

N.º 22/09

Documento de trabajo

México | ¿El confinamiento por COVID-19 redujo la contaminación del aire?

Luis Antonio Espinosa Carrasco,
Juan José Li Ng

Ciudad de México, octubre 2022

México | ¿El confinamiento por COVID-19 redujo la contaminación del aire?

Luis Antonio Espinosa Carrasco, Juan José Li Ng

Se estiman modelos de datos diarios en panel para cuantificar si las medidas de confinamiento y reducción de actividades económicas implementadas por la pandemia por COVID-19 impactaron en la reducción de contaminantes en el aire de la Zona Metropolitana del Valle de México (ZMVM). La base de comparación se construyó con datos de 2015 a 2019, se analizaron 5 trimestres: de 2T2020 a 2T2021 y se controló por variables atmosféricas. Se verificó la ausencia de raíces unitarias por la prueba Im-Pesaran-Shin, se validó la cointegración de las series por las pruebas Pedroni, Kao y Westerlund, y los modelos en panel se estimaron con errores estándar de Driscoll-Kraay. Se encontró que en el segundo (2T) y tercer trimestre (3T) de 2020 disminuyó la concentración de los contaminantes NOX (-35%, -19%), NO (-65%, -21%), NO2 (-25%, -18%), SO2 (-26%, -33%), PMCO (-13%, -26%) y CO (-13%, sin efecto). Sin embargo, en 2T aumentó O3 en +17% y no cayeron las de PM2.5 y PM10, aunque estos dos contaminantes tuvieron variaciones de -19% y -13% en 3T. Adicionalmente, se calcularon las elasticidades ante cambios en la movilidad en el periodo analizado: los contaminantes NOX, NO, NO2, SO2, PMCO y CO tuvieron elasticidades de entre -1.47% y -0.40%, el O3 de +0.37%, y para PM2.5 y PM10 no fueron significativas. Llegamos a la conclusión que la reducción de la movilidad en la ZMVM lleva a la mejora en la calidad del aire al reducir la contaminación por NOX, NO, NO2, SO2, PMCO y CO; pero para controlar las concentraciones de O3, PM2.5 y PM10 se requieren estrategias complementarias que atiendan las fuentes de área (emisiones domésticas, de solventes, de residuos, etc.).

Palabras clave: Contaminación del aire, Calidad del aire, COVID-19, modelo econométrico, datos en panel.

Clasificación JEL: Q53, C52, J6.

Mexico | Did the COVID-19 lockdown reduce air pollution?

Luis Antonio Espinosa Carrasco, Juan José Li Ng

Daily panel data models are estimated to quantify whether the measures of confinement and reduction of economic activities implemented by the COVID-19 pandemic had an impact on the reduction of pollutants in the air of the Metropolitan Zone of the Valley of Mexico (ZMVM). The comparison base was built with data from 2015 to 2019, 5 quarters were analyzed: from 2Q2020 to 2Q2021 and we controlled by atmospheric variables. The absence of unit roots was verified by Im-Pesaran-Shin test, the cointegration of the series was validated by Pedroni, Kao and Westerlund tests, and panel models were estimated with Driscoll-Kraay standard errors. It was found that in the 2nd (Q2) and 3rd quarter (Q3) of 2020 the concentration of pollutants NOX (-35%, -19%), NO (-65%, -21%), NO2 (-25%, -18%), SO2 (-26%, -33%), PMCO (-13%, -26%) and CO (-13%, no effect) decreased. However, in Q2 O3 increased by +17% and PM2.5 and PM10 did not fall, although these two pollutants had variations of -19% and -13% in Q3. Additionally, the elasticities were calculated in the face of changes in mobility during the analyzed period: the pollutants NOX, NO, NO2, SO2, PMCO and CO had elasticities of between -1.47% and -0.40%, O3 of +0.37%, and for PM2.5 and PM10 were not significant. We conclude that the reduction of mobility in the ZMVM leads to an improvement in air quality by reducing the pollution through NOX, NO, NO2, SO2, PMCO and CO; but to control the concentrations of O3, PM2.5 and PM10, complementary strategies that address area sources (domestic emissions, solvents, waste) are required.

Keywords: Air pollution, Air quality, COVID-19, Econometric model, Panel data.

JEL classification: Q53, C52, J6.

Índice

Introducción	4
1. La calidad del aire en la ZMVM y sus fuentes de contaminantes.....	5
1.1. La medición de la calidad del aire	5
1.2. Principales fuentes de contaminantes en la ZMVM	6
2. Variables y disponibilidad de datos.....	8
2.1. Fuente de información	8
2.2. Variables dependientes: los contaminantes	9
2.3. Variables de control: condiciones atmosféricas	10
2.4. Disponibilidad de datos.....	12
3. Metodología	14
3.1. Pruebas de raíces unitarias	14
3.2. Cointegración.....	14
3.3. Modelo de datos panel.....	15
4. Resultados: La calidad del aire durante la pandemia.....	17
4.1. Variables de control	17
4.2. Efectos de la pandemia en la calidad del aire	17
5. Elasticidad de los contaminantes ante cambios en la movilidad.....	22
6. Conclusiones y consideraciones finales	25
7. Referencias	27
8. Anexos	31
8.1. Pruebas de raíces unitarias	31
8.2. Pruebas de cointegración	32
8.3. Estimaciones de los modelos de panel de datos	33
8.4. Concentraciones históricas de ozono en la ZMVM	42

Introducción

De acuerdo con datos del Censo de Población y Vivienda, en las 16 demarcaciones territoriales de la Ciudad de México residían 9.2 millones de habitantes en 2020 (Inegi, 2021). Si se considera a la Zona Metropolitana del Valle de México (ZMVM) definida por el Consejo Nacional de Población (Conapo, 2018), que además incluye a 59 municipios del Estado de México y 1 de Hidalgo, la población en esta área geográfica asciende a 21.8 millones de habitantes, siendo una de las urbes más grandes a nivel mundial. Al menos desde finales de la década de los setenta, como reflejo de los movimientos ambientales a nivel internacional, la calidad del aire ha sido de gran importancia para las autoridades y para la población que la habita en la ZMVM.

El reporte Air Quality Life Index 2022 elaborado por la Universidad de Chicago estima que un habitante promedio en México podría ganar 1.1 años más en la esperanza de vida de reducirse la contaminación a los estándares de la Organización Mundial de la Salud (OMS) (Greenstone, Hasenkopf, & Lee, 2022). La estrategia para la restauración de una calidad del aire “buena” ha derivado en un proceso paulatino en el que se han considerado diversas medidas. Por ejemplo, algunas de las acciones han sido la reducción del uso de combustibles de alta contaminación o muy volátiles, la aprobación de la norma para establecer los niveles de concentración máximos para contaminantes, el programa de Verificación Vehicular Obligatorio y el programa Hoy No Circula. En específico, el programa Hoy No Circula, impone restricciones a la movilidad para reducir las concentraciones de los contaminantes normados. El Inventario de Emisiones de la ZMVM sustenta dicho programa a través de la identificación del sector transporte como una de las principales fuentes de contaminantes (Sedema, 2021).

Durante los inicios de la pandemia por COVID-19, en México como en muchos otros países en el mundo se implementaron medidas de confinamiento y distanciamiento social para disminuir los contagios ocasionados por el nuevo coronavirus. Entre las acciones realizadas se encuentran: confinamiento domiciliario, cierre de escuelas y de comercios considerados no esenciales, suspensión de eventos culturales y deportivos, cierre de oficinas y corporativos, restricciones a la movilidad interna, prohibiciones de traslados internacionales, entre otros. Al tomar en cuenta la reducción extraordinaria de la movilidad al interior de la ZMVM como consecuencia de las medidas de restricción por la pandemia de COVID-19, los primeros trimestres de 2020 se plantean como una oportunidad para analizar un periodo específico de reducción excepcional de fuentes de contaminantes.

El objetivo de la investigación es analizar el efecto agregado de las medidas de distanciamiento social, restricciones a la movilidad y cierre de actividades económicas que se implementaron de manera drástica a causa de la pandemia por COVID-19 sobre las concentraciones de contaminantes de la ZMVM. Para tal objetivo se realiza un conjunto de modelos de datos panel para identificar los cambios existentes entre el nivel base de contaminantes que se ha tenido en los diferentes años previos a la pandemia, y poder compararlo con las condiciones específicas observadas desde el inicio de la pandemia hasta el segundo trimestre de 2021, que son los principales periodos en que se observan las mayores afectaciones a la movilidad en la ZMVM.

