables explicativas para máximo diario de $NO_2$ . . . . .	41
4.28. a) Concentraciones observadas y modeladas para Promedio diario. b) Concentraciones observadas y modeladas para MADA8. . . . .	42
4.29. Concentraciones observadas y modeladas para $CO$ . . . . .	42
4.30. Concentraciones observadas y modeladas para $PM_{2.5}$ . . . . .	43
4.31. Concentraciones observadas y modeladas para $NO$ . . . . .	43

4.32. a) Concentraciones observadas y modeladas para Promedio diario. b) Concentraciones observadas y modeladas para MADA8. . . . .	43
4.33. Concentraciones observadas en el 2020 y ciclo anual del 2015-2019. . .	45
4.34. Esquemas de los escenarios obtenidos. . . . .	46
4.36. Concentraciones observadas, modeladas y promedio del 2015-2019 para <i>CO</i> . . . . .	50
4.35. a) Concentraciones observadas, modeladas y promedio del 2015-2019 para promedio diario de <i>NO<sub>2</sub></i> . b) Concentraciones observadas, mode- ladas y promedio del 2015-2019 para valor máximo de <i>NO<sub>2</sub></i> . . . . .	51
4.37. Concentraciones observadas, modeladas y promedio del 2015-2019 para <i>NO</i> . . . . .	51
4.38. Concentraciones observadas, modeladas y promedio del 2015-2019 para promedio diario de <i>O<sub>3</sub></i> (gráfica superior) para MDA8 (gráfica inferior). . . . .	52
4.39. Concentraciones observadas, modeladas y promedio del 2015-2019 para <i>PM<sub>2.5</sub></i> . . . . .	52
A.1. Temperatura máxima 2020 y promedio 2015-2019 . . . . .	64
A.2. Radiación: 2020 y promedio 2015-2019 . . . . .	65
A.3. Humedad relativa: 2020 y promedio 2015-2019 . . . . .	65
A.4. Velocidad del viento: 2020 y promedio 2015-2019 . . . . .	65
A.5. Presión: 2020 y promedio 2015-2019 . . . . .	66

# Índice de tablas

1.1. Fases y medidas de seguridad sanitaria ante la pandemia por SARS-CoV-2 (GOB.MX, ) (CDMX, 2020). . . . .	3
3.1. Datos disponible de calidad del aire y meteorología. . . . .	17
3.2. Lista de las variables empleadas para el modelo . . . . .	19
4.1. Variables empleadas en cada modelo, así como estadística descriptiva para $O_3$ . . . . .	22
4.2. Variables empleadas en cada modelo, así como estadística descriptiva para $CO$ . . . . .	23
4.3. Variables empleadas en cada modelo, así como estadística descriptiva para $NO$ . . . . .	24
4.4. Variables empleadas en cada modelo, así como estadística descriptiva para $NO_2$ . . . . .	25
4.5. Variables empleadas en cada modelo, así como estadística descriptiva para $PM_{2.5}$ . . . . .	25
4.6. Tendencia obtenida para cada contaminante. . . . .	44
4.7. Promedio de concentraciones para las fases de contingencia. P= Promedio diarios, m= MDA8 y máx=Máximo diario . . . . .	53
4.8. Promedio de concentraciones para las fases de contingencia. . . . .	53
4.9. Diferencia del promedio de concentraciones observadas en el 2020 y los resultados del modelo con las del Promedio 2015-2019, para $O_3$ y $NO_2$ donde, P=Promedio, m=MDA8 y máx=Máximo diario. . . . .	53

4.10. Diferencia del promedio de lo observado 2020 y del modelo con el Pro- medio 2015-2019 para <i>NO</i> , <i>CO</i> y <i>PM<sub>2.5</sub></i> . . . . .	54
---	----

# Capítulo 1

## Introducción

La calidad del aire se ha convertido en una preocupación creciente en todo el mundo, debido a que una exposición prolongada puede causar problemas de salud, enfermedades crónicas e incluso la muerte (World Health Organization, 2005); (Chen et al., 2007).

La Organización Mundial de la salud (OMS) estimó que a nivel mundial 4,2 millones de muertes se atribuyeron a efectos de la contaminación del aire en el 2016 (WHO, 2018).

Debido a esto, diversos países han implementado medidas para disminuir la contaminación del aire en las grandes metrópolis.

Para el estudio de la contaminación del aire, el año 2020 se ha convertido en un año clave debido a que, en diciembre del año 2019 una nueva enfermedad surgió en Wuhan, China, la cual tuvo una rápida dispersión dentro de ese país y se exportó a más de 20 países para antes del 30 de enero de 2020. Ante la ausencia de un tratamiento efectivo para esta nueva enfermedad, se comenzaron a implementar en China, medidas de aislamiento, cuarentenas, distanciamiento social y la contención comunitaria (Wilder-Smith and Freedman, 2020). Ante la propagación mundial de esta enfermedad muchos países empezaron a implementar medidas estrictas como las establecidas en China para frenar la propagación de la enfermedad, que la Organización Mundial de la Salud declaró como pandemia el 13 de marzo del 2020. Se cancelaron miles

de eventos, se cerraron escuelas, restaurantes, bares y varios sistemas de transporte colectivo fueron cerrados o reducidos en sus frecuencias de servicio (Cohen and Kupferschmidt, 2020). En consecuencia, científicos realizaron estudios en diferentes ciudades y países para encontrar los posibles beneficios en la calidad del aire de estas medidas. En algunos lugares como en la India se encontró una disminución en las concentraciones de:  $PM_{2.5}$ ,  $PM_{10}$ ,  $CO$ ,  $NO_2$ , mientras que el  $O_3$  mostró un aumento (Sharma et al., 2020); en China utilizando imágenes satelitales de la NASA se detectó una disminución significativa de  $NO_2$  (NASA, 2020); en São Paulo Brasil encontraron reducciones de  $NO$ ,  $NO_2$  y  $CO$  y un aumento de  $O_3$  (Nakada and Urban, 2020); el estudio de (Kumari and Toshniwal, 2020) mostró que ciudades como Beijing, Bengaluru, Delhi, Lima, Mumbai, Roma y Wuhan mostraron una reducción significativa durante los periodos de aislamiento en las concentraciones de:  $PM_{2.5}$ ,  $PM_{10}$  y  $NO_2$ , sin embargo,  $SO_2$  y  $O_3$  mostraron una tendencia mixta; Para la Ciudad de México en un estudio realizado para los meses de marzo a mayo del 2018-2020, se encuentra una mayor disminución en el pico de  $NO_x$  del año 2020 comparado con dos años previos, también muestran que los perfiles de las medianas de  $O_3$  en un ciclo diurno, para todos los sitios evaluados de la Zona Metropolitana del Valle de México no cambiaron sustancialmente entre los tres años, además identifican una reducción en las concentraciones de  $CO$  (Peralta et al., 2020).

Finalmente para aspectos de este trabajo es importante mencionar el estudio realizado por (Carlos Ordóñez, 2020) en el que estudia el  $NO_2$  y  $O_3$  en Europa durante el periodo del 15 de marzo al 15 de abril del año 2020, encontrando que las medidas de aislamiento implementadas provocaron una reducción sustancial de las concentraciones de  $NO_2$  en Europa, mientras que el  $O_3$  disminuyó en la Península Ibérica y aumentó en el resto de Europa, una fracción considerable de estos cambios de  $O_3$  pueden explicarse por efectos meteorológicos, los cuales se estudian en este trabajo empleando un modelo aditivo generalizado, la importancia de su estudio esta en que los efectos meteorológicos puede complicar la atribución de los cambios en las concentraciones de contaminantes, como un efecto puramente debido a las emisiones.

Durante los primeros dos meses del año 2020, en México no se registró ningún caso de COVID-19, a este periodo se decidió nominar como fase 0, el 27 de febrero del 2020 se reportó el primer caso de COVID-19 dando inició la fase 1, el 24 de marzo se comenzaron a registrar casos de transmisiones locales, lo que originó que se estableciera la fase 2 (SSalud, 2020), para esta fase el gobierno comenzó a cancelar grandes eventos públicos, cerrar establecimientos comerciales y centros educativos, permitiendo solo que las industrias indispensables continuaran trabajando (Tabla 1.1).

El 21 de abril el país entró a la fase 3, debido a que se comenzaban a registrar un gran número de contagios y hospitalizaciones, por lo que el gobierno extendió y continuó con las medidas de aislamiento.

Fases	Fecha	Medidas
Fase 0	Enero 1- Febrero 27	Sin medias de seguridad sanitaria.
Fase 1	Febrero 28 - Marzo 23	Sin medias de seguridad sanitaria.
Fase 2	Marzo 24 - Abril 20	<ol style="list-style-type: none"> <li>1. Suspensión de actividades no esenciales en los sectores público, privado y social.</li> <li>2. Suspensión de eventos masivos.</li> <li>3. Suspensión de clases</li> <li>4. Resguardo domiciliario voluntario y estricta a toda persona mayor de 60 años, mujeres embarazadas o personas que padezcan enfermedades crónicas o autoinmunes.</li> </ol>
Fase 3	Abril 21 - Junio 1	<ol style="list-style-type: none"> <li>1. Cierre del 20% de estaciones de transporte público.</li> <li>2. Hoy No Circula Obligatorio.</li> <li>3. Quédate en casa y guarda sana distancia</li> </ol>

Tabla 1.1: Fases y medidas de seguridad sanitaria ante la pandemia por SARS-CoV-2 (GOB.MX, ) (CDMX, 2020).



El martes 17 de marzo de 2020, el transporte público de la Ciudad de México registró reducciones significativas en su afluencia respecto a su comportamiento típico y después de la Semana Santa y hasta el 31 de mayo de 2020, se reportaron reducciones en la afluencia de distintos medios de transporte público y el tránsito vehicular alcanzó mínimos históricos durante la Semana Santa con variaciones de -80% respecto a su comportamiento típico y hasta finales de mayo las variaciones diarias se mantuvieron alrededor de -70% comparado con el tránsito vehicular habitual (SEMOVI, 2021).

El objetivo de este trabajo es identificar si las reducciones en la afluencia de transporte debido a las medidas de aislamiento, tuvieron un impacto en las concentraciones de los contaminantes en la zona de Ciudad Universitaria, en la Ciudad de México. Para esto se empleará un modelo aditivo generalizado (GAM) y además en este modelo se intentará cuantificar el efecto de la meteorología en las concentraciones del año 2020, para finalmente comparar los resultados del modelo con las concentraciones observadas del año 2020 y el promedio de los años 2015-2019.

# Capítulo 2

## Marco Teórico

### 2.1. Contaminantes criterios

La atmósfera es una mezcla gaseosa, que se compone principalmente de 21 partes de oxígeno y 78 partes de nitrógeno. El resto lo componen vapor de agua, gases nobles y bióxido de carbono. Sin embargo, el aire puede ser alterado debido a la presencia de otros compuestos, que en determinadas proporciones pueden afectar a la salud de las personas que lo respiran. En este sentido definimos como contaminante del aire, al compuesto o compuestos que alteran la composición normal del aire (INE, 2016), mientras que la calidad del aire es resultado de una combinación de factores, que producen cambios en su composición y que puede variar de un momento a otro. Algunos de los contaminantes del aire, por sus efectos en la salud de la población, han sido normados, estableciendo límites máximos de concentración en el aire y son conocidos como contaminantes criterio. Estos contaminantes incluyen : el ozono ( $O_3$ ), el monóxido de carbono ( $CO$ ), el bióxido de azufre ( $SO_2$ ), el bióxido de nitrógeno ( $NO_2$ ), el plomo ( $Pb$ ), las partículas suspendidas totales ( $PST$ ), y las partículas suspendidas menores a 10 y a 2.5 micrómetros ( $PM_{10}$  y  $PM_{2.5}$ ) (INE, 2016). A continuación se presentan los contaminantes empleados en este trabajo.

### 2.1.1. Ozono

El ozono ( $O_3$ ) es un gas oxidante reactivo producido naturalmente en cantidades mínimas. El ozono troposférico es un contaminante secundario lo que indica que es formado en la atmósfera por los siguientes constituyentes primarios: Óxidos de Nitrógeno ( $NO_x = NO_2 + NO$ ), los compuestos orgánicos volátiles ( $VOC_s$ ) y el Monóxido de Carbono (CO) los cuales a través de un mecanismo fotoquímico generan el  $O_3$  troposférico (Sillman, 1999); (Monks et al., 2015).

Debido a que el ozono depende de reacciones fotoquímicas, las concentraciones más altas tienden a observarse durante los períodos de primavera y verano, con concentraciones mínimas generalmente en otoño (Monks, 2000).

Los efectos adversos en la salud asociados con los niveles de ozono en el aire ambiente incluyen aumento de los síntomas respiratorios, daño a las células del tracto respiratorio, disminución de la función pulmonar, mayor susceptibilidad a la infección respiratoria, aumento en los riesgos de hospitalización y mortalidad (SEDEMA, 2017).

### 2.1.2. Óxidos de Nitrógeno

La gran mayoría de  $NO_x$  ( $NO_2 + NO$ ) emitidos a la atmósfera provienen de la quema de combustibles fósiles, quema de biomasa, suelos y rayos (Seinfeld and Pandis, 2006). Las fuentes de  $NO_x$  incluyen vehículos (gasolina y diésel), aviones, transporte marítimo, calderas industriales y calefacción doméstica. Las proporciones de mezcla atmosférica de  $NO_x$  tienden a oscilar entre <1 ppb (partes por billón), en lugares remotos marinos o forestales, hasta <10 ppb en lugares rurales y entre 10 y 1000 ppb en áreas urbanas. El  $NO_x$  es emitido por los procesos de combustión y presenta la siguiente composición  $NO$  (95 %) y solo una pequeña cantidad de  $NO_2$  primario. Sin embargo, una vez en la atmósfera, el  $NO_2$  se forma a partir de la oxidación del  $NO$ :  $O_3 + NO \rightarrow NO_2 + O_2$  (Von Schneidmesser et al., 2015).

Las emisiones de dióxido de Nitrógeno tiene efectos adversos a la salud, contribuyendo a problemas respiratorios tales como la disminución de la función pulmonar, asma, el aumento en la respuesta de las vías respiratorias y la inflamación pulmonar (EPA.U.S., 2016)

### 2.1.3. Monóxido de Carbono ( $CO$ )

La principal fuente de emisiones de monóxido de carbono a la atmósfera es la combustión, ya sea por fuentes naturales o antropogénicas. El transporte y la quema de biomasa son los mayores contribuyentes a las emisiones antropogénicas de  $CO$  (Godish, 2004).

Las fuentes móviles contribuyen con más del 95 % de las emisiones de  $CO$ . La presencia de este contaminante es indicador de emisiones vehiculares y por lo tanto, de los compuestos asociados a humos de escape como hidrocarburos, óxidos de nitrógeno, carbono negro, etc. El comportamiento temporal y espacial de las concentraciones de este contaminante está relacionado directamente con la dinámica del tránsito vehicular en la ciudad y la meteorología. Las zonas con mayor tránsito vehicular o con congestiones vehiculares frecuentes, son las que generalmente reportan los mayores niveles del contaminante (SEDEMA, 2017). Además se observa que la concentración máxima ocurre durante la primavera local y la mínima se encuentra a fines del verano o principios del otoño (Seinfeld and Pandis, 2006).

El monóxido de carbono es responsable de los efectos tóxicos asociados a la reducción en el suministro de oxígeno en el torrente sanguíneo. Se sabe que las personas con insuficiencia en el suministro de sangre al corazón (cardiopatía isquémica) son particularmente susceptibles a los efectos del monóxido de carbono (EPA.U.S, 2010).

#### 2.1.4. Material Particulado ( $PM$ )

El material particulado se clasifica utilizando los conceptos de  $PM_{10}$ ,  $PM_{2.5}$  que representan concentraciones de masa de partículas de aerosol con diámetros aerodinámicos de menos de 10 o 2.5 micras respectivamente (Von Schneidmesser et al., 2015). El material particulado procede de fuentes naturales, como el polvo transportado por el viento, y de actividades antropogénicas, como la combustión de combustibles fósiles. El material particulado puede ser emitido directamente como partículas (primario) o formados en la atmósfera (secundario) (Seinfeld and Pandis, 2006). Su vida media en la atmósfera va de días a semanas y por lo tanto sus efectos son en escala local y regional.

Existen pruebas que apoyan la relación entre la exposición a partículas finas ( $PM_{2.5}$ ) con los efectos cardiovasculares y respiratorios, así como el desarrollo y exacerbación del asma o alergia, cáncer de pulmón, impactos en la función pulmonar, inflamación pulmonar, estrés oxidativo y la hiperreactividad de las vías respiratorias. Tanto la exposición de corto como la de largo plazo están relacionadas con efectos en la salud humana (SEDEMA, 2017).

## 2.2. Meteorología

La concentración de contaminantes en el aire y sus impactos están determinados no solo por las tasas de emisiones, sino también por la eficiencia de sus sumideros químicos y físicos, por ejemplo; las transformaciones químicas, así como la deposición húmeda y seca a la superficie de la tierra. En gran medida, estos procesos se ven afectados por factores meteorológicos como la temperatura, la intensidad de la radiación solar y la presencia de inversiones de temperatura, así como de nubes y nieblas (Finlayson-Pitts, 2000).

## Temperatura

La temperatura es una de las magnitudes más utilizadas para describir el estado de la atmósfera, es una magnitud relacionada con la rapidez del movimiento de las partículas que constituyen la materia. (Jiménez et al., 2004).