El documento está conformado por seis apartados. El primer apartado analiza la forma en que se realiza la medición de la calidad del aire en la ZMVM y se da cuenta del inventario de emisiones la cual determina las principales fuentes de contaminantes del aire. En el segundo apartado, se describen las fuentes de información, las variables dependientes y de control, y la selección de los datos a estudiar en los modelos. Posteriormente, se discute la metodología utilizada para la estimación de los modelos de datos panel de los contaminantes y las pruebas de raíz unitaria y cointegración realizadas. El cuarto apartado presenta los principales resultados de los efectos de la pandemia sobre la concentración de contaminantes en la ZMVM y se comparan con estudios en otras geografías, y en el quinto apartado, se muestra un análisis de elasticidades de los contaminantes ante los cambios en la movilidad. Finalmente, en el último apartado se plantean las conclusiones del trabajo y algunas consideraciones al respecto de la investigación.

1. La calidad del aire en la ZMVM y sus fuentes de contaminantes

1.1. La medición de la calidad del aire

Uno de los eventos más emblemáticos del siglo pasado, en términos de la contaminación del aire, fue el conocido como “The Great Smog of London” de 1952, donde dicha ciudad se cubrió de una neblina de contaminación por 5 días, ocasionando el deceso estimado de 12,000 personas a causa de problemas respiratorios (Martínez, 2021). Al menos desde ese suceso y durante la década de los sesenta, se conformó un movimiento ambiental moderno a nivel internacional producto de los eventos de elevados niveles de smog en diversas urbes (como el mencionado ocurrido en Londres y en ciudades como Nueva York) y la evidente degradación del medio ambiente después de la Segunda Guerra Mundial, lo que dio un fuerte impulso a la presión política para atender la problemática ambiental (Hays, 1981).

Las presiones dieron lugar a cambios políticos y sociales como la aprobación de legislaciones para abatir la contaminación del aire como los Clean Air Act en Reino Unido en 1956 y en Estados Unidos en 1970. En 1972 fue publicado el célebre informe “Los Límites del Crecimiento” por el Club de Roma, en el que se establece que el desequilibrio en los niveles de crecimiento poblacional, industrial y de contaminantes nos llevarían a un estado estacionario y una incontrollable disminución de la población y la capacidad industrial (Meadows, Meadows, Randers, & Behrens III, 1972).

En ese contexto, México dio un primer paso en favor de la política ambiental con la aprobación de la Ley Federal para Prevenir y Controlar la Contaminación Ambiental en 1971, como respuesta a los movimientos ambientales que se estaban gestando en esa época (Velazquez, 2010). A raíz de esta preocupación, en 1977, la Subsecretaría de Mejoramiento del Ambiente diseñó el índice Mexicano de Calidad del Aire (Imexca) con el objetivo de informar a la población de la Ciudad de México sobre los niveles de contaminación (SSA, 1978). Posteriormente, en 1982, se diseñó el Índice Metropolitano de la Calidad del Aire (Imeca) para conocer el nivel de contaminación y posibles afectaciones a la salud, el cual se continúa utilizando a la fecha (CAME, 2018).

De esta forma, con el objetivo de cumplir con los criterios internacionales de la Organización Mundial de la Salud OMS y la Agencia de Protección Ambiental de los Estados Unidos (EPA), se instaló la Red Automática de Monitoreo Atmosférico (RAMA) en 1984, e inició su operación en 1986 con múltiples estaciones en la ZMVM (Sedesol, 1992). A la fecha, en dichas estaciones se registran las concentraciones de los contaminantes a tomar en cuenta para estimar la evolución de la calidad del aire.


Con los datos provenientes de las estaciones, la Comisión Ambiental de la Megalópolis (CAME) es la encargada de activar el Programa de Contingencias Ambientales Atmosféricas (PCAA), el cual se activa en el evento de un incremento de los niveles de concentración de contaminantes por encima de los límites establecidos en la Norma oficial. El programa contiene dos fases que permiten ejercer acciones inmediatas para reducir emisiones de las principales fuentes de contaminación, y evitar un agravamiento de un episodio de alta contaminación. Las acciones más comunes que ha implementado la CAME ante una contingencia ambiental son: a) Diversos niveles de restricción a la circulación del parque vehicular en la ZMVM mediante el programa Hoy No Circula y b) Suspensión de algunas actividades, como pueden ser la asistencia a las escuelas.

Entre 1988 y 2021 se han registrado 144 días de contingencia y 54 días de precontingencia ambiental, que se han distribuido a lo largo de 76 eventos de activación de protocolos de contingencia ambiental y 214 precontingencias. Cabe resaltar que los límites establecidos en la Norma oficial se han ajustado a lo largo del tiempo y de donde se

pueden distinguir al menos 4 periodos. De 1986 a 1996, donde se especifican los niveles de ozono para contingencia, pero no se definen para precontingencia. Posteriormente, de 1996 a 2006 que especifica niveles de precontingencia y contingencia de PM10. De 2006 a abril de 2016, donde se registraron 7 ajustes a la baja del límite de nivel de concentración de los contaminantes. Finalmente, de 2016 a la fecha, en el que se suspendió el uso de la fase de precontingencia y otra vez se hicieron ajustes a la baja en los límites de emisiones para la declaración de contingencia, tuvieron como consecuencia que registráramos nuevamente fases con contingencia. No obstante, los continuos ajustes a los niveles de activación de fases, los límites actuales permitidos aún se encuentran por encima de los recomendados por la OMS (2006).

La Gráfica 1, describe la distribución de los días de los eventos de alta contaminación en la Ciudad de México. En consecuencia, en el primer periodo (1986 a 1996) se registraron 77 días de contingencia. En el segundo periodo (1997-2006) se observaron 29 días de contingencia y 5 de precontingencia. Para el tercer periodo (2007 a abril de 2015) se tuvieron únicamente 44 días de precontingencia. Finalmente, a partir de 2016 a 2021 se han observado 38 días de contingencia y 5 días de precontingencia en 2016. En este último periodo destaca que 76.3% (29 días) de los días y eventos de contingencia fueron ocasionados únicamente por elevados niveles de ozono, siendo el contaminante de mayor preocupación en conjunto con las partículas PM10 y PM2.5.

Gráfico 1. **DÍAS DE CONTINGENCIA Y PRECONTINGENCIA AMBIENTAL EN LA ZMVM, 1988-2021 (Días)**



Nota: Los días de contingencia hacen referencia a la estimación de días en los que se activaron las restricciones especiales del programa Hoy No Circula en la mayor parte del día, es decir, se contemplan los días si el programa se implementó antes o desde las 6 am y si la desactivación tuvo efecto después de las 11 am. Los días de precontingencia de 2016 se registraron antes del cambio de la norma que entró en vigor el 6 de abril.

Fuente: BBVA Research, con información de la Sedema (2022).

1.2. Principales fuentes de contaminantes en la ZMVM

Los inventarios de emisiones de contaminantes de la ZMVM conforman el principal reporte del continuo monitoreo y evaluación de las fuentes de emisión de contaminantes derivadas de las actividades económicas. Los inventarios tienen una publicación periódica bianual, siendo la edición más reciente la publicada en 2021 (con referencia a las fuentes de contaminantes de 2018) y la más antigua la publicada en 1999 (con referencia a las fuentes de contaminantes de 1996).

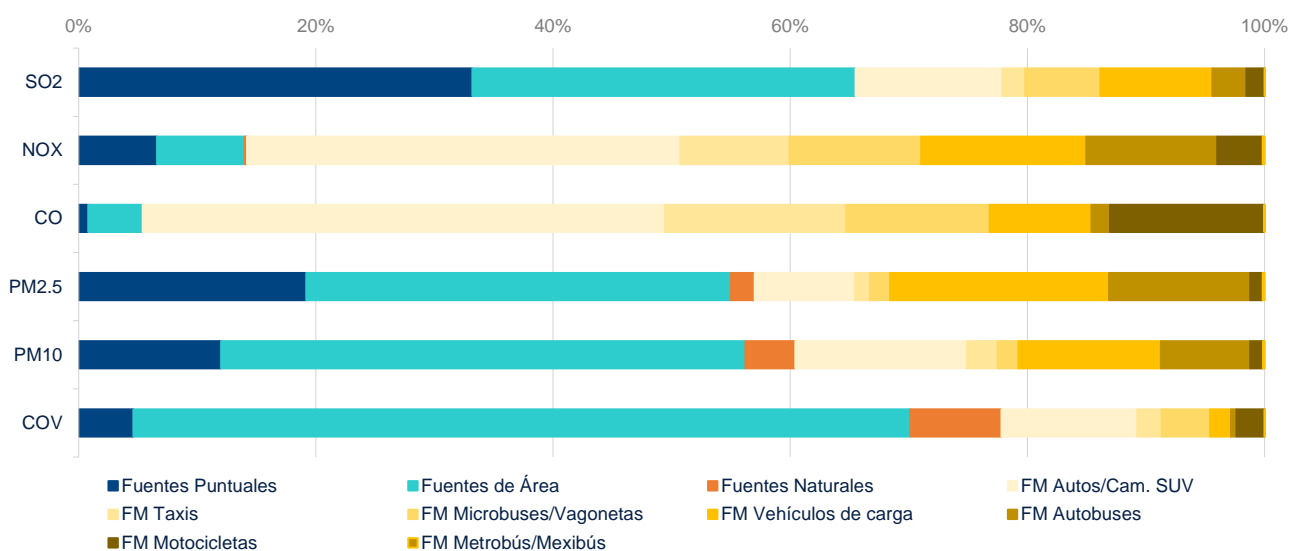
Los inventarios dan seguimiento a diversos contaminantes como lo son el dióxido de azufre (SO₂), dióxido de nitrógeno (NO₂), monóxido de carbono (CO), ozono (O₃) y partículas suspendidas menor a 10 y 2.5 micrómetros

(PM10 y PM2.5 respectivamente). Adicionalmente, se reportan otros contaminantes identificados como precursores en la formación O3 como son los compuestos orgánicos volátiles (COV) y el óxido nítrico (NO).

De acuerdo con los inventarios elaborados por la Secretaría del Medio Ambiente de la Ciudad de México (Sedema, 2021), las emisiones de los contaminantes para la ZMVM se pueden clasificar en cuatro tipos de fuentes principales:

- **Fuentes puntuales o fijas:** hacen referencia a las estimaciones de emisiones por la quema de combustibles fósiles en instalaciones de ubicación fija, que tiene como propósito ejecutar operaciones o procesos industriales, comerciales o de servicios. Incluyen a las industrias, comercios y servicios regulados.
- **Fuentes de área:** incluyen las emisiones de contaminantes a la atmósfera de instalaciones que son pequeñas, numerosas y dispersas, pero que en conjunto pueden ser considerables. La categoría está conformada por: emisiones domésticas, de combustibles, de solventes, de residuos, agrícolas y ganaderas, así como comercios y servicios no regulados.
- **Fuentes móviles:** se refiere a la estimación de las emisiones de cualquier transporte automotor que circula por las vialidades. La estimación toma en cuenta los kilómetros recorridos, el tipo de combustible y tipo de vehículo.
- **Fuentes naturales:** en esta categoría se contemplan las emisiones que se generan por procesos naturales en la vegetación y los suelos, como lo son las emisiones biogénicas (COV de vegetación y NOX de los suelos) y la erosión eólica (vegetación y suelos).

Gráfico 2. **CONTRIBUCIÓN PORCENTUAL DE EMISIONES DE CONTAMINANTES SELECCIONADOS PARA LA ZMVM, 2018 (%)**



Fuente: BBVA Research a partir de datos de Sedema (2021), Inventario de Emisiones de la Zona Metropolitana del Valle de México, 2018.

Como se observa en la Gráfica 2, las fuentes móviles fueron las que contribuyeron en mayor medida a la emisión de PM2.5 (43.0%), la segunda en la contribución de PM10 (39.6%) y de COV (22.2%). Las fuentes de área emitieron 35.8% de las PM2.5, 44.2% de las emisiones de PM10 y el 65.5% de las emisiones COV.

Específicamente, el documento apunta que, dentro de las fuentes móviles, las unidades pesadas a diésel y los vehículos particulares a gasolina son los principales contribuyentes de partículas suspendidas y de contaminantes como NOX. Se destaca que, las unidades a diésel generaron 30.4% de las PM2.5, 18.8% de las PM10 y 21.2% de las emisiones de NOX. En cuanto que los vehículos particulares a gasolina tuvieron una contribución de 12.3% de las PM2.5, 20.6% de las PM10.

Finalmente, dichos resultados apuntan a que las restricciones en movilidad de la población podrían tener un impacto positivo sobre el nivel de contaminantes en la ZMVM, observándose una reducción de esos niveles al tener un sector de transporte más eficiente y menos numeroso en las vialidades, como se sugiere por ejemplo con la implementación de los programas de Verificación Vehicular Obligatorios y Hoy No Circula o con la propuesta de renovación de la flota de transportes a diésel y extensión del sistema de transporte público de alta capacidad como el Metrobús (Sedema, Smagem, Semarnath, & Semarnat, 2021). No obstante, las fuentes de área también tienen una importante contribución en la emisión de contaminantes, pero debido a su naturaleza diversa, las acciones implementadas para reducir las emisiones de esta fuente no pueden ser tan generalizables; en este caso, el documento sugiere impulsar normas que limiten el contenido de COV en productos y programas que atiendan las fugas de gas L.P. en viviendas, comercios, industrias y servicios.

2. Variables y disponibilidad de datos

2.1. Fuente de información

Los datos de las variables dependientes e independientes provienen de la información que genera el Sistema de Monitoreo Atmosférico de la Ciudad de México (Simat), el cual ha trabajado de manera ininterrumpida los últimos 35 años y permite la medición de contaminantes, así como de diversos parámetros meteorológicos. En 2021, el Simat contaba con 44 sitios o estaciones de monitoreo en operación distribuidos en la ZMVM (Sedema, Smagem, Semarnath, & Semarnat, 2021), que están subdivididos en cuatro subsistemas:

- La Red Automática de Monitoreo Atmosférico (RAMA), que mide los niveles de concentración de contaminantes mediante 34 estaciones.
- La Red Manual de Monitoreo atmosférico (REDMA), que registra los valores de concentración en muestras de partículas suspendidas mediante 9 estaciones.
- La Red de Meteorología y Radiación Solar (REDMET), la cual, mediante 28 estaciones, reporta parámetros meteorológicos como temperatura ambiente, velocidad y dirección del viento, radiación solar, humedad relativa y presión barométrica.
- La Red de Depósito Atmosférico (REDDA), que recolecta muestras de depósito seco y depósito húmedo para monitorear el impacto de la contaminación en el suelo y fenómenos de precipitación, a través de 16 estaciones.

La administración, operación y el mantenimiento del Simat, están a cargo del gobierno de la Ciudad de México, y se rigen bajo la Norma NOM-156-SEMARNAT-2012.

2.2. Variables dependientes: los contaminantes

A continuación, se presentan las características básicas de los agentes contaminantes que se captan en las estaciones de monitoreo y que se analizan en el artículo. La información corresponde a las descripciones de contaminantes en los informes anuales de calidad del aire de la Ciudad de México (Sedema, 2012, 2018, 2020).

Dióxido de azufre (SO₂). Gas incoloro, de olor irritante muy estable, soluble en agua. Se forma principalmente durante la combustión de compuestos que contienen azufre (gasolina, carbón, diésel) y la manufactura química. La exposición aguda a altas concentraciones puede ocasionar dificultad para respirar e irritación severa de las vías respiratorias a corto plazo; mientras que a largo plazo puede vulnerar el sistema inmunológico, ocasionar enfermedades respiratorias como la bronquitis y agravar enfermedades cardiovasculares y respiratorias preexistentes.