La temperatura favorece la formación de  $O_3$  y otros contaminantes secundarios, y afecta el transporte de los contaminantes del aire (Yoshikado and Tsuchida, 1996);(Jazcilevich et al., 2002).

## Radiación

La radiación es la transferencia de calor por ondas electromagnéticas como la luz visible, el infrarrojo y la radiación ultravioleta (Hugh and Freedman, 2009). La Tierra emite la mayor parte de su radiación en longitudes de onda más largas (5 y 25  $\mu\text{m}$ ) y a menudo se denomina radiación de onda larga, mientras que el Sol emite la mayor parte de su radiación en longitudes de onda inferiores (menor a 2  $\mu\text{m}$ ) y se conoce como radiación de onda corta (Ahrens and Henson, 2018). Los datos de radiación empleados en este trabajo son los que provienen del sol.

La interacción entre la radiación solar y la contaminación atmosférica es recíproca: la radiación solar influye en los contaminantes del aire y los contaminantes influyen en la radiación solar. Por ejemplo, las partículas en suspensión y los contaminantes gaseosos disminuyen la cantidad de radiación solar que llega a la superficie de la Tierra. Por el contrario, la radiación ultravioleta (UV) es necesaria para iniciar una serie de reacciones que provocan altos valores de ozono urbano (Peterson and Flowers, 1977).

## Humedad Relativa

La humedad relativa (RH) es la relación entre la cantidad de vapor de agua en el

aire y la cantidad máxima de vapor de agua requerida para la saturación a cierta temperatura y presión (Ecuación 2.1). Se expresa como porcentaje (Ahrens and Henson, 2018).

$$RH = \frac{\textit{Presión de vapor}}{\textit{presión de vapor de saturación}} * 100 \quad (2.1)$$

En términos de la contaminación atmosférica la humedad desempeña un papel importante en los procesos de formación de los contaminantes secundarios, las interacciones gas-partícula, la visibilidad y las características termodinámicas de la atmósfera (SEDEMA, 2017).

### Capa límite

La troposfera se extiende desde el suelo hasta una altitud promedio de 11 km, pero a menudo solo los dos kilómetros más bajos son afectados directamente por la superficie subyacente. Podemos definir la capa límite como la parte de la troposfera que está directamente influenciada por la presencia de la superficie terrestre y que responde a los forzamientos superficiales. Estos forzamientos incluyen arrastre por fricción, evaporación y transpiración, transferencia de calor, emisión de contaminantes y modificación del flujo inducida por el terreno. El grosor de la capa límite es bastante variable en el tiempo y el espacio (Stull, 1988).

La mayoría de las fuentes contaminantes se encuentran cerca de la superficie terrestre, por lo tanto, las concentraciones de estos pueden acumularse en la capa límite. En ocasiones puede existir una capa de inversión, es decir una capa estable debido a que la temperatura aumenta con la altitud, capturando contaminantes y acumulándolos por debajo de esta (Stull, 1988).

### Velocidad del Viento

El viento consiste en el movimiento de aire, normalmente se origina cuando entre

dos puntos se establece una cierta diferencia de presión o de temperatura. En el primer caso, cuando entre dos zonas la presión del aire es distinta, éste tiende a moverse desde la zona de alta presión a la zona de baja presión (Jiménez et al., 2004). En presencia de viento fuerte existe una mejor dispersión de la contaminación (independientemente de la dirección) y contrariamente, el viento débil propicia la acumulación de los contaminantes al limitar su dispersión, situación que se puede agravar en presencia de una altura baja de la capa límite y/o por la presencia de radiación solar intensa (SEDEMA, 2018).

### **Presión**

La presión atmosférica puede considerarse como el peso horizontal de la atmósfera por unidad de área horizontal. La unidad meteorológica convencional es el milibar (mb) el cual es equivalente a 100 Pa (Pascuales) (Montes de Oca et al., 2010). En un día despejado y seco la presión atmosférica es mayor en comparación con un día húmedo o lluvioso (SEDEMA, 2018).

En la atmósfera, existe una relación directa entre presión y viento (Jiménez et al., 2004). Durante los días en los que la presión es alta y la velocidad de viento es débil las condiciones son favorables para el estancamiento de la contaminación, debido a la escasa dispersión vertical y horizontal (SEDEMA, 2018).

### **Precipitación acumulada**

La precipitación acumulada es la cantidad de agua que cae a la superficie terrestre. Esto incluye básicamente: lluvia, nieve y granizo.

El instrumento que se suele utilizar para medir la precipitación se denomina pluviómetro. La precipitación se reporta en milímetros (mm) de lluvia que equivale a la altura de la lámina que alcanzaría el volumen acumulado en un área de 1 metro cuadrado ( $m^2$ ). Un mm de lluvia equivale a aproximadamente a un litro de agua por metro cuadrado (1 L/m<sup>2</sup>) (SEDEMA, 2017). Por lo tanto la precipitación acumulada



es la suma de la lluvia registrada sobre un periodo de tiempo (generalmente 24 horas).

## 2.3. Modelo Aditivo Generalizado

En las últimas décadas los avances en los análisis estadísticos de los modelos lineales ha generado una mayor capacidad de estudio en áreas ambientales.

Los Modelos lineales generales surgen en el siglo XX y se basan en emplear variables de respuesta continua y una o varias variables independientes (Bandera and Pérez, 2018). La generalización matemática de las regresiones múltiples puede transformarse como modelos lineales generales, en particular, el método de ajuste lineal de mínimos cuadrados el cual se usa para predecir una variable  $Y$  dependiente para un conjunto de predictores o variables  $X$  en regresión lineal (Ec. 2.2) (Ravindra et al., 2019).

$$Y = b_0 + b_1X_1 + \dots + b_mX_m \quad (2.2)$$

Donde  $Y$  es la variable dependiente (variable de respuesta);  $X_1 \dots X_m$  representan los valores  $m$  (variables independientes) para la variable predictora, y  $b_0 \dots b_m$  se estiman mediante regresión múltiple y se denominan coeficientes de regresión.

Sin embargo el uso del modelo lineal general se limita cuando la distribución de las variables no son normales, además falla cuando los efectos no son lineales (Fig.2.1).

Posteriormente se desarrollaron los modelos lineales generalizados (GLM), lo cuales son una expansión de los modelos lineales generales (Ravindra et al., 2019), el modelo lineal generalizado, a diferencia de los lineales generales, permite que la variable de respuesta puede seguir cualquier distribución de la familia exponencial (Fig.2.1). En los modelos lineales generales, el valor de las variables dependientes sigue la distribución asintótica y la función de identidad respectiva es la función de enlace, por lo que otra diferencia es la "asociación" de la variable dependiente con las variables

independientes, a través de esta función de enlace (Ec. 2.3)(Ravindra et al., 2019).

$$\begin{aligned} Y &= g(b_0 + b_1X_1 + \dots + b_mX_m) \\ gi(\mu Y) &= g(b_0 + b_1X_1 + \dots + b_mX_m) \end{aligned} \quad (2.3)$$

Donde  $g(\dots)$  es una función y de acuerdo con la teoría, la función inversa de  $g(\dots)$ , es decir,  $gi(\dots)$ , se conoce como función de enlace (Ravindra et al., 2019).

Sin embargo, para muchas aplicaciones, los modelos lineales generales y generalizados son demasiado restrictivos, porque las relaciones entre las variables independientes son muy complejas para representarlas como funciones lineales (Carslaw et al., 2007). En estas situaciones, los modelos aditivos generalizados (GAM por sus siglas en inglés), ofrecen muchas ventajas para modelar estas relaciones complejas, así los coeficientes de regresión se reemplazan por funciones suaves (*smooth functions*)

El propósito de los modelos aditivos generalizados es maximizar la calidad de predicción de una variable dependiente de varias distribuciones (Fig. 2.1), mediante la estimación de funciones no paramétricas de las variables predictoras que están "conectadas" a la variable dependiente a través de una función de enlace, en la ecuación 2.4 se observa el modelo expresado en forma general (Hastie and Tibshirani, 1990).

$$C_i = \sum_{j=1}^n \beta_j(x_{ij}) + \epsilon_i \quad (2.4)$$

Donde  $C_i$  representa la concentración en un periodo,  $\beta_j$  las funciones suavizadas que vinculan las variables independientes,  $x_{ij}$  el valor de las variables independiente  $j$  al periodo  $i$  y finalmente el término de error  $\epsilon_i$  que contiene a los residuales.

Algunas de las aplicaciones más populares de estos modelos son los estudios de contaminación del aire, donde existen muchas relaciones no lineales entre variables (Carslaw et al., 2007). Tal es el caso del efecto de la contaminación del aire sobre la mortalidad, donde (Katsouyanni et al., 2001) utilizó GAM para estimar los efectos

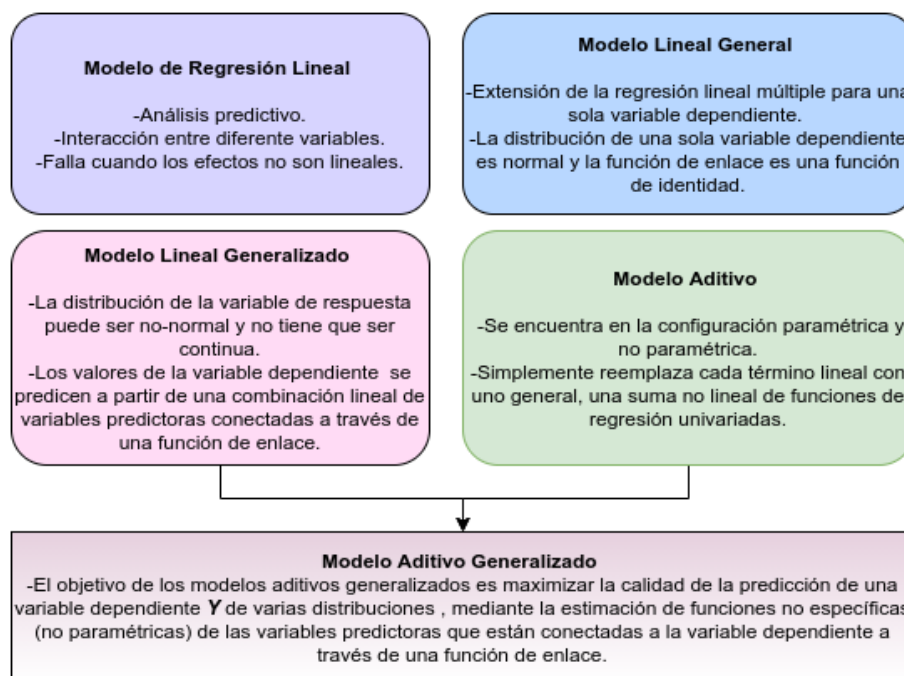


Figura 2.1: Modelos de regresión y su vinculación (Ravindra et al., 2019)

de  $PM_{10}$ ,  $NO_2$  y  $CO$  en las tasas de mortalidad.

Un modelo aditivo generalizado proporciona resultados de los modelos de regresión lineal general y regresión no lineal, lo que incluye diagramas de residuales, valores predichos, así como los residuales para el modelo ajustado, estos diagramas ayudan a comprender mejor el modelo (Ravindra et al., 2019).

## 2.4. Tendencias

Las tendencias a largo plazo de la calidad del aire han sido un tema muy estudiado en los últimos años. Más específicamente, se ha estudiado en detalle el papel de las variaciones interanuales en la meteorología frente al efecto de los cambios en las emisiones antropogénicas para las tendencias. En la literatura científica GAM es uno de los métodos propuesto para aislar estos dos efectos sobre las tendencias a largo plazo de los contaminantes del aire (Solberg et al., 2018a).

Al observar un período de tiempo de varios años, los contaminantes generan una

tendencia que no está influenciada por perturbaciones meteorológicas, lo que permite conocer si los cambios observados en las concentraciones es debido a un aumento o disminución de emisiones o precursores (Solberg et al., 2018b).

# Capítulo 3

## Metodología

### 3.1. Área de estudio

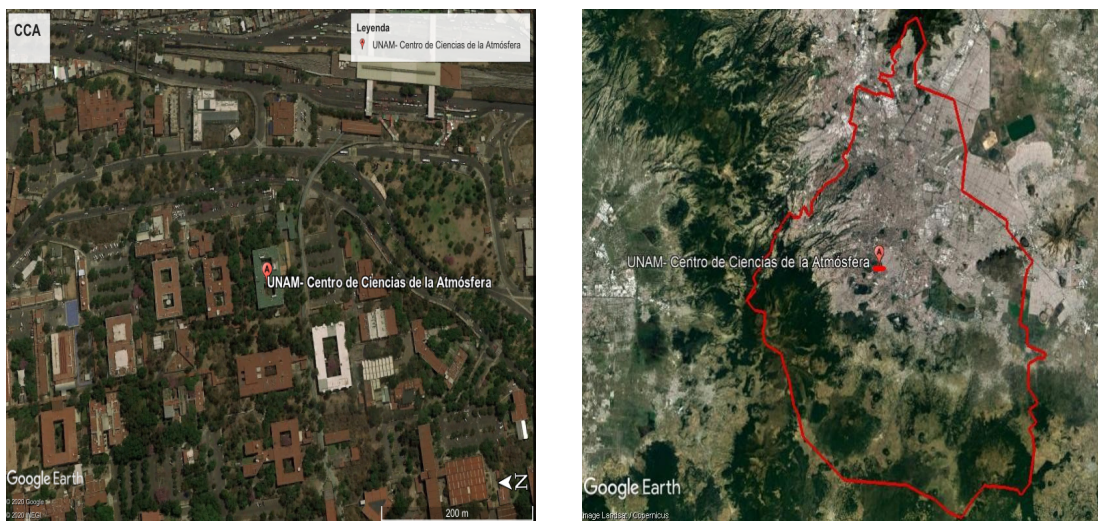


Figura 3.1: Estación Centro de Ciencias de la Atmósfera (Google-Earth, SF).

La Ciudad de México (CDMX) está integrada por 16 alcaldías; abarca una superficie total de casi  $1,494.3 \text{ km}^2$  y tiene una población de 9,209,944 habitantes (INEGI, 2021), forma parte de la Zona Metropolitana del Valle de México (ZMVM) en donde aproximadamente once millones de personas se desplazan todos los días entre semana para ir a trabajar o a estudiar (Silva et al., 2018).

Para este trabajo se tomaron datos meteorológicos y de contaminantes criterio de la estación de monitoreo atmosférico "CCA" (SEDEMA, 2021a) que pertenece a la

secretaría de monitoreo atmosférico (SEDEMA) ubicada en el Centro de Ciencias de la Atmósfera en la Universidad Nacional Autónoma de México (latitud 19.3262 y longitud -99.1761), alcaldía Coyoacán (Fig. 3.1).

Esta estación se encuentra al sur de la Ciudad de México, rodeado por una zona residencial con una alta actividad vehicular y sin actividades industriales cercanas (Peralta et al., 2019).

## 3.2. Filtrado y control de calidad

Los datos de contaminantes criterios fueron obtenidos de la Red Automática de Monitoreo Atmosférico (RAMA) de la Ciudad de México (SEDEMA, 2021a), mientras que los datos meteorológicos de la Red Universitaria de Observatorios Atmosféricos (RUOA) (RUOA, 2021). En la tabla 3.1 se observan los datos disponibles y el periodo de tiempo de estos. Se realizó la limpieza de los datos tanto meteorológicos como los de contaminantes criterio, eliminando aquellos valores mayores a tres desviaciones estándar de la media (Miller, 1991).

Estación	Periodo	Calidad del aire	Meteorología
Centro Ciencias de la atmósfera (CCA)	2015-2020	Ozono $PM_{2.5}$ $CO$ $NO_2$ $NO$	Temperatura Radiación Humedad Relativa Precipitación Velocidad del viento Presión Capa límite

Tabla 3.1: Datos disponible de calidad del aire y meteorología.

Hubo dos casos especiales para las  $PM_{2.5}$ , identificados cuando se realizaron los gráficos de los ciclos anuales, estos casos corresponden al 1 de Enero y al 25 de Diciembre, en donde los valores fueron muy altos comparados con días previos y posteriores, esto puede ser debido a la actividad humana, como la quema de pirotecnia, ya que son fechas festivas. Estos valores correspondientes a los años 2015-2019 no cambiaron incluso después de la limpieza, por lo que se decidió eliminarlos, ya que

generan problemas en el modelo, afectando a las predicciones de los días posteriores.

### 3.3. Diagramas del flujo del programa

El trabajo fue llevado a cabo utilizando los lenguajes de programación Python y R. Con Python se escribió un programa que realiza la lectura de los datos y la limpieza de estos. Se utilizó la paquetería "Pandas" con la cual, se generaron los promedios de los datos meteorológicos así como de los contaminantes además del el MDA8 del  $O_3$ , para ser finalmente exportadas en un mismo archivo, este proceso se observa en el diagrama 3.2.

En R fue ajustado el modelo GAM utilizando la librería "mgcv" (Wood, 2017), este fue empleado para cada contaminante y utilizamos los parámetros meteorológicos como variables independientes de entrada para predecir los niveles diarios del contaminante, estas variables se aprecian en la tabla 3.2, la ecuación matemática esta dada por la Ec. 3.1 (Solberg et al., 2018b) .

$$C_i = \beta_0 + \beta_1(x_{i,1}) + \beta_2(x_{i,2}) + \dots + \beta_9(x_{i,9}) + \beta_{10}(x_{i,10}) + \epsilon_i \quad (3.1)$$

Donde  $C_i$  representan las concentraciones de un contaminante;  $x$  es la variable explicativa (cada uno de los parámetros de la tabla 3.2) en el día  $i$ ;  $\beta$  son las funciones de respuesta suavizadas que vinculan las variables explicativas; Finalmente  $\epsilon_i$  que representa el término de error que contiene los residuales.