Óxidos de Nitrógeno (NOX). Familia de compuestos químicos (NO, NO₂, N₂O, NO₃, N₂O₃, N₂O₄ y N₂O₅) presentes habitualmente en altas concentraciones en la capa baja de la troposfera e identificados como precursores de ozono. Existen diversas afectaciones respiratorias relacionadas con los NOX y particularmente con el NO₂, también son considerados como precursores de la formación de lluvia ácida, y de conllevar consecuencias negativas a la vegetación y cuerpos de agua. Los óxidos de nitrógeno provenientes de fuentes antropogénicas se generan principalmente por la quema de combustibles fósiles, así como la quema de biocombustibles y biomasa. Para efectos del monitoreo de los contaminantes prioritarios, se reportan principalmente dos:

- **Monóxido de nitrógeno (NO).** Gas penetrante de olor dulce a temperatura ambiente, no es inflamable y su color tiende al pardo.
- **Dióxido de nitrógeno (NO₂).** Gas tóxico e irritante de color rojo pajizo, con capacidad de reaccionar fácilmente con el agua para producir ácido nítrico y óxido nítrico. La exposición a altas concentraciones de este contaminante ocasiona irritación en las vías respiratorias, daño en la membrana celular del tejido pulmonar y agrava los síntomas en personas con enfermedades respiratorias crónicas.

Monóxido de carbono (CO). Gas inodoro, incoloro e insípido, poco soluble en agua, producido principalmente durante la combustión incompleta de compuestos que contienen carbono (gas natural, gas propano, gasolina, petróleo, queroseno, madera o carbón), así como la quema de biomasa y subproductos durante los procesos oxidativos para obtener sustancias químicas. Es altamente tóxico para los seres humanos y en exposiciones a altas concentraciones durante periodos relativamente cortos puede provocar la muerte.

Ozono (O₃). Gas incoloro, que desprende un olor intenso (metálico y picante), altamente oxidante e inestable en altas concentraciones. Existe principalmente en dos capas de la atmósfera: la estratosfera (capa superior) y troposfera (nivel del suelo a ~ 10-15 km). En la estratósfera, la fuerte absorción de la radiación ultravioleta (UV-B) es benéfica para la vida en el planeta; sin embargo, el ozono en la troposfera (al nivel del suelo) es un contaminante del aire nocivo para los seres humanos y las plantas (WMO & UNEP, 2011).

Las partículas suspendidas hacen referencia a cualquier material sólido o líquido capaz de permanecer en suspensión en el aire ambiente por medios físicos o mecánicos. De acuerdo con su tamaño, varían de 1 nm a 10 mm de diámetro:

- **Partículas finas y ultrafinas (PM2.5).** La suma de las partículas ultrafinas (menos de 100 nm de diámetro o <math> < 0.1 \mu\text{m}</math>) y finas de 100 a 2,500 nm de diámetro (0.1 - 2.5 $\mu\text{m}</math>) se le conoce como PM2.5. Son emitidas durante la combustión de diésel, combustóleo o carbón y producidas a partir de la condensación de los gases de combustión de los vehículos a gasolina. Debido a que ingresan al sistema respiratorio profundo, en consecuencia, este contaminante tiene afectaciones a corto y largo plazo.$
- **Partículas gruesas y finas (PM10).** La suma de las partículas menores a 10 $\mu\text{m}</math> de diámetro se denominan PM10. Estas partículas son generadas principalmente por la resuspensión del polvo del suelo, la minería y el tráfico de las carreteras.$
- **Partículas de fracción gruesa (PMCO).** Son aquellas partículas de entre 2.5 a 10 $\mu\text{m}</math>.$

La Tabla 1 muestra los valores promedio anuales de los contaminantes en la ZMVM en el periodo analizado: Se observa que los contaminantes SO₂, CO, NO, NO₂, NO_X muestran valores menores en los últimos años a comparación de 2015; sin embargo, las concentraciones de O₃, PM₁₀, PM_{2.5} y PMCO se han mantenido relativamente estables durante prácticamente todo el periodo.

Tabla 1. **CONCENTRACIÓN PROMEDIO ANUAL DE LOS CONTAMINANTES PARA LA ZMVM, 2015-2021**

Contaminante	2015	2016	2017	2018	2019	2020	2021
SO ₂ (ppb)	4.4	4.3	4.6	4.2	3.3	3.3	3.2
CO (ppm)	0.7	0.6	0.6	0.4	0.4	0.3	0.4
NO (ppb)	19	17	17	16	13	11	11
NO ₂ (ppb)	26	25	26	25	22	19	20
NO _X (ppb)	45	42	42	41	36	30	32
O ₃ (ppb)	28	30	31	30	31	32	33
PM ₁₀ ($\mu\text{g}/\text{m}^3$)	43	43	46	43	43	38	44
PM _{2.5} ($\mu\text{g}/\text{m}^3$)	24	22	23	23	23	19	21
PMCO ($\mu\text{g}/\text{m}^3$)	19	20	22	21	20	18	20

Fuente: BBVA Research a partir de datos de la Sedema, Dirección de Monitoreo Atmosférico.

2.3. Variables de control: condiciones atmosféricas

Las condiciones atmosféricas tienen un efecto directo sobre la calidad del aire; ya que, regulan el transporte, dispersión y acumulación de los contaminantes y los procesos fotoquímicos (Sedema, 2012). Dependiendo de las condiciones atmosféricas específicas se puede distinguir su influencia a corto y largo plazo. En ese sentido, la categoría de “tiempo” hace posible distinguir entre los cambios de corto plazo en el estado de la atmósfera que hacen referencia a los factores de temperatura, humedad relativa, etc.; y “clima” que es la categorización del conjunto de los registros del estado de la atmósfera en una ventana amplia de tiempo.

El tiempo en la ZMVM es monitoreado periódicamente a lo largo de todos los días mediante las estaciones meteorológicas. Dentro de las características atmosféricas que mide se tomaron para el presente estudio cuatro variables de control (SMN, 2021):

- **Temperatura (TMP).** Reportada en grados Celsius o Centígrados (°C), es una medida del movimiento molecular que parte de escalas arbitrarias a partir del cero absoluto (-273.15°C), donde, teóricamente, las moléculas ya no presentan movimiento. La temperatura es uno de los principales parámetros que definen las temporadas climáticas de una zona geográfica.
- **Humedad Relativa (RH).** Medida con el higrómetro y expresada en porcentaje de saturación. La humedad relativa se refiere a la relación entre la cantidad de vapor de agua que contiene el aire y el máximo que es capaz de contener a una determinada temperatura.
- **Velocidad del viento (WSP).** Hace referencia al promedio del movimiento del aire durante un lapso determinado y su unidad de medida son los metros por segundo (m/s). La dispersión de los contaminantes tiene una influencia relevante a esta variable.
- **Precipitaciones pluviales (PP).** Hacen referencia a fenómenos como la lluvia, granizo, aguanieve, entre otros. Este fenómeno elimina una parte importante de los contaminantes suspendidos en la atmósfera, mediante el proceso denominado lavado atmosférico.

La incidencia de estas variables depende del tipo de contaminante y la región en que se esté analizando. No obstante, existen relaciones estables entre las variables meteorológicas y los niveles de concentración de contaminantes. De acuerdo con la literatura (Lu, Zhang, & Shen, 2019; Coates et al., 2016; Ramasamy et al., 2013; Sedema, 2018), en el caso de las cuatro variables control utilizadas se señala que:

La **temperatura (TMP)** tiene una relación positiva (+) con los niveles de concentración de contaminantes, ya que incide en el movimiento de las corrientes de aire evitando el desplazamiento de los contaminantes a capas superiores de la atmósfera. Adicionalmente, las temperaturas altas, asociadas a los días soleados, benefician las reacciones químicas en el aire generadoras de ozono. Por otra parte, la **humedad relativa (RH)** tiene principalmente una relación negativa (-) con respecto a los contaminantes de aire, ya que un nivel elevado de humedad está relacionado con un ambiente más frío y presencia de nubes que bloquea la luz del sol y disminuyen las reacciones químicas en el aire, así como también a la temporada de lluvias. La **velocidad de viento (WS)** también tiene una relación negativa (-), por un lado, la presencia de viento fuerte (es decir que alcanza altas velocidades) propicia una mejor dispersión de los contaminantes; por otro lado, se limita la dispersión de los contaminantes con la existencia de vientos débiles. En el caso de **precipitaciones pluviales (PP)** esta variable guarda una relación negativa (-) también con los niveles de concentración de contaminantes; ya que, las lluvias generan un proceso de lavado atmosférico en el cual los contaminantes que se encuentran en el aire caen al piso y debido al medio acuoso ya no existe una resuspensión de los mismos.