Es importante mencionar que las variables  $x_9$  y  $x_{10}$  (tabla 3.2) son variables explicativas que no representan ningún parámetro meteorológico. El término  $\beta_{10}(x_{i,10})$  en la ecuación expresa la tendencia lineal a largo plazo en los valores de las concentraciones corregidos por las variaciones interanuales de la meteorología en cada sitio. El coeficiente  $\beta_{10}$  es un valor constante, que representa la pendiente en esta tendencia. La parte  $\beta_0 + \beta_{10}(x_{i,10})$  en el lado derecho de la ecuación es entonces idéntico a una regresión lineal estándar con intersección  $\beta_0$  y pendiente  $\beta_7$  y donde ambos son coefi-

cientes constantes (Solberg et al., 2018b).

X	Variable	Función
$x_1$	Promedio diario de Radiación	<i>Smooth</i>
$x_2$	Promedio diario de Temperatura	<i>Smooth</i>
$x_3$	Máximo diario de Temperatura	<i>Smooth</i>
$x_4$	Promedio diario de Humedad Relativa	<i>Smooth</i>
$x_5$	Promedio diario de Velocidad del Viento	<i>Smooth</i>
$x_6$	Promedio diario de la altura de Capa Límite	<i>Smooth</i>
$x_7$	Promedio diario de Presión	<i>Smooth</i>
$x_8$	Precipitación Acumulada diaria	<i>Smooth</i>
$x_9$	Día del año	<i>Smooth</i>
$x_{10}$	Tiempo continuo en fracción de años	Lineal

Tabla 3.2: Lista de las variables empleadas para el modelo

Teniendo definidas las variables explicativas y las funciones suavizadas a utilizar, se corrió el modelo para los años previos al 2020, es decir del 2015 al 2019 donde se obtuvieron los coeficientes  $\beta$ . Posteriormente utilizando la librería "openair" (Carslaw, 2015) se obtuvieron métricas estadísticas para llevar a cabo la evaluación del modelo, las métricas empleadas fueron:

- \* El error cuadrático medio (RMSE *Root mean squared error*) que proporciona un valor de cuán cerca están los valores predichos de los valores observados.
- \* Índice de ajuste (IOA *Index of Agreement*) que va de -1 a 1, en donde los valores más cercanos a 1 indican un mejor rendimiento del modelo.
- \* R cuadrado ajustado (R-sq(adj)), el cual aumenta cuando un nuevo término mejora el modelo.
- \* Coeficiente de correlación, con este valor podemos conocer si es buena la relación lineal entre dos variables. Si existe una relación lineal perfecta con pendiente positiva entre las dos variables,  $r = 1$ .

En R también se obtuvo la estimación de las tendencias de los valores resultantes del modelo y los valores de los coeficientes  $\beta$ . Posteriormente con estos coeficiente  $\beta$  se predijeron las concentraciones para el año 2020, este proceso se observa en el diagrama 3.3.



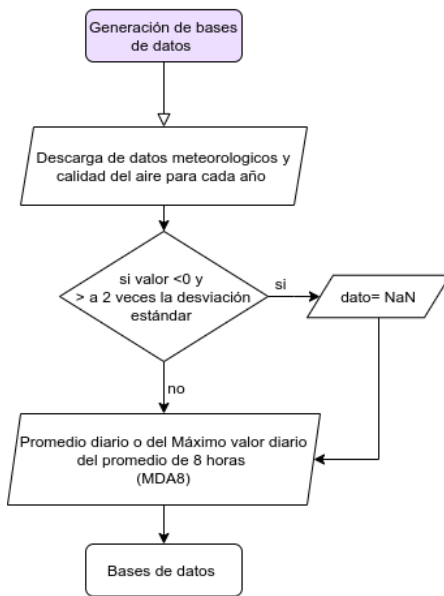


Figura 3.2: Diagrama de flujo del programa que permite generar las bases de datos.

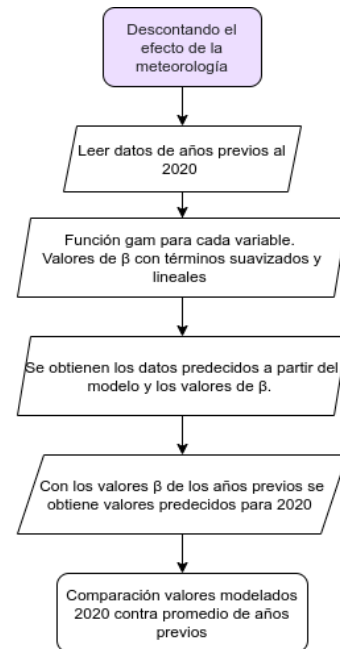


Figura 3.3: Diagrama del flujo para el modelo GAM.

Finalmente en Python se realizaron los gráficos para la evaluación de las concentraciones del 2020 ajustadas meteorológicamente contra el promedio de los años 2015-2019, y se compararon 4 periodos diferentes que corresponden a los meses antes del primer caso de COVID-19 en México que para efectos de este trabajo denominamos Fase 0, seguido de las 3 fases indicadas por el gobierno federal: Fase 1 ( Febrero 28- Marzo 23 ), Fase 2 (Marzo 24-Abril 20) y Fase 3 (Abril 21 - Junio 1), por dos razones se decidió no estudiar el resto del año, la primera fue la implementación de un semáforo epidemiológico que va permitiendo de acuerdo a su color la apertura de ciertas actividades y la segunda por la falta de datos meteorológicos durante los últimos meses del año, especialmente de la capa límite lo que impide tener resultados del modelo para este periodo.

# Capítulo 4

## Resultados

### 4.1. Selección de modelo

Se estudiaron diferentes modelos para cada contaminante, con la finalidad de seleccionar uno que proporcionara los mejores resultados, es decir una predicción de concentraciones muy parecida a lo observado.

Para el  $O_3$  se estudiaron 5 modelos diferentes (Tabla 4.1), los cuales incluyen las variables de la tabla 3.2, el uso de estas variables está basado en estudios previos (Solberg et al., 2018b) (Solberg et al., 2018a). El término  $x_{10}$  (Tabla 3.2) representa la tendencia lineal a largo plazo en los valores de las concentraciones, corregidos por las variaciones interanuales de la meteorología en cada sitio.

Se encontró que hay dos modelos que mejor representan a este contaminante, el primero es el modelo "D", este modelo emplea el promedio diario de  $O_3$  y al comparar los valores de R cuadrado ajustado (R-sq por sus siglas en inglés *adjusted R-squared*) así como el IOA (*Index of Agreement*) con los resultados de los demás modelos, estos valores son mayores, lo que indica que las variables empleadas ayudan a generar mejores resultados. El otro modelo seleccionado es el modelo "E", que utiliza el valor máximo del promedio de 8 horas (MDA8 por sus siglas en inglés *Mean values of the daily maximum 8 hour average*) y muestra resultados similares al modelo "D".

Modelo	Variables	Tendencia	Estadística
A. Promedio diario de $O_3$	$x_1, x_2, x_4$ $x_5, x_9, x_{10}$	m= -0.49	R-sq.(adj) = 0.528 RMSE=7.72 r=0.73 IOA= 0.54
B. Promedio diario de $O_3$	$x_1, x_3, x_4$ $x_5, x_9, x_{10}$	m=-0.21	R-sq.(adj) = 0.54 RMSE=7.72 r=0.74 IOA= 0.56
C. Promedio diario de $O_3$	$x_1, x_3, x_4$ $x_5, x_6, x_9, x_{10}$	m= -0.33	R-sq.(adj) = 0.54 RMSE=7.65 r=0.74 IOA= 0.56
<b>D. Promedio diario de <math>O_3</math></b>	$x_1, x_3, x_4, x_5, x_6$ $x_7, x_8, x_9, x_{10}$	m= -0.31	R-sq.(adj) = 0.55 RMSE=7.57 r=0.75 IOA= 0.57
<b>E. MDA8 de <math>O_3</math></b>	$x_1, x_3, x_4, x_5, x_6$ $x_7, x_8, x_9, x_{10}$	m= -2.25	R-sq.(adj) = 0.54 RMSE=14.33 r=0.75 IOA= 0.57

Tabla 4.1: Variables empleadas en cada modelo, así como estadística descriptiva para  $O_3$ .

Para el  $CO$ , se realizaron 5 modelos (Tabla 4.2), los cuales incluyen también algunas variables de la tabla 3.2. Se encontró que el modelo "E" es el que mejor resultados otorga. De las variables empleadas en el modelo "E", la introducción de la altura de Capa límite favorece los resultados del modelo, lo cual se comprueba con los indicadores de R-sq(adj) así como el valor de IOA.

Es importante mencionar que no se utiliza la precipitación en el modelo seleccionado, ya que se reduce a un simple efecto lineal, esto provoca que los resultados sean idénticos con o sin esa variable.

Modelo	Variables	Tendencia	Estadística
A. Promedio diario de $CO$	$x_1, x_2, x_4, x_5$ $x_9, x_{10}$	m= -0.102	R-sq.(adj) = 0.647 RMSE=0.14 r=0.81 IOA= 0.66
B. Promedio diario de $CO$	$x_1, x_3, x_4$ $x_5, x_9, x_{10}$	m=-0.099	R-sq.(adj) = 0.648 RMSE=0.14 r=0.81 IOA= 0.66
C. Promedio diario de $CO$	$x_1, x_2, x_4$ $x_5, x_6, x_9, x_{10}$	m= -0.098	R-sq.(adj) = 0.66 RMSE=0.14 r=0.82 IOA= 0.67
D. Promedio diario de $CO$	$x_1, x_2, x_4$ $x_5, x_6, x_7$ $x_8, x_9, x_{10}$	m= -0.098	R-sq.(adj) = 0.66 RMSE=0.14 r=0.82 IOA= 0.68
<b>E. Promedio diario de <math>CO</math></b>	$x_1, x_2, x_4$ $x_5, x_6, x_7, x_9$ $x_{10},$	m= -0.098	R-sq.(adj) = 0.66 RMSE=0.14 r=0.82 IOA= 0.68

Tabla 4.2: Variables empleadas en cada modelo, así como estadística descriptiva para  $CO$ .

Para el  $NO$ , se realizaron 5 modelos (Tabla 4.3), con las variables de la tabla 3.2. Para este contaminante se encontró que el modelo que mejor representa es el "D". De las variables empleadas la capa límite genera una mejoría en el modelo, esto se observa en el R-sq(adj), y puede deberse a la influencia que tiene para la acumulación del contaminante. Al igual que con el  $CO$  se identifica que la precipitación no otorga cambios en el modelo, por lo que se decidió no utilizarla.

Para el  $NO_2$  se siguió el mismo procedimiento que con los contaminantes previos, los modelos estudiados se observan en la tabla 4.4. Se encontró que los modelos "E" (promedio diario de  $NO_2$ ) y "F" (valor máximo diario) son los que mejores resultados generan. En ambos modelos se utilizan las mismas variables independientes, siendo el modelo "F" ligeramente mejor que el "modelo E" sin embargo se decidió utilizar ambos modelos, basándonos en la metodología de Ordoñez (2020), en este mismo

estudio también indica que el uso del valor máximo diario de el  $NO_2$  y el MDA8 de  $O_3$  está basado en estándares establecidos por la Unión Europea.

Finalmente el contaminante  $PM_{2.5}$ , utilizando el mismo procedimiento empleado previamente, de los cinco modelos estudiados (Tabla 4.5) hay dos que tienen los mejores resultados modelos "D" y "E", estos dos modelos arrojaron los mismos resultados, la diferencia entre ambos es la precipitación acumulada y se decidió emplear el modelo E, el cual emplea esta variable.

Modelo	VARIABLES	Tendencia	Estadística
A. Promedio diario de $NO$	$x_1, x_2, x_4$ $x_5, x_9, x_{10}$	m= -1.87	R-sq.(adj) =0.41 RMSE= 6.03 r= 0.65 IOA=0.45
B. Promedio diario de $NO$	$x_1, x_3, x_4$ $x_5, x_9, x_{10}$	m=-1.82	R-sq.(adj) = 0.41 RMSE=6.0 r=0.65 IOA= 0.45
C. Promedio diario de $NO$	$x_1, x_2, x_4$ $x_5, x_6, x_9, x_{10}$	m= -1.80	R-sq.(adj) = 0.44 RMSE=5.96 r=0.67 IOA=0.49
<b>D. Promedio diario de <math>NO</math></b>	$x_1, x_2, x_4$ $x_5, x_6, x_7$ $x_9, x_{10}$	m= -1.8	R-sq.(adj) = 0.45 RMSE=5.91 r=0.68 IOA= 0.5
E. Promedio diario de $NO$	$x_1, x_2, x_4$ $x_5, x_6, x_7$ $x_8, x_9, x_{10}$	m= -1.76	R-sq.(adj) = 0.45 RMSE=5.91 r=0.68 IOA= 0.5

Tabla 4.3: Variables empleadas en cada modelo, así como estadística descriptiva para  $NO$ .

Modelo	VARIABLES	Tendencia	Estadística
A. Promedio diario $NO_2$	$x_1, x_2, x_4$ $x_5, x_9, x_{10}$	m=-1.17	R-sq.(adj) =0.55 RMSE=4.78 r= 0.75 IOA=0.57
B. Promedio diario $NO_2$	$x_1, x_3, x_4$ $x_5, x_9, x_{10}$	m=-1.23	R-sq.(adj) = 0.53 RMSE=4.87 r= 0.73 IOA= 0.56
C. Promedio diario $NO_2$	$x_1, x_2, x_4$ $x_5, x_6, x_9, x_{10}$	m=-1.26	R-sq.(adj) = 0.56 RMSE=4.81 r=0.75 IOA=0.58
D. Promedio diario $NO_2$	$x_1, x_2, x_4$ $x_5, x_6, x_7$ $x_8, x_9, x_{10}$	m=-1.23	R-sq.(adj) = 0.56 RMSE=4.75 r=0.76 IOA= 0.59
<b>E. Promedio diario <math>NO_2</math></b>	$x_1, x_2, x_4$ $x_5, x_6, x_7$ $x_9, x_{10}$	m= -1.22	R-sq.(adj) = 0.56 RMSE=4.76 r=0.76 IOA= 0.59
<b>F. Máximo diario <math>NO_2</math></b>	$x_1, x_2, x_4$ $x_5, x_6, x_7$ $x_9, x_{10}$	m=-2.6727	R-sq.(adj) = 0.474 RMSE= 20.31 r=-0.73 IOA= -0.17

Tabla 4.4: Variables empleadas en cada modelo, así como estadística descriptiva para  $NO_2$ .

Modelo	VARIABLES	Tendencia	Estadística
A. Promedio diario $PM_{2.5}$	$x_1, x_2, x_4$ $x_5, x_9, x_{10}$	m=0.86	R-sq.(adj) = 0.45 RMSE=5.81 r= 0.68 IOA=0.5
B. Promedio diario $PM_{2.5}$	$x_1, x_3, x_4$ $x_5, x_9, x_{10}$	m=0.87	R-sq.(adj) = 0.432 RMSE=5.90 r= 0.67 IOA= 0.49
C. Promedio diario $PM_{2.5}$	$x_1, x_2, x_4$ $x_5, x_6$ $x_9, x_{10}$	m=0.67	R-sq.(adj) = 0.42 RMSE=5.92 r=0.66 IOA=0.47
D. Promedio diario $PM_{2.5}$	$x_1, x_2, x_4$ $x_5, x_6, x_7$ $x_9, x_{10}$	m=0.87	R-sq.(adj) = 0.46 RMSE=5.77 r=0.69 IOA= 0.51
<b>E. Promedio diario <math>PM_{2.5}</math></b>	$x_1, x_2, x_4$ $x_5, x_6, x_7$ $x_8, x_9, x_{10}$	m= 0.86	R-sq.(adj) = 0.46 RMSE= 5.77 r=0.69 IOA= 0.51

Tabla 4.5: Variables empleadas en cada modelo, así como estadística descriptiva para  $PM_{2.5}$ .

## 4.2. Antecedentes del comportamiento de los contaminantes y meteorología

En la figura 4.1 se observan las concentraciones de  $O_3$  para el periodo 2015-2019, el gráfico 4.1b presenta el ciclo anual a partir del MDA8 para  $O_3$ , y toda la serie de tiempo para cada año se observa en el gráfico 4.1a, en ambos gráficos se identifica entre los meses de abril y junio las concentraciones más altas, recordando que es un contaminante secundario y dependiente de la fotoquímica, es de esperarse que durante estos meses (los cuales presentan la mayor cantidad de radiación solar) se observen estas concentraciones. El mismo comportamiento se identifica con los promedios diarios para cada año, así como para el ciclo anual del periodo 2015-2019 (Fig.4.2).

Para el  $CO$  la serie de tiempo muestra una disminución en las concentraciones con el transcurrir de los años (Fig 4.3a), en cuanto al ciclo anual se identifican los meses de inicio y fin de año (invierno) como aquellos con las concentraciones más altas (Fig 4.3b), esto puede deberse principalmente a las condiciones de estabilidad atmosférica asociadas a las inversiones térmicas de superficie, la disminución de la altura de la capa de mezclado y vientos débiles (SEDEMA, 2017).

Para el  $PM_{2.5}$ , el ciclo anual (Fig. 4.4b) y la serie del tiempo con el promedio diario (Fig. 4.4a), muestran que los meses de diciembre, abril y mayo tienen las concentraciones más altas. Durante diciembre las condiciones de estabilidad atmosférica y la disminución de la altura de la capa límite favorecen las altas concentraciones de partículas (SEDEMA, 2018), mientras que durante los meses más calientes de la temporada seca, el incremento en la concentración de partículas suele producirse por una mayor actividad fotoquímica en la atmósfera, que contribuye a una mayor producción de aerosoles secundarios (SEDEMA, 2018).

La serie de tiempo (Fig. 4.5a) y el ciclo anual (Fig. 4.5b) del periodo de 2015-2019 del  $NO$ , muestra las concentraciones más altas a finales y principios de año, estas altas

concentraciones en temporada seca y fría, suelen ser ocasionadas por las condiciones de estabilidad atmosférica, la disminución en la altura de la capa límite y un aumento en la frecuencia e intensidad de las inversiones térmicas (SEDEMA, 2018). Durante los meses de la temporada de lluvia, se observan las concentraciones más bajas.

Finalmente el  $NO_2$  (Fig. 4.6) muestra un comportamiento muy similar al  $NO$ , con concentraciones menores en los meses de la temporada de lluvia y mayores en los meses de la temporada seca-fría, y difiere con el  $NO_2$  únicamente en los valores de las concentraciones registradas.




Figura 4.1: a) MDA8 para la estación CCA del 2015 al 2019, b) Ciclo anual del MDA8 del 2015-2019.



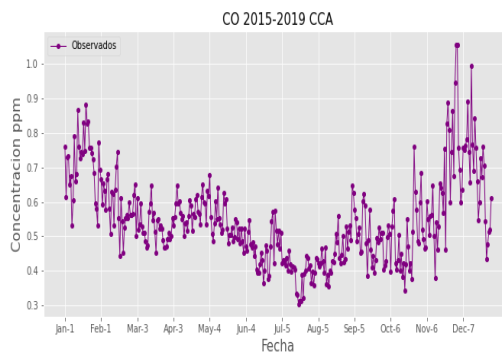


Figura 4.2: a) Promedio diario (CCA de 2015 al 2019), b) Ciclo anual del promedio diario del 2015-2019.






(a)

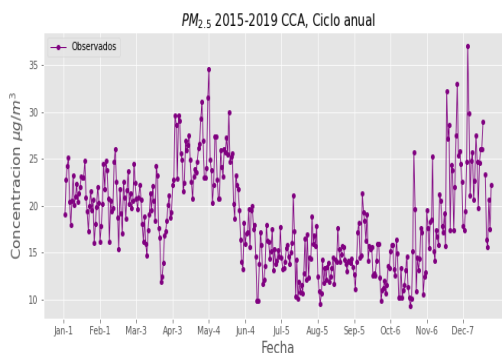


(b)

Figura 4.3: a) Promedio diario de  $CO$  para la estación CCA del 2015 al 2019, b) Ciclo anual de  $CO$  del 2015-2019.

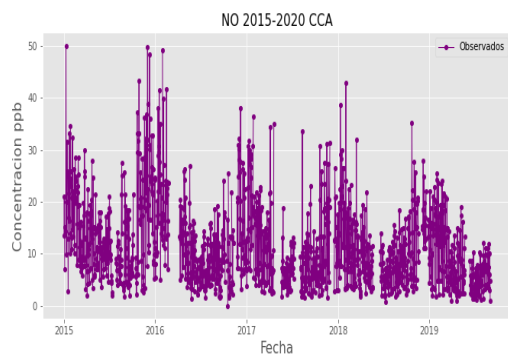


(a)

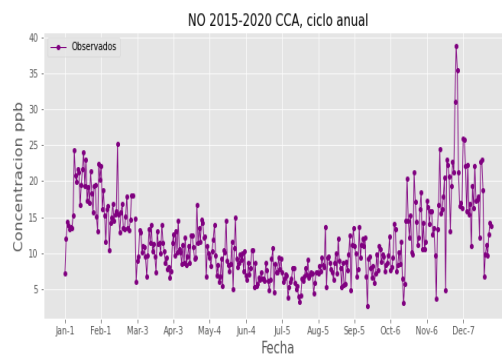


(b)

Figura 4.4: a) Promedio diario de  $PM_{2,5}$  para la estación CCA del 2015 al 2019, b) Ciclo anual de  $PM_{2,5}$  del 2015-2019.



(a)



(b)

Figura 4.5: a) Promedio diario de  $NO$  para la estación CCA del 2015 al 2019, b) Ciclo anual de  $NO$  del 2015-2019.

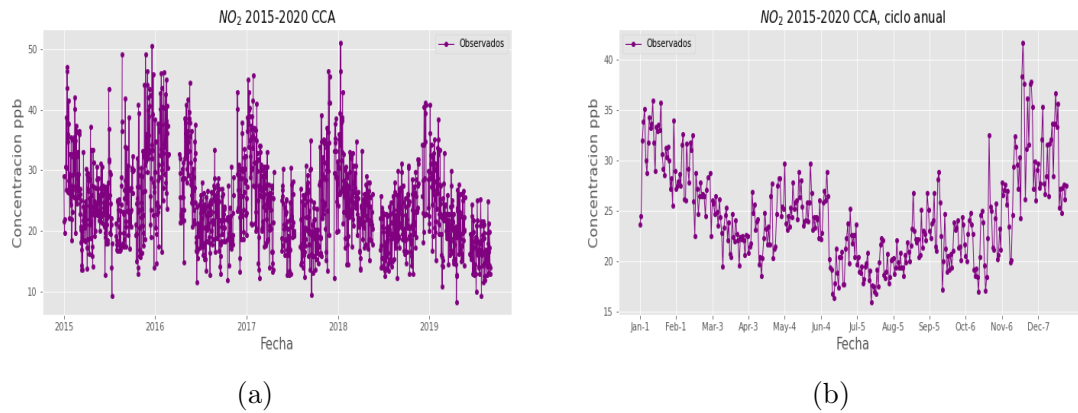


Figura 4.6: a) Promedio diario de  $NO_2$  para la estación CCA del 2015 al 2019, b) Ciclo anual de  $NO_2$  del 2015-2019.

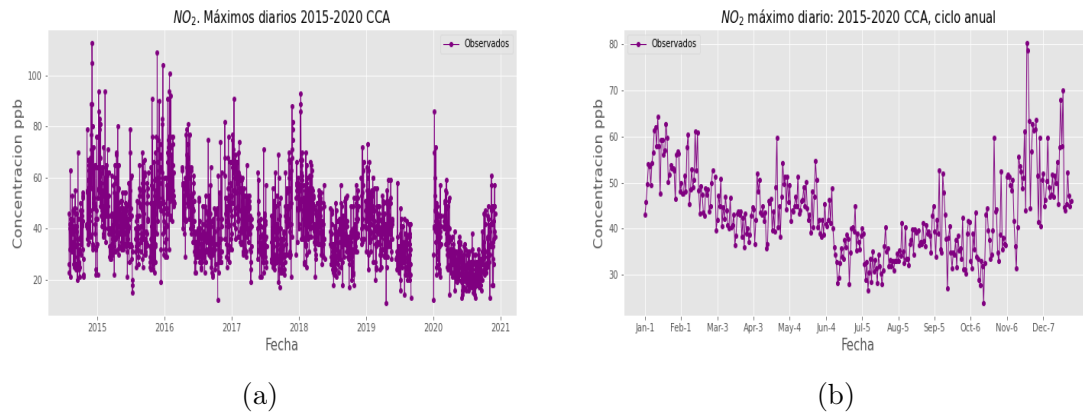


Figura 4.7: a) Máximo diario de  $NO_2$  para la estación CCA del año 2015 al año 2019, b) Ciclo anual de  $NO_2$  del periodo 2015-2019.

En los datos meteorológicos se obtiene para la temperatura el gráfico del ciclo anual (Fig. 4.8), identificando los valores más altos registrados durante la primavera y un descenso hacia la época de invierno, en cuanto a los máximos diarios se observa un comportamiento similar en cada año.

La radiación al igual que la temperatura muestra en el ciclo anual (Fig.4.9a) y la serie de tiempo 2105-2019 (Fig.4.9b) los valores máximos durante los meses de primavera.

En la Figura 4.10 se observan altas presiones durante los meses de invierno esto debido a que suelen ser días poco lluviosos.

En la velocidad del viento se identifican a los meses de invierno como aquellos con las velocidades más bajas (Fig. 4.11b) mientras que en mayo y junio se observan velocidades altas. En la serie de tiempo es difícil identificar un ciclo, pero es importante señalar que durante el 2016 se observaron las velocidades más altas del periodo estudiado (Fig.4.11a).

La serie de tiempo de la humedad relativa muestra a los meses de verano-otoño con los valores más altos (Fig. 4.12a) y claramente también se identifican en el ciclo anual, mientras que los valores descienden en la temporada de invierno y primavera (Fig.4.12b), esta variable está estrechamente relacionada a la precipitación, en donde al compararse ambas variables, se identifica a los meses de verano-otoño con la cantidad de precipitación más alta. Este comportamiento estacional está definido por el régimen pluvial de la Ciudad de México, que se distingue por una temporada de lluvia que inicia en las últimas semanas de mayo y concluye durante las primeras semanas de octubre, con un periodo relativamente seco durante el resto del año (SEDEMA, 2018).

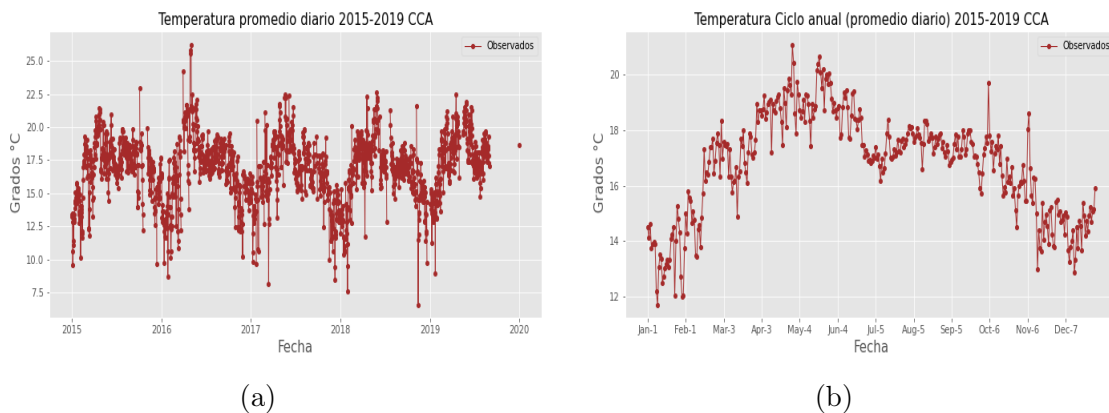


Figura 4.8: a) Promedio diario de Temperatura del 2015-2019. b) Ciclo anual de temperatura con promedio diario del 2015-2019.




Figura 4.9: a) Promedio diario de Radiación del 2015-2019. b) Ciclo anual de Radiación con promedio diario del 2015-2019.

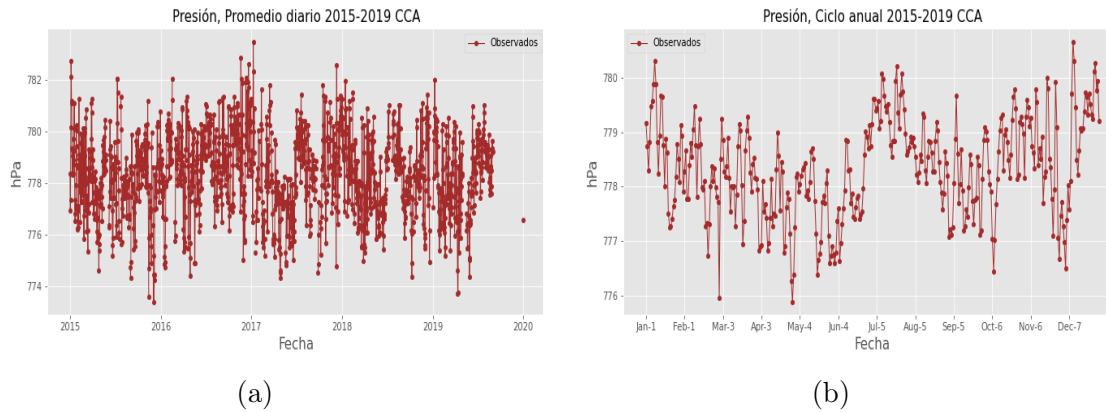


Figura 4.10: a) Promedio diario de Presión del 2015-2019. b) Ciclo anual de Presión con promedio diario del 2015-2019.

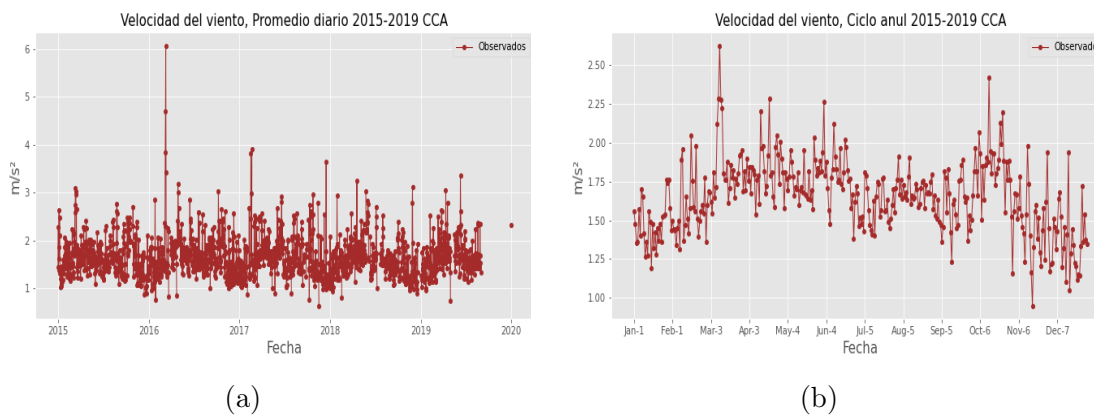


Figura 4.11: a) Promedio diario de la velocidad del viento del 2015-2019. b) Ciclo anual de la velocidad del viento con promedio diario del 2015-2019.

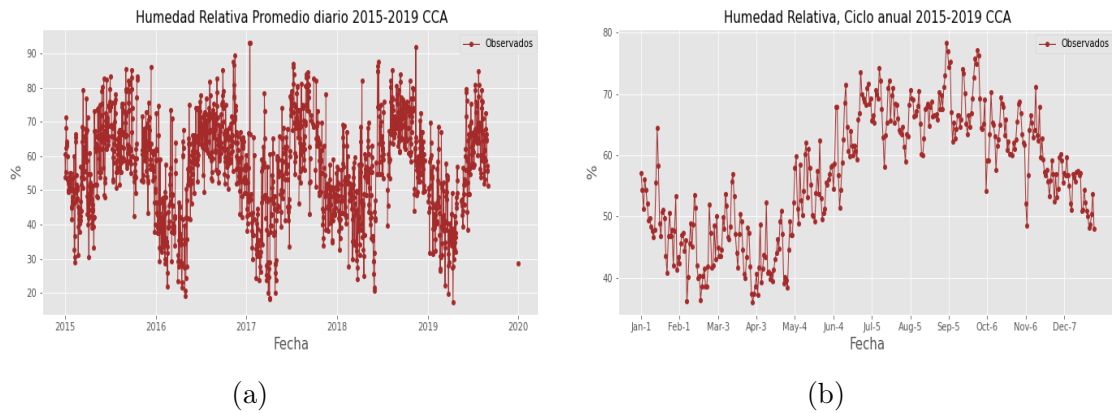


Figura 4.12: a) Promedio diario de humedad relativa del 2015-2019. b) Ciclo anual de humedad relativa con promedio diario del 2015-2019.

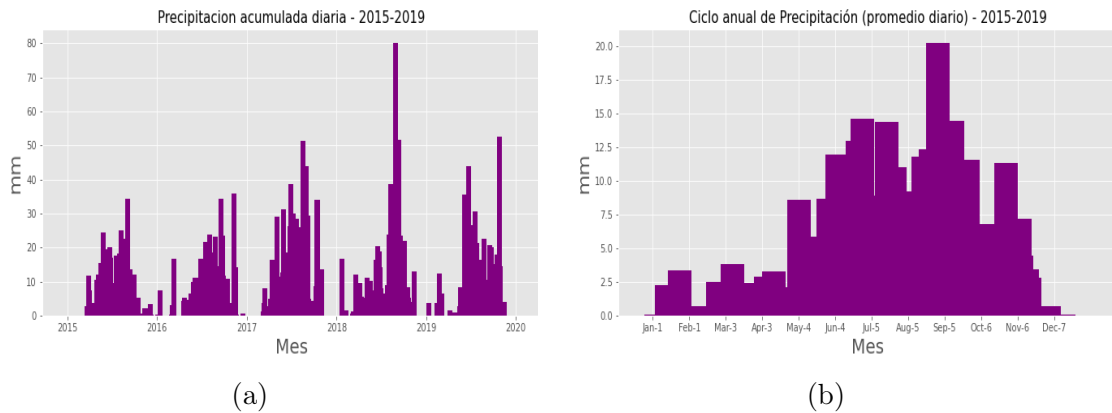


Figura 4.13: a) Precipitación acumulada del 2015-2019. b) Ciclo anual de precipitación acumulada diaria del 2015-2019.