Cabe resaltar que determinadas condiciones meteorológicas generan la modificación de dicha relación. Tal es el caso de la influencia de RH sobre el nivel de concentración de los contaminantes en las zonas con menor concentración NOX (menos urbanas) y con mayores concentraciones de NOX (más urbanas). En el primer caso la mayor cantidad de vapor de agua inhibe la reacción química que produce contaminantes como el ozono y mantiene una relación negativa, en el segundo caso, la relación se vuelve positiva al beneficiar la producción de ozono y otras reacciones químicas. Los trabajos de Dawson & Pandis (2007) para EE. UU. y el trabajo de Horne & Dabdub (2017) para el caso de California son algunos ejemplos donde estos patrones han sido documentados. También es el caso de la velocidad del viento (WS), la relación se puede tornar negativa en donde un incremento de dicha variable en ciertas regiones podría generar el transporte de contaminantes de una región de alta contaminación a otra región de baja contaminación.

De forma específica, se presentan de forma resumida las relaciones base que existen en los contaminantes analizados. Se destaca el caso de las partículas suspendidas (PM) ya que, diversos estudios han mostrado que la correlación con las variables meteorológicas parece tener una fuerte variación estacional y regional (Yang et al., 2017). Adicionalmente, en el caso de la correlación de la variable de humedad relativa y partículas suspendidas, la relación es predominantemente positiva; sin embargo, hay factores que contribuyen a que la relación se modifique después de un nivel de humedad relativamente alto; esto debido a que esto podría representar lluvia e iniciar un proceso de lavado atmosférico, o sobretodo en el caso de las PM_{2.5} la humedad se adhiere a las partículas dándoles suficiente peso para caer al piso (Hernández et al., 2017; Wang & Ogawa, 2015). En la tabla se muestra en primer lugar la correlación más prevalente.

Tabla 2. **TIPO DE RELACIÓN ENTRE LA CONCENTRACIÓN DE CONTAMINANTES Y LAS VARIABLES METEOROLÓGICAS DE CONTROL**

Contaminante	Precipitaciones pluviales	Humedad relativa	Temperatura	Velocidad del viento
SO ₂ , NO _x , CO, O ₃	(-)	(-)	(+)	(-)
PM ₁₀ , PM _{2.5}	(-)	(+) / (-)	(-)	(-)

Fuente: BBVA Research.

2.4. Disponibilidad de datos

Se construyó un panel de datos con información diaria entre el 1º de enero de 2015 al 30 de junio de 2021. Los datos de las variables dependientes y de control generalmente se tienen por hora, por lo que se promediaron para obtener el dato del día en las estaciones de monitoreo. El dato de precipitaciones pluviales no se tuvo por estación de monitoreo, por lo que se usó el promedio diario de la Ciudad de México.

Como se puede percatar en el apartado anterior de fuentes de información, no todos los sitios de monitoreo cuentan con todos los sistemas o aparatos para medir todos los contaminantes analizados o las variables de control necesarias para el panel. Adicionalmente los sistemas o aparatos de medición sufren desperfectos, requieren mantenimiento o se descomponen, por lo que generalmente hay faltantes de datos tanto en las series de tiempo como en las variables. En el periodo analizado, de enero de 2015 a junio de 2021 no existe ninguna serie de tiempo que tenga el 100% de datos completos para al menos una variable en alguna estación de monitoreo. La serie con mayor completitud tuvo un 98.5% de datos.

Para garantizar estimaciones con la mayor calidad posible se analizaron los porcentajes de información disponible en un arreglo en tres dimensiones: 1) estación de monitoreo, 2) año y 3) variable. A partir de este análisis de calidad de la información:

1. Se descartaron como posibles variables de control las de Presión atmosférica y Rayos ultravioleta (UVA y UVB), debido a la escasa información disponible en el periodo analizado.
2. Se descartaron las estaciones de monitoreo que no contaban con un porcentaje aceptable de datos completos para las variables atmosféricas TMP, RH y WSP.
3. Se descartaron las estaciones de monitoreo con información deficiente o faltante para 5 o más de los 9 contaminantes que se busca analizar.

4. Tras valorar las estaciones de monitoreo, caso por caso, se eligieron finalmente 16 estaciones.
5. Para cada uno de los 9 contaminantes, se identificaron de entre las 16 estaciones seleccionadas aquellas que contaban con la mayor completitud de información. Así, el panel de la variable de SO2 se construyó con datos de 16 estaciones, mientras que el panel de la variable PMCO solamente 6 estaciones. Las variables de partículas suspendidas tuvieron menos estaciones con información adecuada para el análisis.

En la Tabla 2 se muestran las estaciones de monitoreo seleccionadas, así como las variables que se usaron de cada una de éstas en la construcción del panel de datos.

Tabla 3. **ESTACIONES DE MONITOREO SELECCIONADAS Y VARIABLES UTILIZADAS EN LOS MODELOS DE DATOS PANEL POR ESTACIÓN**

Entidad	Clave	Estación de monitoreo	Variables dependientes									Variables de control		
			SO2	NOX	NO	NO2	CO	O3	PM10	PM25	PMCO	RH	TMP	WSP
CDMX	bjv	Benito Juárez	Sí	-	-	-	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí
Edo Mex	cut	Cuautitlán	Sí	Sí	Sí	Sí	-	Sí	Sí	-	-	Sí	Sí	Sí
Edo Mex	fac	FES Acatlán	Sí	Sí	Sí	Sí	Sí	Sí	Sí	-	-	Sí	Sí	Sí
CDMX	mer	Merced	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí
CDMX	mgh	Miguel Hidalgo	Sí	Sí	Sí	Sí	Sí	Sí	-	-	-	Sí	Sí	Sí
Edo Mex	mon	Montecillo	Sí	Sí	Sí	Sí	Sí	Sí	-	-	-	Sí	Sí	Sí
CDMX	mpa	Milpa Alta	Sí	-	-	-	Sí	Sí	-	-	-	Sí	Sí	Sí
Edo Mex	nez	Nezahualcóyotl	Sí	Sí	Sí	Sí	Sí	Sí	-	Sí	-	Sí	Sí	Sí
CDMX	ped	Pedregal	Sí	Sí	Sí	Sí	Sí	Sí	-	-	-	Sí	Sí	Sí
Edo Mex	sag	San Agustín	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí
CDMX	sfe	Santa Fe	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí
CDMX	tah	Tláhuac	Sí	Sí	Sí	Sí	Sí	Sí	Sí	-	-	Sí	Sí	Sí
Edo Mex	tla	Tlalnepantla	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí
CDMX	uax	UAM Xochimilco	Sí	Sí	Sí	Sí	Sí	Sí	-	Sí	-	Sí	Sí	Sí
CDMX	uiz	UAM Iztapalapa	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	-	Sí	Sí
Edo Mex	vif	Villa de las Flores	Sí	Sí	Sí	Sí	Sí	Sí	Sí	-	-	Sí	Sí	Sí

Fuente: BBVA Research a partir de datos de la Sedema, Dirección de Monitoreo Atmosférico.

3. Metodología

3.1. Pruebas de raíces unitarias

Antes de realizar estimaciones con las series de datos, es importante determinar si hay presencia de raíz unitaria. La presencia de variables no estacionarias puede llevar a estimar “regresiones espurias” (Enders, 2018). Para ello, las pruebas tradicionales de series de tiempo no son las más adecuadas, debido a que las series de tiempo en este estudio forman parte de un panel de datos. Actualmente muchos paquetes estadísticos ya tienen programado varias pruebas para determinar la presencia de raíz unitaria en las series en panel. Se eligió usar la prueba de Im-Pesaran-Shin (2003) para contrastar la presencia de raíz unitaria debido principalmente a que puede usarse en paneles heterogéneos. En Barrera Ojeda (2017) se realizó simulaciones de Monte Carlos y encontró que la prueba de Im-Pesaran-Shin tiene mayor potencia que la de Levin-Lin-Chu.