### 4.3. Estadística descriptiva del modelo

Se realizaron gráficas de los residuales (errores) con las cuales se puede saber con mayor certeza si el modelo genera buenos resultados.

En las figuras 4.14 a 4.19 se observan 4 gráficos diferentes para cada figura, en el gráfico **A)** se presenta un gráfico cuantil-cuantil Q-Q, este muestra la variación de los residuales contra los cuantiles teóricos de la distribución de la variación residual, con lo que se busca verificar una suposición gaussiana. Lo ideal es que el gráfico represen-

te una línea recta, de ser así, se considera que el modelo obtuvo resultados cercanos a los observado. Este gráfico Q-Q muestran una línea recta (en color rojo), de las figuras obtenidas se observa un ajuste de los valores, con respecto a esta línea roja para los contaminantes  $O_3$  (Fig.4.14 y 4.15),  $CO$  (Fig. 4.16),  $NO_2$  (Fig.4.19 ),  $PM_{2.5}$  (Fig.4.17) y  $NO$  (Fig. 4.18).

En la parte inferior izquierda (gráfico **C**) se observa la dispersión de los residuales del modelo (error) contra el predictor lineal que en este caso corresponde al tiempo, este gráfico sugiere que la varianza del error es aproximadamente constante a medida que aumenta o avanza el tiempo, idealmente este gráfico no deberá mostrar un sesgo (asimetría) y además los valores deben estar cercanos a cero, analizando los resultados se encontró que todos los modelos estudiados y seleccionados muestran una buena dispersión de los residuales.

El gráfico de la parte superior derecha (gráfico **B**) muestra el histograma de residuales, lo esperado es una distribución simétrica perfecta, similar a la de Gauss, además confirma el resultado obtenido en el gráfico Q-Q. Todos los modelos muestran buenos resultados en el histograma y al comparar con el gráfico Q-Q se observan resultados consistentes.

Finalmente en el gráfico **D** se aprecia la respuesta de los valores medidos para cada contaminante y los valores predichos (valores ajustados) por el modelo GAM. Idealmente, deberían seguir una línea de  $45^\circ$  con una relación lineal positiva, la cual sí se aprecia en todos los modelos.

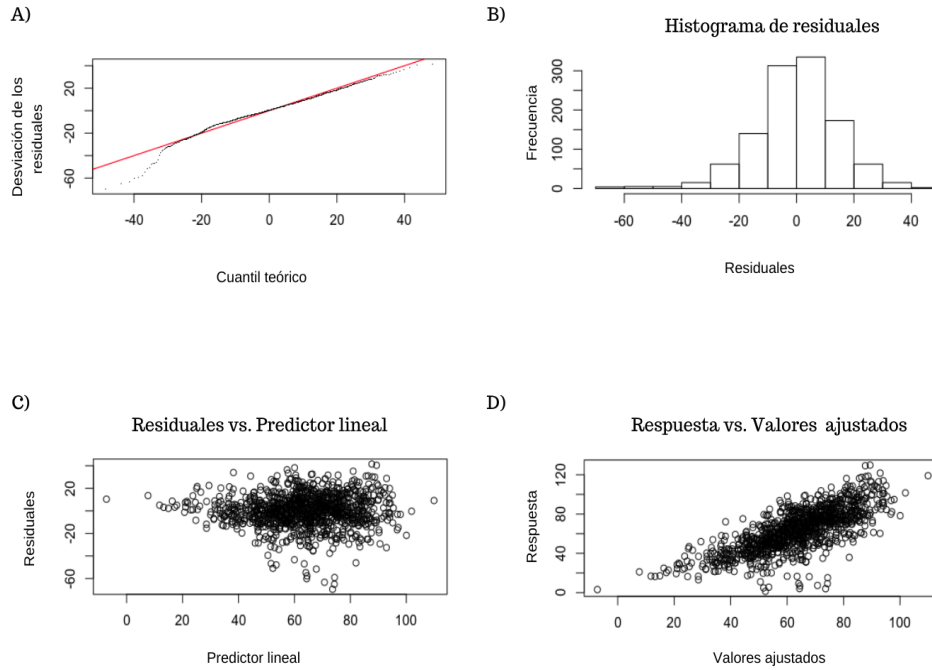


Figura 4.14: Gráficos de residuales del modelo para MDA8 de Ozono.

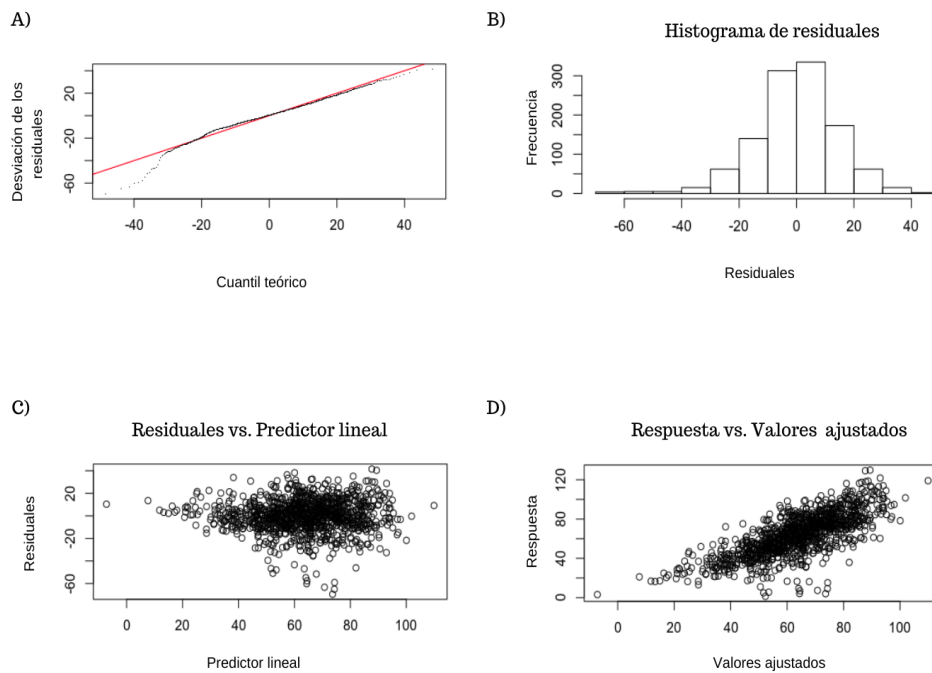


Figura 4.15: Gráficos de residuales del modelo para promedio diario de Ozono.

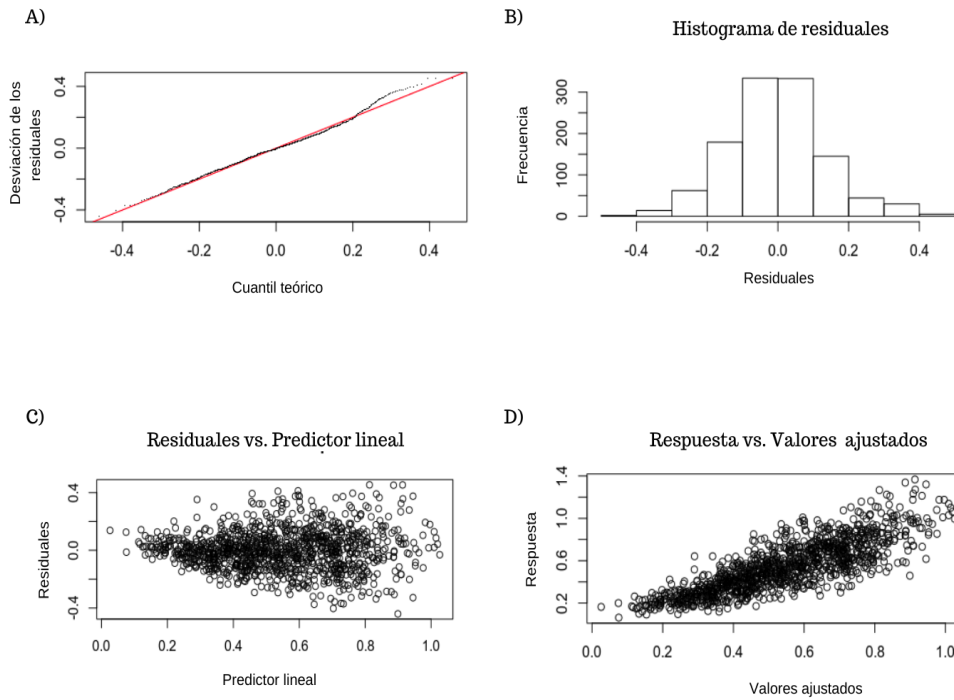


Figura 4.16: Gráficos de residuales del modelo para promedio diario de  $CO$ .

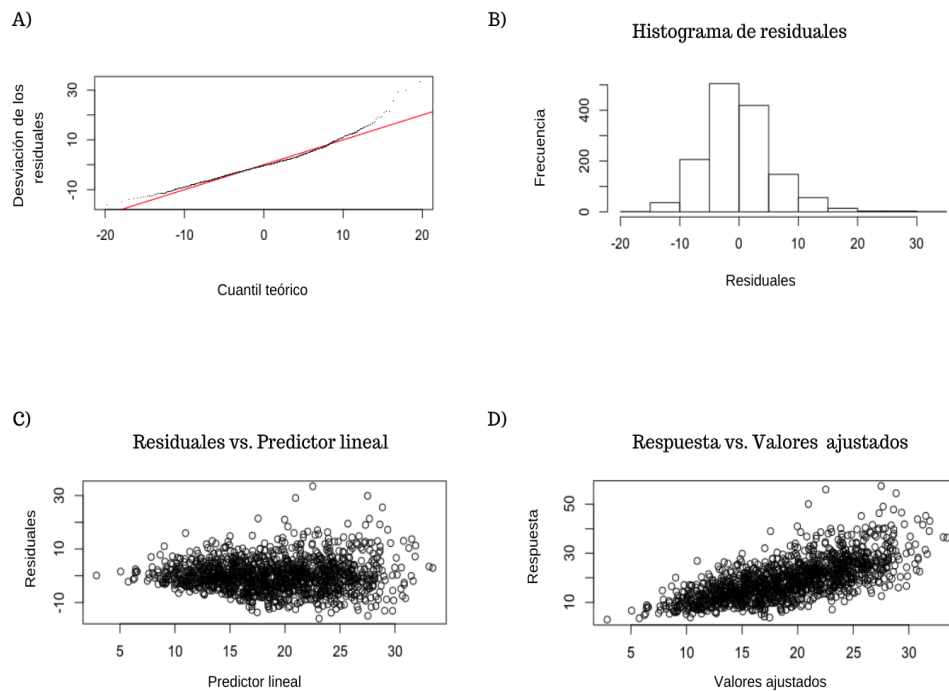


Figura 4.17: Gráficos de residuales del modelo para promedio diario de  $PM_{2.5}$ .



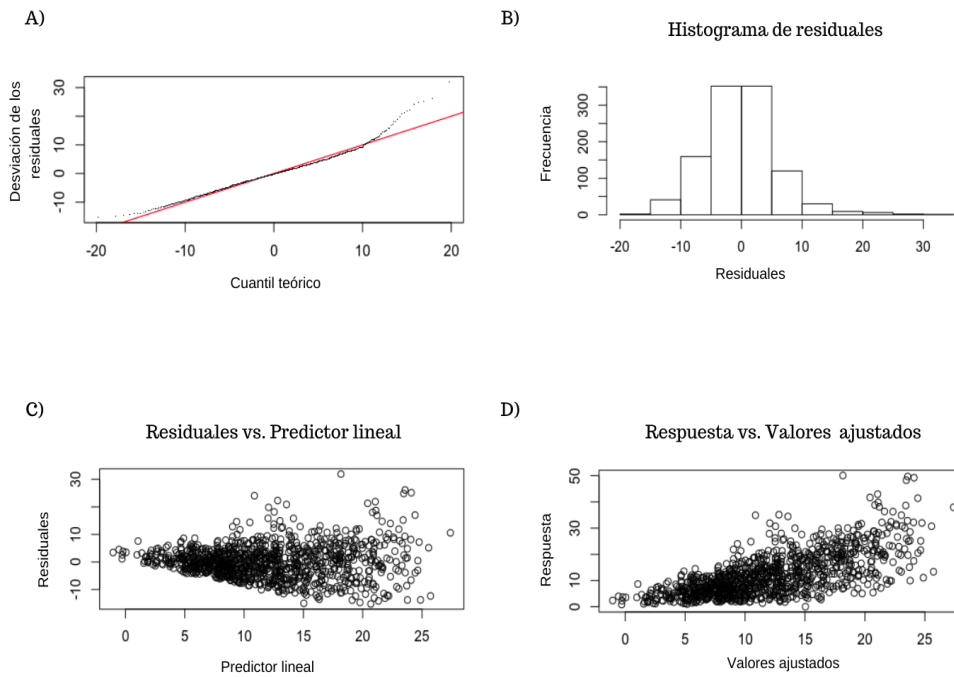


Figura 4.18: Gráficos de residuales del modelo para promedio diario de  $NO$ .

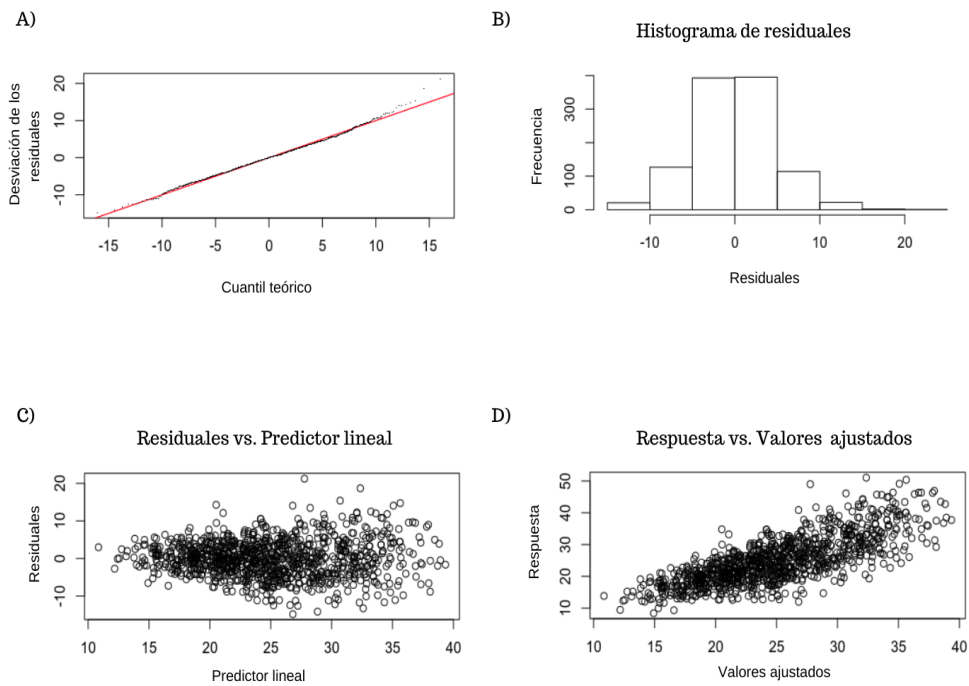


Figura 4.19: Gráficos de residuales del modelo para promedio diario de  $NO_2$ .

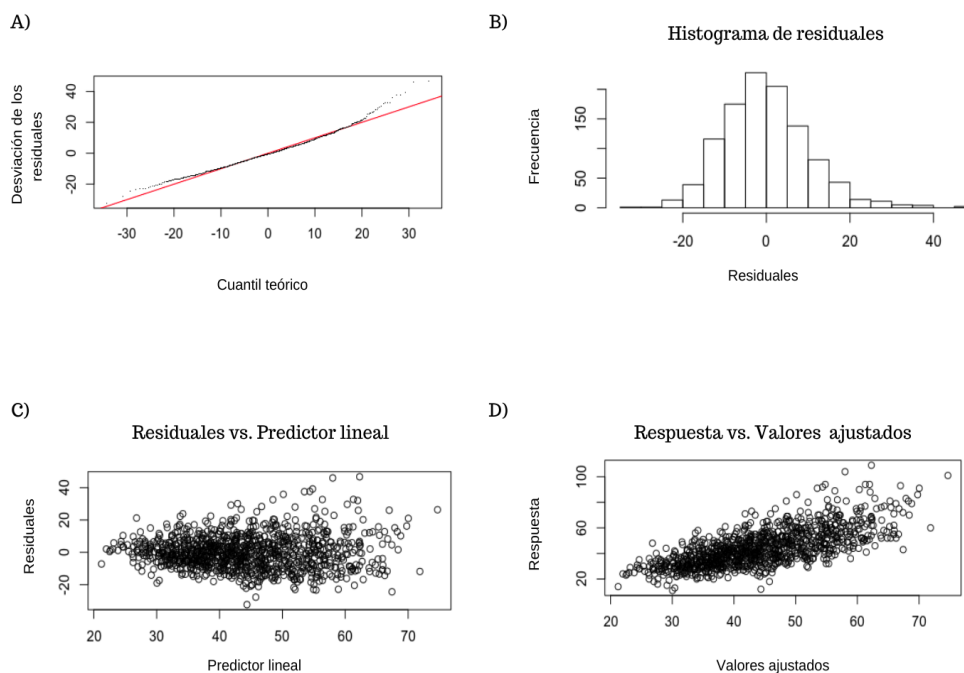


Figura 4.20: Gráficos de residuales del modelo para valores máximos diarios de  $NO_2$ .

### 4.3.1. Relación de los contaminantes con las variables meteorológicas.

Previamente se mencionó que se utilizaron funciones suavizadas ( $\beta$ ) para cada una de las variables explicativas, también denominadas variables independientes, estas funciones suavizadas reemplazan las funciones lineales permitiendo representar relaciones entre las variables independientes más complejas, por lo que se presenta en esta sección las respuestas parciales de cada contaminante a cada una de las variables explicativas individuales.

Las líneas en los diagramas de las figuras 4.21 a 4.27, marcan las funciones suaves ( $\beta$  en la Ecuación 3.1) que mejor se ajustaron al modelo. Las áreas sombreadas representan regiones de incertidumbre, es decir,  $\pm 2$  desviaciones estándar, para las curvas suaves ajustadas. Las curvas en cada diagrama representan las perturbaciones normalizadas cuando se asumen valores medios para todas las demás variables. Así, podemos considerar estas curvas como una expresión de la influencia de cada varia-

ble en los niveles de cada contaminante en función de la época del año manteniendo constantes todas las demás variables, así mismo a partir de la pendiente de esta curva podemos determinar cuales son las variables explicativas con mayor influencia.

Las figuras 4.21 y 4.22 muestran las variables explicativas para el  $O_3$ , de las variables meteorológicas los predictores más eficaces son: la temperatura y humedad relativa tanto para el promedio como el MDA8. La temperatura y radiación muestran una relación positiva, es decir, al aumentar sus valores la concentración suele aumentar también, esto debido a que el  $O_3$  es un contaminante fotoquímico por lo que la radiación favorece su formación. Contrario a lo que sucede con la velocidad del viento el cual tiene relación negativa, ya que la presencia de este genera una dispersión.

Para el  $CO$  se identifica a la velocidad del viento como el predictor meteorológico más eficaz, seguido de la temperatura y la radiación. La velocidad del viento muestra al igual que con el ozono una relación negativa lo que implica que a mayor velocidad la concentración de  $CO$  tiende a disminuir, debido a que el viento favorece la dispersión.

La figura 4.24 muestra que para  $PM_{2.5}$  la velocidad del viento tiene relación negativa, así como la presión y humedad relativa, al igual que con los previos contaminantes la radiación y temperatura muestran relación positiva. El predictor más eficaz para este contaminantes es la velocidad del viento seguido de la temperatura, al igual que con el  $CO$ , el viento también favorece la dispersión lo que explica la relación negativa, mientras que la temperatura puede favorecer la formación de  $PM_{2.5}$  secundarias.

Para el  $NO$  (Fig.4.25) se observa que la velocidad del viento, humedad relativa, capa límite y presión tienen una relación negativa lo que indica que favorecen a que las concentraciones disminuyan. El predictor meteorológico más eficaz es la velocidad del viento, por otro lado los menos eficaces son: la radiación y temperatura, ya que estas dos variables no afectan directamente la formación de  $NO$ .

Finalmente para el  $NO_2$  (Fig.4.26 promedios y 4.27 máximos) se observa que la velocidad del viento es la variable meteorológicas más eficaz, seguida de la temperatura, esta última muestra una relación positiva. También en ambos modelos la humedad relativa, velocidad del viento y presión muestran una relación negativa, que al igual que con los otros contaminantes este favorece la dispersión.

Es importante mencionar que en todos los modelos la variable explicativa no meteorológica considerada a la que se le aplico una función suavizada fue el día del año, observando que la concentración de los contaminantes está fuertemente influenciada por la época del año.

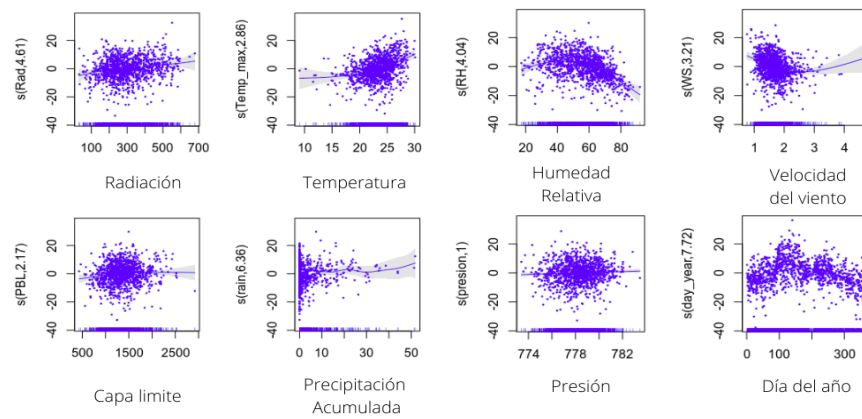


Figura 4.21: Variables explicativas para promedio diario de  $O_3$ .

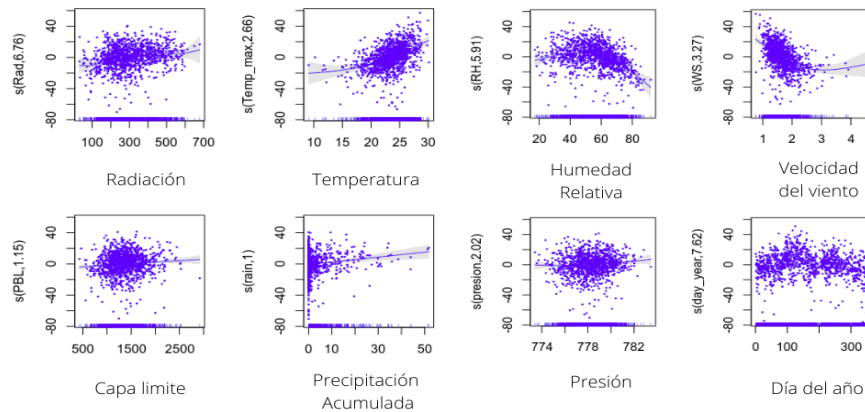


Figura 4.22: Variables explicativas para MDA8 de  $O_3$ .

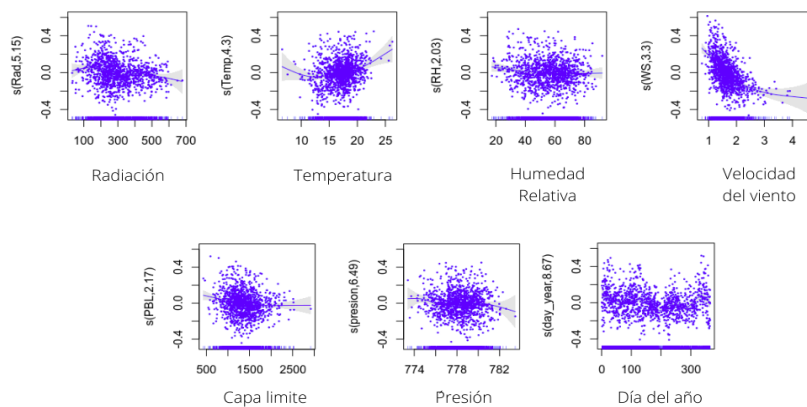


Figura 4.23: Variables explicativas para  $CO$ .

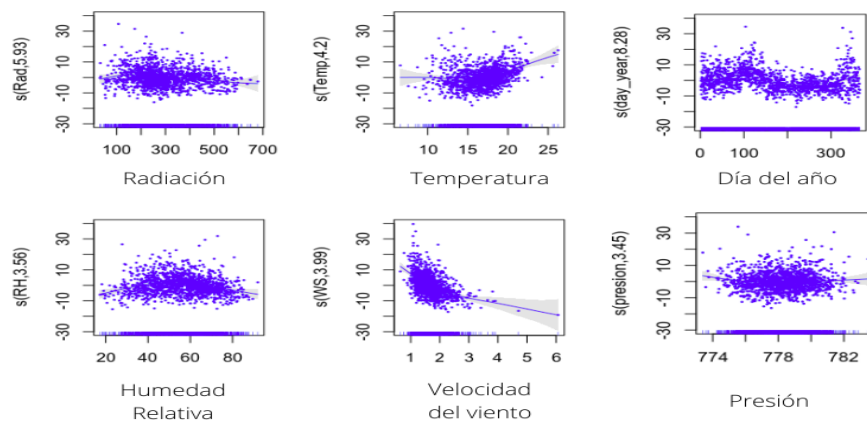


Figura 4.24: Variables explicativas para  $PM_{2.5}$ .

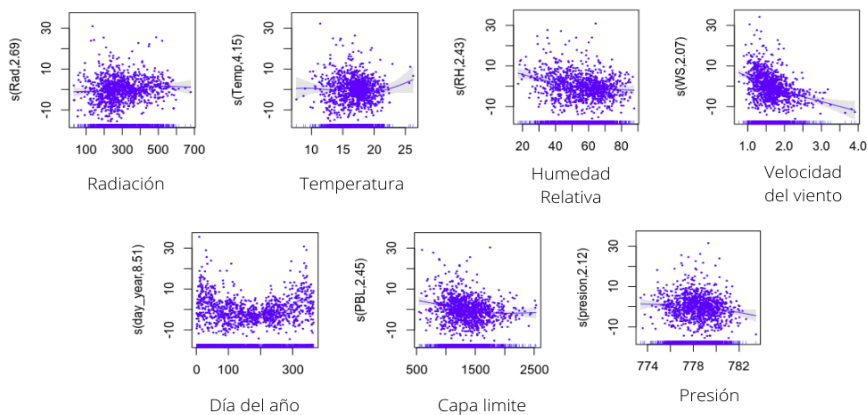


Figura 4.25: Variables explicativas para  $NO$ .

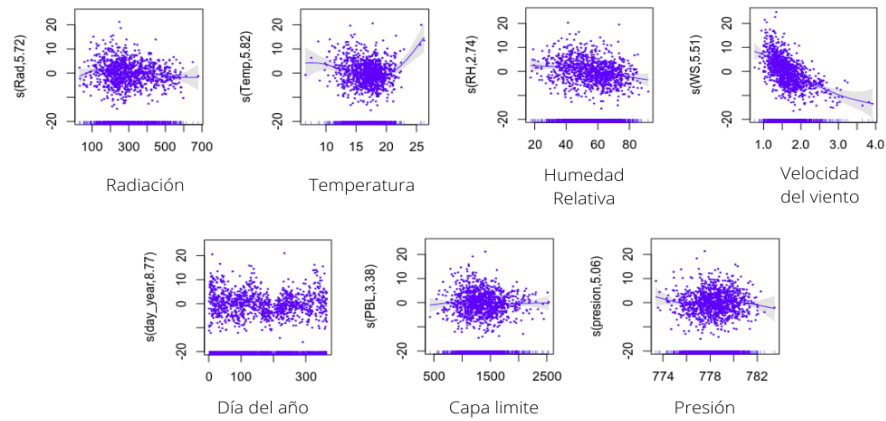


Figura 4.26: Variables explicativas para promedio diario de  $NO_2$ .

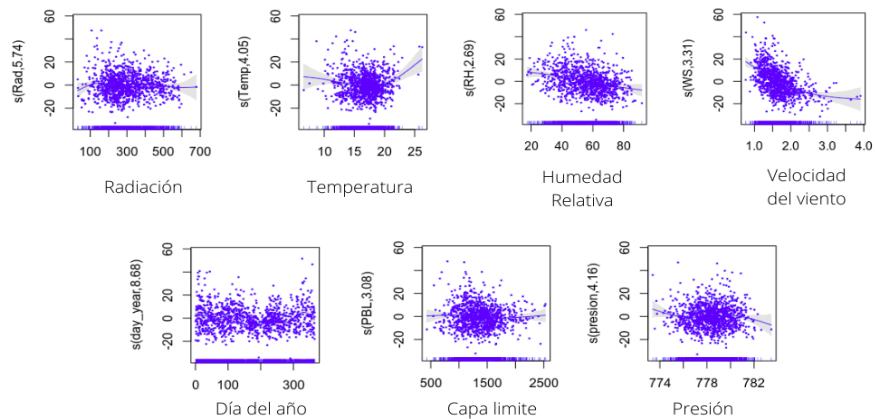


Figura 4.27: Variables explicativas para máximo diario de  $NO_2$ .

## 4.4. Modelo y observaciones

Para evaluar al modelo también se realizaron series de tiempo del periodo 2015 al 2019, donde se comparan las concentraciones observadas y las obtenidas por el modelo.

Para cada uno de los contaminantes estudiados  $O_3$  (Fig.4.28 y),  $CO$  (Fig.4.29),  $PM_{2.5}$  (4.30),  $NO$  (Fig.4.31) y  $NO_2$  (Fig.4.32) los modelos muestran buenos resultados, ya que logran reproducir los ciclos que tienen las concentraciones observadas, sin embargo si se observa que los modelos tienen problemas para predecir las concentraciones muy

altas y en ciertos casos concentraciones muy bajas, pese a estos problemas el modelo nos permite incluir el efecto de la meteorología por lo que su empleo es importante.

Las figuras mencionadas previamente también muestran las líneas de tendencia de los valores obtenidos por el modelo, y visualmente podemos identificar que a excepción del  $PM_{2.5}$  (Fig.4.30), todos los contaminantes estudiados muestran una tendencia descendiente, lo cual analizaremos más adelante.




Figura 4.28: a) Concentraciones observadas y modeladas para Promedio diario. b) Concentraciones observadas y modeladas para MADA8.




Figura 4.29: Concentraciones observadas y modeladas para  $CO$ .




Figura 4.30: Concentraciones observadas y modeladas para  $PM_{2.5}$ .




Figura 4.31: Concentraciones observadas y modeladas para NO.




Figura 4.32: a) Concentraciones observadas y modeladas para Promedio diario. b) Concentraciones observadas y modeladas para MADA8.



## 4.5. Tendencia obtenida

En la tabla 4.6 se observa el valor de la pendiente de cada uno de los contaminantes, es decir la tendencia calculada sobre los valores obtenidos por el modelo, todos a excepción de las  $PM_{2.5}$  muestran una tendencia negativa siendo tanto el  $NO$  y el  $NO_2$  los contaminantes con la mayor tendencia negativa.

Modelo	Tendencia
Promedio diario $O_3$	m= -0.49
MDA8 $O_3$	m=-0.21
$CO$	m=-0.098
$NO$	m= -1.8
$NO_2$	m=-1.22
$PM_{2.5}$	m= 0.86

Tabla 4.6: Tendencia obtenida para cada contaminante.

## 4.6. Análisis de las concentraciones por fases.

En la figura 4.33 se compara las concentraciones observadas para el 2020 contra el ciclo anual realizado a partir del periodo 2015-2019. El promedio y el MDA8 de  $O_3$  para el año 2020 muestran una variabilidad semejante a los años previos que aumenta durante la primavera. Se puede identificar que en los primeros meses del año las concentraciones observadas en el año 2020 son menores, y para el mes de marzo y lo que resta del año las concentraciones del año 2020 suelen ser mayores.

El  $CO$  muestra en general concentraciones menores durante todo el año en comparación a los años previos, se puede distinguir dentro de la variabilidad del ciclo anual que los primeros y últimos meses del año muestran las concentraciones más altas.