Se estimaron tres especificaciones para la prueba de Im-Pesaran-Shin sobre las series originales en niveles: 1) primero se calculó con la prueba Dickey-Fuller para un AR(1), 2) posteriormente se especificaron pruebas de Dickey-Fuller Aumentada en donde el número de rezagos en las series por sección cruzada fue determinado por el Criterio de Información de Akaike (AIC), y 3) al final se repitió esta última especificación pero removiendo las medias de sección cruzada de los datos. En el anexo se presentan los resultados. En todas las especificaciones de las pruebas Im-Pesaran-Shin, tanto para las variables dependientes como de control, el p-value fue de 0.0000, lo que indica que las series en el panel de datos son estacionarias.

Si las series no hubieran sido estacionarias, hubiéramos optado por incluir variables relacionadas con la actividad humana (e.g. PIB) y/o el tamaño de la población, como posibles variables explicativas. Sin embargo, al ser estacionarias, las series de los contaminantes que se analizan muy probablemente se vieron afectados por mejoras tecnológicas, adaptativas y/o normativas que desvincularon su trayectoria de la actividad económica y/o crecimiento poblacional para el periodo y región analizados.

3.2. Cointegración

Para que las estimaciones de las variables independientes en función de las variables de control tengan sentido, las series deben cointegrar. Dado que los datos se encuentran estructurados en un panel se deben usar pruebas específicas de cointegración para estos modelos. Se realizaron las pruebas de cointegración de primera generación de Pedroni (1999) y de Kao (1999), y para robustecer los resultados, se agregó la prueba de razón de varianzas de Westerlund (2005), la cual puede incluso realizarse con problemas de dependencia de los datos de sección cruzada. Las pruebas fueron aplicadas a los datos en logaritmos, dado que son los que se usan en los modelos a estimar.

Para los nueve conjuntos de datos, que resultan de las variables dependientes, los resultados de las tres pruebas indican que las series cointegran, con p-values para los diferentes estadísticos iguales o muy cercanos a 0.0000. Se realizaron estimaciones para las series en el periodo completo y considerando únicamente los años entre 2015 a 2019. Dado que los resultados fueron muy similares, se decidió presentar solo los resultados de las pruebas de cointegración para el periodo de 2015-2019, dado que en 2020 y 2021 se presentó un choque externo, el cual este estudio tiene por objetivo cuantificar. Además, para que las series cointegren se debe de incluir en la prueba de Westerlund la tendencia lineal; así, en las especificaciones de los modelos estimados también se incluye la tendencia lineal.

3.3. Modelo de datos panel

El modelo que se estimó para cada uno de los contaminantes, los cuales no presentan problemas de raíz unitaria, considera tres conjuntos de variables explicativas: variables de carácter atmosféricas, dummies para captar el efecto estacional para cada día de la semana relacionado con la actividad humana, dummies para distinguir los trimestres de interés de la base contrafactual, y la tendencia. Las variables dependientes y las de control se transformaron en su forma logarítmica para estimar una aproximación al cambio porcentual. Para evitar la pérdida de información valiosa, los valores numéricos igual a cero se establecieron a un valor relativamente pequeño previo a aplicar el logaritmo.

Las series de tiempo de los agentes contaminantes analizados generalmente presentan un comportamiento estacional. Cuando se realizan estimaciones econométricas se tiene que controlar esta característica para que los estimadores sean insesgados, ya sea desestacionalizando las series o estimando en diferencias. En el caso particular del presente modelo, la estacionalidad fue controlada directamente por las variables de control incluidas: Temperatura (TMP), Humedad Relativa (RH), Velocidad del viento (WSP) y Precipitaciones pluviales (PP), las cuales explican directamente los factores ambientales y atmosféricos, e indirectamente los antropogénicos.

Así, la ecuación para un modelo de los efectos fijos (FEM) tendría la siguiente forma:

$$y_{i,t} = \alpha + X_{i,t}\beta + D_t\gamma + Z_t\theta + v_i + t + \epsilon_{i,t}$$

en donde:

$y_{i,t}$	es el dato del contaminante que se analiza para la estación i en el día t $y \in \{ISO2, INOX, INO, INO2, ICO, IO3, LPM25, LPM10, LPMCO\}$
α	intercepto común
$X_{i,t}$	matriz formada por los vectores columna de las variables atmosféricas en la estación i del día t , $X_{i,t} = [LRH_{i,t} \quad LTMP_{i,t} \quad LWSP_{i,t} \quad LPP_{i,t}]$
β	vector de coeficientes de las variables atmosféricas
D_t	matriz de variables dummies por día de la semana (1=lunes, excluido)
γ	vector de coeficientes de las variables dummies por día de la semana
Z_t	matriz de variables dummies para los trimestres de interés $Z_t = [2020t1 \quad 2020t2 \quad 2020t3 \quad 2020t4 \quad 2021t1 \quad 2021t2]$
θ	vector de coeficientes de las variables dummies para los trimestres de interés
v_i	intercepto desconocido propio de la estación i
t	tiempo
$\epsilon_{i,t}$	residual del dato para la estación i en el día t

Las estimaciones de un modelo panel a través de efectos fijos (fixed effects) realizan transformaciones a las series de tiempo para eliminar el efecto inobservable propio de cada elemento transversal. Así, cualquier variable explicativa que sea constante en el tiempo se elimina. Una vez especificada adecuadamente la ecuación, los modelos panel de efectos fijos restan la media v_i de las variables y las nuevas variables transformadas se pueden estimar a través de Mínimos Cuadrados Ordinarios (OLS). A las estimaciones por efectos fijos también se le conoce como transformación intergrupala (within). Cuando este efecto inobservable no está correlacionado con ninguna de las variables explicativas, es preferible usar las estimaciones por efectos aleatorios (random effects) (Wooldridge, 2010).

Si el conjunto de nuestras estaciones $i \in I$ son una muestra aleatoria de una población mayor, y las v_i no están correlacionado con $X_{i,t}$ en ningún momento del tiempo, es decir $Cov(v_i, X_{i,t}) = 0$, entonces la estimación debería realizarse a través de un modelo de efectos aleatorios (REM). Su ecuación tendría la siguiente forma:

$$y_{i,t} = \alpha + X_{i,t}\beta + D_t\gamma + Z_t\theta + t + (u_i + \varepsilon_{i,t})$$

en donde, además de las variables ya explicadas anteriormente se añaden:

u_i	término de error entre las estaciones, para la estación i en el día t
$\varepsilon_{i,t}$	término de error dentro de las estaciones, para la estación i en el día t

Al tener en el modelo un error compuesto $(u_i + \varepsilon_{i,t})$, se tendría un problema de correlación serial autorregresiva si se estimaran por OLS. Por este motivo, los modelos de efectos aleatorias se estiman a través de Mínimos Cuadrados Generalizados (GLS), a través de una transformación en el que se les resta a los datos solamente una parte del promedio estimado de las variables (Wooldridge, 2010).

A través de estos métodos, como lo indica Wooldridge (2010), los estimadores son consistentes cuando se tiene una T relativamente pequeña y una N grande. Sin embargo, para los datos que tenemos disponibles en el panel se tiene una N relativamente pequeña (de 6 a 16) y una T muy grande (hasta 2,373), por lo que las estimaciones por modelos panel clásicos no son adecuadas. Al tener una serie de tiempo larga se pueden presentar problemas de heterocedasticidad, lo cual se verificó en los modelos de efectos fijos con una prueba de Wald modificada para datos en panel. Adicionalmente se encontró, dada las características de las series de datos, la presencia de dependencia de sección cruzada (CD) o correlación contemporánea a través de las pruebas de independencia del Multiplicador de Lagrange de Breusch–Pagan (B-P LM) y de Pesaran (2021).

Para solventar estas tres características de nuestros datos en panel, y obtener estimadores consistentes, se calcularon las regresiones a través de la metodología de estimaciones con errores estándar de Driscoll & Kraay (1998). Estos autores proponen una matriz de covarianza consistente en presencia de dependencia espacial a partir de una modificación de la matriz de covarianzas no paramétricas de series de tiempo estándar. Los estimadores obtenidos son consistentes asintóticamente en T, y asumen que la estructura de los errores es heterocedástica, con algún tipo de autocorrelación y que son más eficientes en presencia de dependencia de sección cruzada que otros estimadores. A través de esta metodología se estimaron los modelos de efectos fijos y de efectos aleatorios mediante el paquete `xtsc` de Stata desarrollado por Daniel Hoechle (2007).

Otro método utilizado cuando no se pueden aplicar los modelos clásicos de panel, es a través de Mínimos Cuadrados Generalizados Factibles (FGLS). A través de esta técnica se puede estimar la ecuación del modelo de panel considerando una estructura de errores heterocedástica y con dependencia de sección cruzada. Sin embargo, no está diseñado para estimar modelos de efectos fijos o efectos aleatorios. Además, la estimación por FGLS requiere una estructura balanceada en los datos para tener mejores resultados, mientras que las estimaciones con errores estándar de Driscoll & Kraay pueden calcularse con datos no balanceados. Así, aunque se estiman y presentan las salidas de los modelos FGLS con estructura de errores heterocedásticos, en este artículo solo se analizan los resultados por Driscoll & Kraay.

4. Resultados: La calidad del aire durante la pandemia

4.1. Variables de control

Las condiciones meteorológicas son factores que tienen gran influencia sobre la calidad del aire, por eso se debe controlar por estas condiciones antes de analizar los efectos ocasionados por el confinamiento. A continuación, se comenta de forma agregada los principales hallazgos encontrados en las variables de control. De forma general, en el caso de la ZMVM las variables de control tuvieron los signos correctos y resultaron ser significativas, y cuando esto ocurría casi siempre se obtenían estimadores con significancia al 1%. No obstante, algunas correlaciones prevalentes no pudieron ser observadas en el modelo, es el caso de la temperatura con las PM2.5 y PM10, la humedad relativa y los PM10, o la velocidad del viento y el ozono.

Temperatura (TMP). Los resultados sugieren que cuando menor es la temperatura promedio en la ZMVM se registran menores niveles de concentraciones, ordenados de mayor a menor elasticidad, de: SO₂, NO, NO_x, NO₂ y CO; en cambio, una mayor temperatura aumenta los niveles de O₃. Las variaciones en la temperatura parece que no tuvieron efecto en la concentración en el aire de las partículas finas y pequeñas (PM2.5 y PM10), y solamente 1 de 2 estimaciones sugieren que una mayor temperatura aumentó la concentración de partículas gruesas (PMCO).

Humedad relativa (RH). Las estimaciones indican que los contaminantes en el aire tienden a ser menores cuando mayor es la humedad relativa. Los contaminantes que bajaron su concentración en el aire ante aumentos en la humedad relativa fueron, en orden de sensibilidad: PMCO, PM10, NO, NO_x, NO₂, O₃, CO, PM2.5 y SO₂.

Velocidad del viento (WSP). Para la mayoría de los contaminantes analizados, se encuentra que a mayor velocidad del viento menor es la concentración del contaminante en el aire de la ZMVM. Los contaminantes que redujeron su concentración, ordenados de mayor a menor elasticidad, fueron: NO, CO, NO_x, PM2.5, SO₂, NO₂, PM10 y PMCO. Los resultados para el O₃ no son concluyentes, aunque parece inclinarse más a favor de la idea de que aumenta su concentración cuando mayor es la velocidad del viento.

Precipitaciones pluviales (PP). Se encuentra que mientras mayor es el volumen de precipitaciones pluviales menor la concentración de contaminantes en el aire. Las precipitaciones pluviales disminuyeron, ordenadas de mayor a menor elasticidad, las concentraciones de: PMCO, SO₂, PM10, NO, PM2.5, NO_x, CO, NO₂; pero no tuvieron efecto en la concentración de O₃.

4.2. Efectos de la pandemia en la calidad del aire

Se presentan los resultados de los cambios en las concentraciones de contaminantes en el aire de la Ciudad de México y su área metropolitana para el periodo de cinco trimestres, comprendidos entre el segundo trimestre de 2020 (2020t2) y el segundo trimestre de 2021 (2021t2), en comparación con un escenario base contrafactual. El principal suceso de relevancia, en el periodo analizado, que afectó las concentraciones de contaminantes en el aire en la Ciudad de México y su área metropolitana (y en las principales urbes a nivel mundial) fue que a consecuencia de la pandemia por COVID-19 se implementaron medidas de confinamiento social, cierre de actividades económicas y restricciones a la movilidad, todas ellas para contener los contagios por el virus SARS-CoV-2.

Así, las estimaciones que se presentan tratan de cuantificar la disminución en la contaminación del aire originada directa e indirectamente por la pandemia por COVID-19. Para simplificar la interpretación de los resultados se consideraron únicamente los modelos de efectos fijos y efectos aleatorios con errores estándar de Driscoll &

Kraay, y se promediaron los coeficientes que resultaron significativos al 95% y 99% de confianza. Las salidas de las estimaciones se pueden consultar en el anexo, así como los coeficientes obtenidos por FGLS con estructura de errores heterocedásticos, que pueden servir para contrastar los resultados. En la Gráfica 3 se sintetizan los resultados obtenidos.

Dióxido de azufre (SO₂). Las estimaciones indican que, la concentración en el aire de este contaminante se redujo en 26% durante el segundo trimestre de 2020, y se contrajo 33% durante el tercer trimestre de 2020, ambos en comparación al escenario base. Para el último trimestre de 2020 y primer semestre de 2021, no se observa que los coeficientes sean significativos, lo que indica que son similares al escenario base. Destaca que las variables dummies por día de la semana no resultan ser significativas; es decir, su concentración es similar en todos los días de la semana, lo que puede indicar que tiene poca relación con el ciclo semanal de la actividad humana. De entre los 9 contaminantes analizados, las estimaciones de la concentración de dióxido de azufre son las que presentaron las menores R², lo que sugiere que las variables atmosféricas, de actividad humana semanal, y de tipo tendencial, explican poco su comportamiento, al menos en el periodo analizado de 2015 al primer semestre de 2021.

Óxidos de nitrógeno (NO_x). Este contaminante presenta una disminución evidente los domingos de casi 32% en comparación a los lunes, lo que sugiere una relevante correlación con la actividad humana semanal. Los modelos indican que en el segundo trimestre de 2020 disminuyó 35% la concentración de este contaminante en el aire de la Ciudad de México y su área metropolitana, y se redujo 19% en el tercer trimestre de ese mismo año. No hay evidencia de que en trimestres posteriores la concentración de este gas sea diferente al escenario base. De entre los contaminantes analizados, las estimaciones respecto de los óxidos de nitrógeno son las que presentan los mejores ajustes medido a través de la R², con valores de entre 44% a 66%, lo que indica que las variables atmosféricas, de actividad humana semanal y el componente tendencial predicen bien el comportamiento de este gas.

Monóxido de nitrógeno (NO). Los resultados obtenidos arrojan que la concentración de este gas disminuyó 65% en el segundo trimestre de 2020 y 21% en el tercer trimestre de 2020, en comparación al escenario base. Así, de entre los contaminantes analizados, el monóxido de nitrógeno fue el que más reducción presentó durante los meses más severos del confinamiento en la pandemia por COVID-19, comprendido en el trimestre de entre abril y junio de 2020. Por un lado, esta reducción se puede atribuir directamente a las acciones de confinamiento y restricciones de actividad económica, y por el otro lado, al haber menos contaminantes de otros tipos en el aire, permitió que una mayor cantidad de este gas se mezclara con el oxígeno para convertirse en NO₂.

No se observa que los coeficientes sean significativos para el último trimestre de 2020 y primeros dos trimestres de 2021. Respecto al día de la semana, se encontró que los sábados se tiene 13% menos concentración de este contaminante durante todo el periodo analizado y los domingos se contrae 60%, en comparación a los lunes. Haciendo una simple comparación, la concentración de monóxido de nitrógeno durante el segundo trimestre de 2020 fue como si todos los días de ese trimestre fueran como un domingo ordinario prepandemia.