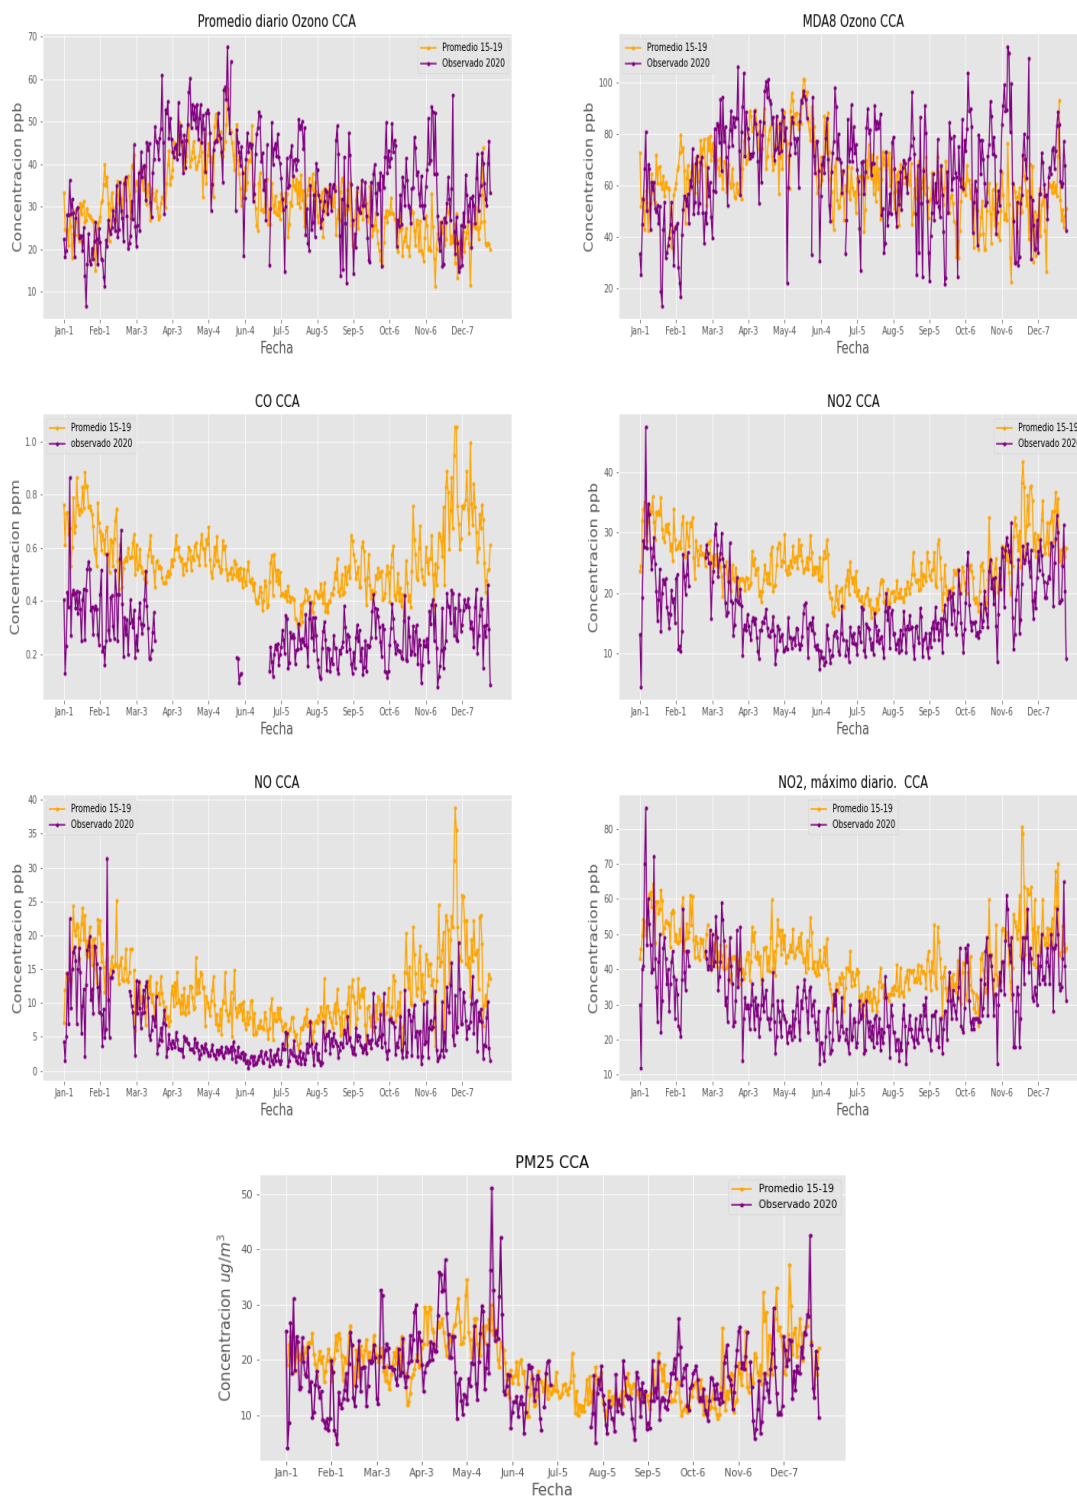


Figura 4.33: Concentraciones observadas en el 2020 y ciclo anual del 2015-2019.

El *NO* en el año 2020 tuvo concentraciones menores a los años previos, mostrando una variabilidad similar a la observada en el ciclo anual. Las concentraciones del año

2020 para el  $NO_2$  con promedio y máximo diario muestra valores inferiores a los años previos siendo más significativo en los meses de verano. Finalmente para el  $PM_{2.5}$  es menos claro si las concentraciones del año 2020 fueron menores al ciclo anual, ya que se mantuvo fluctuando a lo largo del año.

La comparación de las concentraciones observadas del año 2020 con los años previos no es suficiente para saber si las actividades humanas tuvieron algún efecto sobre estas, ya que como se mencionó previamente la meteorología tiene un papel importante en la dispersión, acumulación y generación de los contaminantes estudiados, por lo tanto, como parte del trabajo se mostrarán los resultados del modelo en donde se incluye el papel de la meteorología, para realizar este análisis se evaluarán cuatro escenarios, es decir, diferentes combinaciones de resultados, de las concentraciones observadas durante el año 2020, de los promedios de concentraciones de los años 2015-2019 y de las concentraciones obtenidas por el modelo para el 2020.

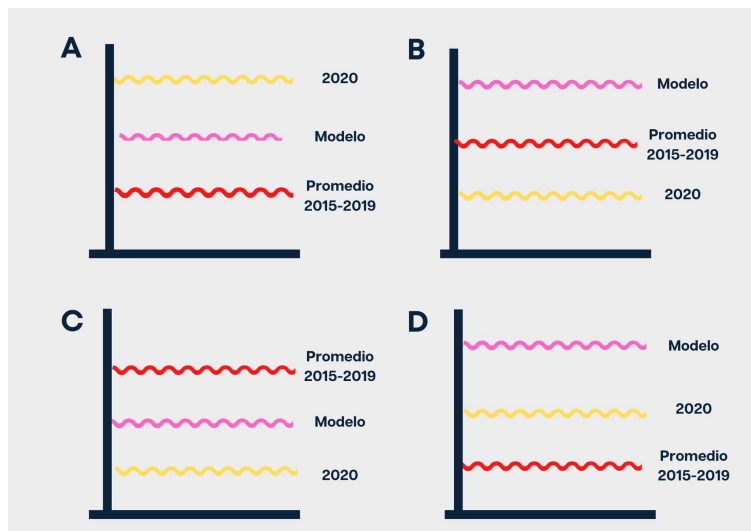


Figura 4.34: Esquemas de los escenarios obtenidos.

El primer escenario se observa en el panel A de la figura 4.34, para este caso el año 2020 tiene las mayores concentraciones seguidas de las concentraciones del modelo y finalmente el promedio de los años 2015-2019, esto indica que:

- 1) En el año 2020 la concentración fue mayor que en años anteriores.

- 2) Este aumento es mayor si no tomamos en cuenta el efecto de la meteorología.
- 3) La meteorología durante este año propició una parte del aumento en la concentración de los contaminantes.
- 4) Este aumento debido a la meteorología es la diferencia entre modelo – promedio 2015-2019.

En el panel B de la figura 4.34 se observa el segundo escenario a analizar, en este, el modelo presenta las mayores concentraciones seguido del ciclo anual y finalmente las observaciones del 2020, esto indica que:

- 1) En el año 2020 la concentración de contaminantes disminuyó con respecto a los años previos.
- 2) El modelo indica que la meteorología favorece las altas concentraciones durante el 2020.
- 3) La meteorología no ayudó a que la contaminación disminuyera en el 2020.
- 4) Los efectos de la meteorología atenuaron que se viera una menor concentración de contaminantes en el año 2020.

En el panel C de la figura 4.34 se presenta el tercer escenario en el cual las concentraciones del ciclo anual son las más altas seguidas de las del modelo y finalmente las observaciones del 2020, esto indica que:

- 1) En el año 2020 la concentración de contaminantes disminuyó con respecto a los años previos.
- 2) Esta disminución se debe en parte a la meteorología.
- 3) Esta disminución debido a la meteorología es la diferencia entre modelo – promedio 2015-2019.

Finalmente en el panel D de la figura 4.34 encontramos el cuarto escenario a estudiar donde el modelo tiene concentraciones mayores que las otras dos variables seguido de las observaciones del año 2020 y finalmente el promedio 2015-2019 esto indica que:

- 1) En el año 2020 la concentración fue mayor que los años previos.

- 2) La meteorología favoreció durante este año las altas concentraciones de contaminantes.
- 3) La meteorología explica parte de este aumento en la concentración de contaminantes.

En la figura 4.35 se presentan los datos de  $NO_2$  tanto para el promedio (Fig. 4.35a) como para el valor máximo (Fig. 4.35b), y se observa que durante el principio de año hay concentraciones similares para el modelo y el promedio de los años 2015-2019, sin embargo las concentraciones observadas son menores que las del modelo. Después del mes de marzo las concentraciones del modelo superan a las del promedio y las observadas, con esto podríamos aproximarnos a un escenario "B". Además al analizar cada una de las fases (Tabla 4.7), estas presentan el mismo escenario "B" tanto en promedio como en valor máximo diario.

En la tabla 4.9 se observa la diferencia entre las concentraciones observadas en el año 2020 y el promedio del periodo 2015-2019, en las diferentes fases se encuentran valores negativos lo que indica que el año 2020 registró concentraciones menores al promedio de los años previos estudiados, por otro lado la misma tabla muestra las diferencias del modelo y los años previos estudiados, esta diferencia nos indica el impacto que tuvo la meteorología en donde los valores positivos indican que esta no favoreció a que las concentraciones disminuyeran, es interesante observar que previo a la contingencia los resultados de promedio y máximos diario son ligeramente diferentes, pues el promedio se ajusta a un escenario "C" esto indica que los valores del modelo fueron ligeramente mas pequeños que el promedio 2015-2019 por lo que la meteorología ayudó a inhibir los valores alrededor del valor máximo.

Por otro lado el  $CO$  (Fig.4.36) muestra con mayor claridad que las concentraciones modeladas fueron las mayores, seguidas del promedio 2015-2019 y finalmente las observadas en el año 2020 por lo que se ajusta el resultado al escenario "B". Analizando la tabla 4.8 cada una de las fases determinadas para la pandemia en México muestran

este mismo comportamiento. Al analizar las diferencias (Tabla 4.10) se identifica que existió una reducción en las concentraciones del año 2020 con respecto al promedio de los años previos, siendo más significativo en la fase 3, por otro lado la diferencia de las concentraciones obtenidas por el modelo y el promedio del periodo 2015-2019 indican que la meteorología propicia altas concentraciones.

Para el  $NO$  (Fig. 4.37), el modelo predice las mayores concentraciones, seguido del promedio 2015-2019 y finalmente las concentraciones observadas, lo que indica un escenario "B". Durante la fase 0 existen días en donde las concentraciones tienen mayores fluctuaciones por lo que visualmente no es tan claro el patrón en este periodo, sin embargo podemos afirmar, basado en el promedio por fases, que durante cada periodo, se observó el comportamiento descrito del escenario "B" (tabla 4.8). Con las diferencias de la tabla 4.10 en cada una de las fases se muestra un cambio en las emisiones, siendo la fase 3 la más significativa. También los valores positivos de las diferencias del modelo con el promedio de los años 2015-2019 indican que la meteorología no favorece a que las emisiones disminuyan.

Finalmente para el  $O_3$  y el  $PM_{2.5}$  figuras 4.38 y 4.39 respectivamente, visualmente es difícil indicar el orden de los resultados puesto que constantemente hay variabilidad. Haciendo el promedio para el  $PM_{2.5}$  durante cada fase de contingencia podemos afirmar con mayor claridad que las fases 0 y 3 muestran un escenario "C", mientras que la fases 1 y 2 presentan el escenario "D". En la tabla 4.10 encontramos que la fase 0 y 3 muestran disminución en las concentraciones, por otro lado en la diferencia del modelo con el promedio 2015-2019, en estas mismas fases los resultados negativos indican que la meteorología favorece a que las concentraciones disminuyan. En los dos periodos con el escenario "D" podemos ver que las concentraciones no disminuyeron en comparación con años anteriores y la diferencia del modelo con el promedio 2015-2019 demuestran que la meteorología no favoreció la disminución de concentraciones.

En cuanto al  $O_3$  en la fase 0 tanto el promedio diario como el MDA8 presentan

el escenario "B", las diferencias mostradas en la tabla 4.9 muestran que las concentraciones en el año 2020 disminuyeron en comparación a los años previos pero la meteorología no fue la causante directa de estas disminuciones, esto se demuestra con los valores positivos observados en la diferencia del modelo y el promedio 2015-2019. La fase 1 presenta el escenario "D", esto indica que en los primeros meses existió un aumento que se debió en parte a la meteorología, que se logra apreciar con los valores positivos de la diferencia modelo-promedio 2015-2019. La fase 2 tiene dos escenarios, el "A" para los promedios diarios y el escenario "D" para los valores de MDA8, en la fase 3 también se tiene un escenario "A" para promedios diarios pero un escenario "B" para MDA8, entonces con el promedio parte del aumento del  $O_3$  en estas fases se debió a una influencia meteorológica que se identifica también en la tabla 4.9. Para MDA8 como se mencionó, en la fase 2 se observa el escenario "D" y en la fase 3 el escenario "B", esto indica que para el promedio el aumento de las concentraciones fue debido a las emisiones, mientras que para el MDA8 muestra una disminución debido a la meteorología (tabla 4.9).






Figura 4.36: Concentraciones observadas, modeladas y promedio del 2015-2019 para  $CO$ .



(a)



(b)

Figura 4.35: a) Concentraciones observadas, modeladas y promedio del 2015-2019 para promedio diario de  $NO_2$ . b) Concentraciones observadas, modeladas y promedio del 2015-2019 para valor máximo de  $NO_2$ .




Figura 4.37: Concentraciones observadas, modeladas y promedio del 2015-2019 para  $NO$ .






Figura 4.38: Concentraciones observadas, modeladas y promedio del 2015-2019 para promedio diario de  $O_3$  (gráfica superior) para MDA8 (gráfica inferior).




Figura 4.39: Concentraciones observadas, modeladas y promedio del 2015-2019 para  $PM_{2,5}$

Periodo	Observado 2020		Modelo 2020		Promedio 15-19	
Contaminante	$O_3$ ppb	$NO_2$ ppb	$O_3$ ppb	$NO_2$ ppb	$O_3$ ppb	$NO_2$ ppb
Fase 0	P=23.68 m=48.57	P= 21.55 máx=40.84	P=29.26 m=65.16	P= 29.47 máx=54.74	P=28.71 m=61.07	P=29.54 máx=52.25
Fase 1	P=37.06 m=73.06	P= 22.72 máx=40.56	P=37.60 m=78.96	P=25.92 máx=50.63	P=34.46 m=66.98	P= 24.02 máx=43.65
Fase 2	P= 47.51 m=81.56	P= 15 máx= 30.96	P= 44.72 m=88.30	P= 26.43 máx=54.10	P=40.50 m=74.84	P=22.32 máx=42.38
Fase 3	47.83 m=78.3	P= 12.98 máx= 26.76	P=44.70 m=87.02	P= 27.31 máx=52.31	P=43.28 m=81.22	P=25.15 máx=45.65

Tabla 4.7: Promedio de concentraciones para las fases de contingencia. P= Promedio diarios, m= MDA8 y máx=Máximo diario

Periodo	Observado 2020			Modelo 2020			Promedio 15-19		
Contaminante	NO ppb	CO ppm	PM2.5 $\mu g/m^3$	NO ppb	CO ppm	PM2.5 $\mu g/m^3$	NO ppb	CO ppm	PM2.5 $\mu g/m^3$
Fase 0	12.17	0.37	15.66	23.31	0.86	17.50	16.84	0.66	20.89
Fase 1	8.13	0.30	19.89	18.32	0.81	20.62	10.99	0.54	19.82
Fase 2	4.31	NaN	24.34	19.03	0.85	24.66	10.31	0.54	22.32
Fase 3	2.87	0.14	21.27	17.34	0.81	21.58	10.08	0.56	24.33

Tabla 4.8: Promedio de concentraciones para las fases de contingencia.

Periodo	2020-(Promedio 2015-2019)		Modelo- (Promedio 2015-2019)	
Contaminante	$O_3$ ppb	$NO_2$ ppb	$O_3$ ppb	$NO_2$ ppb
Fase 0	P= -5.03 m= -12.5	P=-8.57 máx=-12.33	P= 0.2 m=2.72	P= -0.11 máx= 2.05
Fase 1	P= 2.61 m= 6.08	P= -1.39 máx= -3.10	P= 3.27 m= 11.80	P= 1.31 máx= 5.91
Fase 2	P= 7.01 m=6.73	P= -7.32 máx= -11.42	P= 4.32 m=13.57	P=4.07 máx= 11.61
Fase 3	P= 4.45 m= -2.91	P=-12.17 máx=-18.89	P= 1.02 m= 5.19	P=2.24 máx=6.78

Tabla 4.9: Diferencia del promedio de concentraciones observadas en el 2020 y los resultados del modelo con las del Promedio 2015-2019, para  $O_3$  y  $NO_2$  donde, P=Promedio, m=MDA8 y máx=Máximo diario.

Periodo	2020-(Promedio 2015-2019)			Modelo-(Promedio 2015-2019)		
Contaminante	NO ppb	CO ppm	$PM_{2.5}$ $\mu g/m^3$	NO ppb	CO ppm	$PM_{2.5}$ $\mu g/m^3$
Fase 0	-5.01	-0.28	-5.4	5.75	0.2	-3.33
Fase 1	-2.88	-0.24	0.07	7.05	0.25	0.81
Fase 2	-5.99	NaN	2.02	8.69	0.31	2.34
Fase 3	-7.21	-0.36	-3.06	7.55	0.24	-2.76

Tabla 4.10: Diferencia del promedio de lo observado 2020 y del modelo con el Promedio 2015-2019 para  $NO$ ,  $CO$  y  $PM_{2.5}$ .

# Capítulo 5

## Conclusiones

En este trabajo encontramos que existe una relación entre las medidas de confinamiento y las concentraciones de contaminantes atmosféricos en el aire observados en la ciudad de México, los principales resultados de este trabajo se expondrán a continuación:

1. El  $CO$  presentó durante todas sus fases un escenario "B". Estos resultados indican que las bajas concentraciones durante el 2020 se atribuyen a una disminución de emisiones, particularmente en la fase 3, como se mencionó previamente durante esta etapa hubo hasta un 75 % de reducción vehicular (SEMOVI, 2021), esto podría indicar que la disminución de las concentraciones de este contaminantes se atribuye a las medidas para contener la movilidad impuestas durante la contingencia sanitaria.
2. Para el  $NO$  se encontró para cada fase un escenario "B", donde las concentraciones más altas son las obtenidas por el modelo, seguidas por el promedio del periodo 2015-2019 y finalmente las concentraciones del año 2020, por lo que las concentraciones menores a los años previos fueron debidas a la disminución de emisiones consecuencia de un decremento en la movilidad vehicular, estos elementos también sugieren que la disminución de  $NO$  en el 2020 se debe a las medidas para contener la movilidad.
3. El  $PM_{2.5}$  mostró dos escenarios, por un lado en los primeros meses del año y

durante la fase 3 se apreció un escenario "C", por lo que la meteorología favoreció las bajas concentraciones, sin embargo también las emisiones directas o de precursores favorecieron en la disminución del año 2020, las diferencias indican que fueron estas últimas más significativas para esta reducción de concentraciones, este escenario concuerda con los resultados encontrados por Peralta(2020) donde encuentra una reducción de  $PM_{2.5}$  de los promedios horarios en 2020 con respecto a dos años previos. Con un 56 % el transporte representa uno de los principales generadores de emisiones de partículas en la Ciudad de México (SEDEMA, 2021b), lo que sugiere que el aislamiento tuvo un impacto en las emisiones de estas. Por otro lado, las fases 1 y 2 mostraron escenario "D", por lo tanto la meteorología favoreció las altas concentraciones. Sin embargo estas concentraciones siguieron siendo mayores al promedio de los años previos, recordando que este contaminante tiene diferentes fuentes de emisiones y también una naturaleza secundaria, se podría suponer que parte de este aumento no necesariamente es debido a las emisiones vehiculares.

4. El  $NO_2$  presenta para el promedio y valor máximo durante las fases 1,2 y 3 un escenario "B", este resultado indica una disminución por emisiones directas así como de precursores, recordando que la fuente más importante de  $NO_2$  es la oxidación en la atmósfera del  $NO$  emitido durante los procesos de combustión (SEDEMA, 2018), se puede concluir que las restricciones de movilidad si favorecieron a un decremento en las concentraciones de este contaminante.
5. El  $O_3$  presentó un aumento de concentraciones en la fase 1 comparado con los primeros meses del año, en esta fase el aumento de MDA8 fue principalmente por la meteorología, mientras que para el promedio fueron las emisiones de los precursores. En las fases 2 y 3, para el promedio se observa un aumento influenciado tanto por meteorología y por las emisiones sin embargo las diferencias indican que este último fue más significativo. Para el MDA8 durante la fase 2 hay un aumento que es favorecido por la meteorología y en la fase 3 una disminución influenciada por ambos factores mencionados. El  $O_3$  es una relación

de  $VOC_s$  y  $NO_x$  compleja y no lineal lo que se observa es que emisiones más bajas de  $NO_x$  pueden conducir a niveles más altos de ozono. Esto provoca el bien documentado "Efecto de fin de semana", en el que el ozono aumenta los fines de semana debido a los niveles más bajos de  $NO_x$  debido a la reducción del tráfico (Kroll et al., 2020), esto explicaría lo observado en la fase 1 y 2 tanto en promedio diario como MDA8 y en el promedio de la fase 3. En el trabajo de Peralta (2020) realizan un análisis del comportamiento en el ciclo diurno del  $O_3$  en la Zona Metropolitana del Valle de México y encuentran que los perfiles de  $O_3$  promediados tienen un pico alrededor de 80 ppb que al comparar con los años previos se encuentran indistinguibles, debido a que también encuentran una reducción de  $NO_x$  mayor en el año 2020, estudian la importancia de la relación  $VOC_s$  y  $NO_x$ , generando una discusión donde las concentraciones observadas se deben a un aumento de  $VOC_s$ , los cuales no se atribuyen directamente a combustión incompleta sino a otras actividades domésticas e incluso el aumento de productos de limpieza.

# Bibliografía

- Ahrens, C. D. and Henson, R. (2018). *Meteorology Today: An Introduction to Weather, Climate, and the Environment, Twelfth Edition*.
- Bandera, E. and Pérez, L. (2018). Los modelos lineales generalizados mixtos. Su aplicación en el mejoramiento de plantas. *Cultivos Tropicales*, 39(1):127–133.
- Carlos Ordóñez, JoseM. Garrido-Perez, R. G.-H. (2020). Early spring near-surface ozone in Europe during the COVID-19 shutdown: Meteorological effects outweigh emission changes.
- Carslaw, D. (2015). The openair manual open-source tools for analysing air pollution data. *King's College London*, page 287.
- Carslaw, D. C., Beevers, S. D., and Tate, J. E. (2007). Modelling and assessing trends in traffic-related emissions using a generalised additive modelling approach. *Atmospheric Environment*, 41(26):5289–5299.
- CDMX (2020). Nuevas medidas para la fase 3 por covid-9. Disponible: <https://www.cdmx.gob.mx/portal/articulo/nuevas-medidas-para-la-fase-3-por-covid-9>.
- Chen, T. M., Gokhale, J., Shofer, S., and Kushner, W. G. (2007). Outdoor air pollution: Nitrogen dioxide, sulfur dioxide, and carbon monoxide health effects. *American Journal of the Medical Sciences*, 333(4):249–256.
- Cohen, J. and Kupferschmidt, K. (2020). Countries test tactics in "war" against COVID-19. *Science*, 367(6484):1287–1288.

- EPA.U.S (2010). Integrated Science Assessment (ISA) for Carbon Monoxide. *Federal Register*, 74(183):48536–48538.
- EPA.U.S. (2016). Integrated Science Assessment (ISA) for Oxides of Nitrogen – Health Criteria. *Federal Register*, 73(134):39960–39961.
- Finlayson-Pitts, Barbara J. James N. Pitts, J. (2000). Upper and Lower Atmosphere. page 969.
- GOB.MX. Medidas de seguridad sanitaria., year = 2020, note = Disponible: <https://coronavirus.gob.mx/medidas-de-seguridad-sanitaria/>,.
- Godish, T. (2004). Air Quality. *CRC Press LLC: Boca Raton, 4th ed.*
- Google-Earth (S.F.). Imagen. Disponible: <https://www.google.com/maps/@19.4615534,-99.181462,80938m/data=!3m1!1e3>.
- Hastie, T. J. and Tibshirani, R. J. (1990). Generalized Additive Models .
- Hugh, Y. and Freedman, R. (2009). Física Universitaria. Volumen 1. *Pearson Educación*, page 760.
- INE (2016). Manual 1. Principios de Medición de la Calidad del Aire. *Instituto Nacional de Ecología*, page 43.
- INEGI (2021). Censo de población y vivienda 2020. pages 2–7.
- Jazcilevich, A. D., García, A. R., and Ruíz-Suárez, L. G. (2002). A modeling study of air pollution modulation through land-use change in the Valley of Mexico. *Atmospheric Environment*, 36(14):2297–2307.
- Jiménez, R. M. R., Capa, B., and Lozano, A. P. (2004). *Meteorología Y Climatología*.
- Katsouyanni, K., Touloumi, G., Samoli, E., Gryparis, A., Le Tertre, A., Monopoli, Y., Rossi, G., Zmirou, D., Ballester, F., Boumghar, A., Anderson, H. R., Wojtyniak, B., Paldy, A., Braunstein, R., Pekkanen, J., Schindler, C., and Schwartz, J. (2001). Confounding and effect modification in the short-term effects of ambient



- particles on total mortality: Results from 29 European cities within the APHEA2 project. *Epidemiology*, 12(5):521–531.
- Kroll, J. H., Heald, C. L., Cappa, C. D., Farmer, D. K., Fry, J. L., Murphy, J. G., and Steiner, A. L. (2020). The complex chemical effects of COVID-19 shutdowns on air quality. *Nature Chemistry*, 12(9):777–779.
- Kumari, P. and Toshniwal, D. (2020). Urban Climate Impact of lockdown on air quality over major cities across the globe during COVID-19 pandemic. *Urban Climate*, 34(August):100719.
- Miller, J. (1991). Reaction Time Analysis with Outlier Exclusion: Bias Varies with Sample Size. *The Quarterly Journal of Experimental Psychology Section A*, 43(4):907–912.
- Monks, P. S. (2000). A review of the observations and origins of the spring ozone maximum. *Atmos. Environ - 34*, 3545., (Eionet Report – ETC/ACM 2018/9).
- Monks, P. S., Archibald, A. T., Colette, A., Cooper, O., Coyle, M., Derwent, R., Fowler, D., and Granier, C. (2015). Tropospheric ozone and its precursors from the urban to the global scale from air quality to short-lived climate forcer. pages 8889–8973.
- Montes de Oca, L., Tricio, V., Pierre, A., Cuesta, O., Sanchez, E., and Rodríguez, R. (2010). Aspectos termodinámicos de la meteorología y su influencia en la dispersión de los contaminantes atmosféricos. *Revista Cubana de Física*, 27(2A):134–137.
- Nakada, L. Y. K. and Urban, R. C. (2020). COVID-19 pandemic: Impacts on the air quality during the partial lockdown in São Paulo state, Brazil. *Science of the Total Environment*, 730:139087.
- NASA (2020). Airborne nitrogen dioxide plummets over china. Disponible: <https://earthobservatory.nasa.gov/images/146362/airborne-nitrogen-dioxide-plummets-over-china>.

- Peralta, O., Ortínez-Alvarez, A., Basaldud, R., Santiago, N., Alvarez-Ospina, H., de la Cruz, K., Barrera, V., de la Luz Espinosa, M., Saavedra, I., Castro, T., Martínez-Arroyo, A., Páramo, V. H., Ruíz-Suárez, L. G., Vazquez-Galvez, F. A., and Gavilán, A. (2019). Atmospheric black carbon concentrations in Mexico. *Atmospheric Research*.
- Peralta, O., Ortínez-Alvarez, A., Torres-Jardón, R., Suárez-Lastra, M., Castro, T., and Ruíz-Suárez, L. G. (2020). Ozone over Mexico City during the COVID-19 pandemic. *Science of the Total Environment*.
- Peterson, J. T. and Flowers, E. C. (1977). Interactions between air pollution and solar radiation. *Solar Energy*, 19(1):23–32.
- Ravindra, K., Rattan, P., Mor, S., and Aggarwal, A. N. (2019). Generalized additive models: Building evidence of air pollution, climate change and human health. *Environment International*, 132(March):104987.
- RUOA (2021). Observatorio atmosférico unam. Disponible: <https://www.ruoa.unam.mx/index.php?page=estacionesid=1>.
- SEDEMA (2017). Calidad del aire en la Ciudad de México. Informe 2016. (Canal 5):1–48.
- SEDEMA (2018). Calidad del aire en la ciudad de Mexico, Informe 2017.
- SEDEMA (2021a). Bases de datos - red automática de monitoreo atmosférico (rama). Disponible: <http://www.aire.cdmx.gob.mx/default.php?opc=%27aKBh%27>.
- SEDEMA (2021b). Principales generadores de emisiones en la cdmx. Disponible: <http://www.aire.cdmx.gob.mx/default.php?opc=%27ZKBhnmWkYg==%27>.
- Seinfeld, J. and Pandis, S. (2006). *Atmospheric: From Air Pollution to Climate Change SECOND EDITION*. John Wiley and Sons.

- SEMOVI (2021). Movilidad durante la emergencia sanitaria covid-19. Disponible: <https://www.semovi.cdmx.gob.mx/tramites-y-servicios/transparencia/preguntas-frecuentes/preguntas-frecuentes-covid-19/movilidad-durante-la-emergencia-sanitaria-covid-19?text=En%20general%2C%20desde%20el%20martes,y%20el%2080%25%20menor>).
- Sharma, S., Zhang, M., Anshika, Gao, J., Zhang, H., and Kota, S. H. (2020). Effect of restricted emissions during COVID-19 on air quality in India. *Science of the Total Environment*, 728:138878.
- Sillman, S. (1999). The relation between ozone, NO<sub>x</sub> and hydrocarbons in urban and polluted rural environments. *Atmospheric Environment*, (1):33–1821.
- Silva, P. F., Suárez, M., and Quiroz, H. (2018). *La movilidad en la ciudad de México. Impactos, Conflictos y Oportunidades*, volume 934.
- Solberg, S., Walker, S. E., and Schneider, P. (2018a). Trends in measured NO<sub>2</sub> and PM: Discounting the effect of meteorology. *Eionet Report – ETC/ACM 2018/9*.
- Solberg, S., Walker, S.-E., Schneider, P., Guerreiro, C., and Colette, A. (2018b). Discounting the effect of meteorology on trends in surface ozone: Development of statistical tools. *ETC/ACM Technical paper 2017/15*, pages 1–62.
- SSalud (2020). Inicia fase 2 por coronavirus covid-19. Disponible: <https://coronavirus.gob.mx/2020/03/24/inicia-fase-2-por-coronavirus-covid-19/>.
- Stull, R. B. (1988). *An introduction to boundary layer meteorology - Par Roland B. Stull*, volume 8.
- Von Schneidmesser, E., Monks, P. S., Allan, J. D., Bruhwiler, L., Forster, P., Fowler, D., Lauer, A., Morgan, W. T., Paasonen, P., Righi, M., Sindelarova, K., and Sutton, M. A. (2015). Chemistry and the Linkages between Air Quality and Climate Change. *Chemical Reviews*, 115(10):3856–3897.

WHO (2018). Burden of disease from ambient air pollution for 2016. pages 1–4.

Wilder-Smith, A. and Freedman, D. O. (2020). Isolation, quarantine, social distancing and community containment: Pivotal role for old-style public health measures in the novel coronavirus (2019-nCoV) outbreak. *Journal of Travel Medicine*, 27(2):1–4.

Wood, S. N. (2017). *Generalized additive models: An introduction with R, second edition*.

World Health Organization, W. (2005). WHO Air quality guidelines for particulate matter, ozone, nitrogen dioxide and sulfur dioxide. pages 1–21.

Yoshikado, H. and Tsuchida, M. (1996). High Levels of Winter Air Pollution under the Influence of the Urban Heat Island along the Shore of Tokyo Bay. *Journal of Applied Meteorology and Climatology*, pages 68–70.

# Apéndice A

## Meteorología 2020

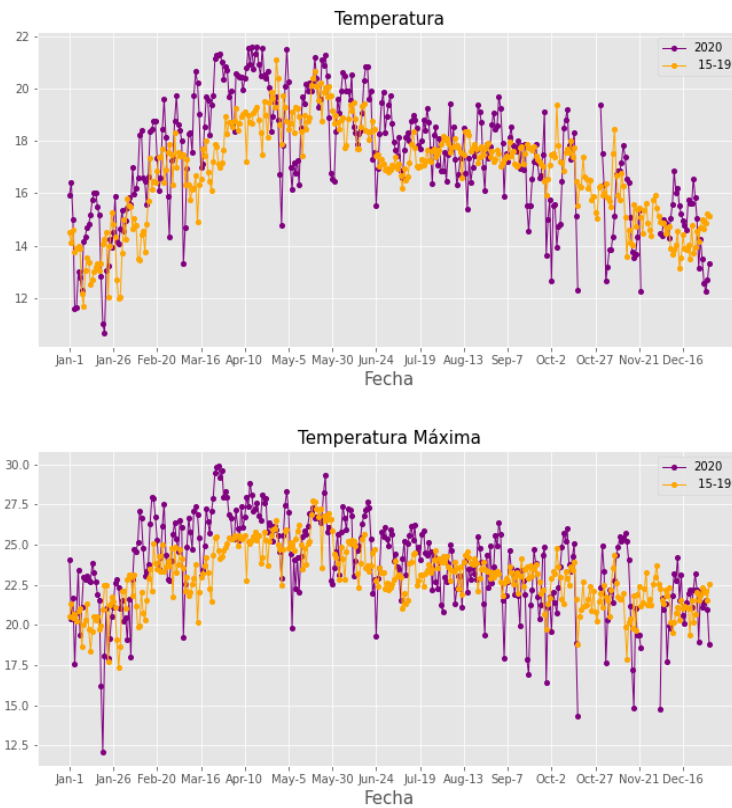


Figura A.1: Temperatura máxima 2020 y promedio 2015-2019




Figura A.2: Radiación: 2020 y promedio 2015-2019




Figura A.3: Humedad relativa: 2020 y promedio 2015-2019




Figura A.4: Velocidad del viento: 2020 y promedio 2015-2019

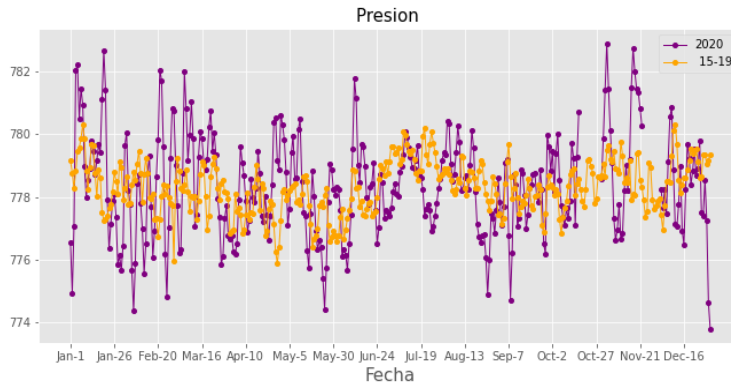


Figura A.5: Presión: 2020 y promedio 2015-2019