Dióxido de nitrógeno (NO₂). Este contaminante también presenta un comportamiento en función de la actividad humana semanal, disminuye en 19% los domingos en comparación a los lunes. Las estimaciones indican que la concentración de este gas en el aire disminuyó 25% en el segundo trimestre de 2020 y 18% en el tercer trimestre de ese año, en comparación a la línea base. No se observa que la presencia de este contaminante sea diferente al escenario contrafactual para el resto de 2020 ni para el primer semestre de 2021.

Parece que hay un consenso en la literatura que apunta a una importante mejora en la calidad del aire derivada de la reducción en la concentración de NO₂ por el confinamiento por COVID-19, como lo muestran estudios para Estados Unidos, China, India, Indonesia, Portugal, Reino Unido, España, Francia, Italia y Suecia (Chen, Chien, Li,

& Lin, 2020; Fardani, Tarlani, & Aji, 2021; He, Pan, & Tanaka, 2020; Rajput & Barde, 2022; Skirienė & Stasiškienė, 2021; Slezakova & Pereira, 2021). Es posible que también en estos países se hayan presentado reducciones en NO, y, por tanto, de NOX, pero no fueron analizados directamente en estos artículos. En el caso específico de México, se puede interpretar que el factor que influye en la variación semanal de NOX, pudiese estar en la movilidad que tienen las personas durante la semana laboral. Las fuentes móviles representan el principal origen de este contaminante, en 2018, solamente los autos privados, taxis y microbuses y vagonetas representaron el 56.9% de las emisiones de este gas.

Monóxido de carbono (CO). Los resultados de los modelos econométricos indican que durante el segundo trimestre de 2020 se contrajo 13% la concentración de este contaminante en el aire, en comparación al escenario base. Para el tercer trimestre de 2020, la presencia de este gas fue similar a lo esperado en el escenario prepandemia, pero durante el cuarto trimestre de 2020 y los dos primeros trimestres de 2021, se encuentra que la concentración de CO en el aire fue en promedio 26% mayor que el escenario base. Los fines de semana se observa que se tiene menor concentración de este contaminante en el aire en comparación a los días hábiles. En su gran mayoría, las fuentes móviles conforman el principal emisor de CO, por lo tanto, la mayor cantidad de traslados por trabajo y escuela entre semana podría explicar la mayor concentración de este contaminante entre semana, en comparación con los fines de semana.

Partículas de fracción gruesa (PMCO). Los modelos calculados indican que la concentración de este contaminante disminuyó 13% en el segundo trimestre de 2020 y 26% en el tercer trimestre de ese año, en comparación a la línea base. También se encuentra que en el segundo trimestre de 2021 la concentración de este contaminante decreció en 48% respecto de la línea base. Los cambios observados durante 2020 pueden estar vinculados con los efectos directos e indirectos de la pandemia, aunque el dato obtenido para 2021 parece tener otra explicación particular.

Ozono (O3). Las estimaciones apuntan a que la concentración de ozono aumentó en 17% durante el segundo trimestre de 2020, en comparación al escenario base. Del tercer trimestre de 2020 al segundo de 2021, no se observa que la concentración de este gas sea diferente a lo esperado en el escenario base. Los resultados también indican que la concentración de este contaminante aumenta durante los fines de semana. Sin embargo, para atribuir la existencia de una posible relación causal, se requiere hacer un estudio a mayor profundidad, el cual supera los alcances de este artículo. En el anexo se muestran los niveles históricos de concentración de ozono en la ZMVM.

Estos resultados son similares a los reportados en estudios en China sobre los efectos del confinamiento por COVID-19 en la calidad del aire, en los que hallan que disminuye de manera significativa la concentración de contaminantes como CO, NO2, SO2, pero aumenta la concentración de O3 (He et al., 2020; Shen et al., 2020). En un metaestudio de 34 países con datos satelitales se encuentra también una disminución en la concentración de NO2 y un aumento promedio de O3 (Venter, Aunan, Chowdhury, & Lelieveld, 2020). Tanto en He et al. (2020) y en Venter et al. (2020), argumentan que la reducción de NOX (= NO + NO2) durante la pandemia disminuyó la concentración de NO en el aire, el cual interactúa con el O3.

Una de las variables meteorológicas que influyen de forma importante en la formación de ozono a nivel troposfera es la radiación solar. En el caso del ZMVM dicha variable es monitoreada por el Simat; no obstante, no fue tomada en cuenta para el presente análisis debido a importantes faltantes en la información, dando lugar a una variable no balanceada y que no contaba con los mínimos requerimientos necesarios para su confiabilidad.

Partículas finas (PM2.5) y Partículas pequeñas (PM10). En los trimestres analizados, solo se observa que los coeficientes son estadísticamente diferentes a cero para el tercer trimestre de 2020, en donde se encuentra una contracción en la concentración del contaminante PM2.5 de 19% y de PM10 de 13%, respecto al escenario base.

Los datos indican que las partículas PM2.5, PM10 y PMCO presentan un comportamiento cíclico gradual de forma peculiar a lo largo de la semana, con su máximo los jueves y mínimo los domingos.

La literatura de artículos similares en otras geografías indica que los efectos de la pandemia en la concentración de PM2.5 y PM10 fueron mixtos. En estudios en China, India y Portugal que encuentran evidencia en la reducción de PM2.5 y PM10 durante el periodo más severo del confinamiento (He et al., 2020; Rajput & Barde, 2022; Slezakova & Pereira, 2021). En un artículo que analizó 28 estaciones a lo largo de Estados Unidos se encontraron resultados no uniformes: estaciones donde aumentó la concentración de PM2.5 y PM10, y otras donde disminuyó (Chen et al., 2020). En la región de Beijing, en China, se encontró que durante las dos primeras semanas del confinamiento se incrementó la concentración de PM2.5 en 23%, aunque posteriormente se registró una disminución con respecto al periodo prepandemia. Los autores atribuyen esta situación a que factores climatológicos (alta humedad relativa y relativa baja velocidad del viento) que pesaron más que la reducción de las actividades antropogénicas (Xian, Li, & Wei, 2021). Para México, las fuentes de área representan uno de los principales emisores de estos contaminantes, contribuyendo con 35.8% y 44.2% de las emisiones de PM2.5 y PM10 en 2018, respectivamente. En ese sentido, una hipótesis podría referir que el aumento de los niveles de concentración de estos contaminantes durante los meses de la pandemia, la disminución de las emisiones de fuentes móviles en 2020 no alcanzó a compensar el incremento de las emisiones por fuentes de área. Las cuales están ligadas en parte al uso de combustibles domésticos que, de acuerdo con el índice de movilidad se observa un incremento relevante la actividad en zonas residenciales durante los meses de pandemia. No obstante, se requiere mayor investigación al respecto de dicha hipótesis.

La ZMVM está en las regiones en el mundo en donde las concentraciones de PM2.5 y PM10 no disminuyeron en el segundo trimestre de 2020. Una o una combinación de las siguientes explicaciones puede explicar el por qué: 1) Que en México se implementó el confinamiento de forma diferente a estos otros países, 2) Que las fuentes de origen de PM2.5 y PM10 en México sean diferentes, o 3) Como en el caso de la región de Beijing, que los factores ambientales tuvieron más peso que los factores ligados a la actividad económica.

Gráfica 3. **SÍNTESIS DE LAS ESTIMACIONES DE LOS CAMBIOS EN TÉRMINOS PORCENTUALES EN LAS CONCENTRACIONES DE CONTAMINANTES EN LA ZMVM, 2020T2 - 2021T2**
(% VS. ESCENARIO BASE CONTRAFACUAL)



Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

5. Elasticidad de los contaminantes ante cambios en la movilidad

La emergencia sanitaria por COVID-19, y con ella las medidas de distanciamiento social implementadas para contener la cadena de contagios a nivel nacional, han provocado cambios importantes de corto y largo plazo en los patrones de movilidad y consumo de la población mexicana y a nivel mundial. Actualmente, la cantidad de información que se registra a nivel individual de nuestras actividades diarias en comparación con décadas pasadas es amplia, a raíz de nuestra interacción con los medios digitales se ha conformado una huella digital con información de diversas variables relacionadas con nuestra ubicación y consumo a lo largo del tiempo. La huella digital ha permitido diversos ejercicios de análisis que buscan conocer los patrones de movilidad y consumo y su cambio en el tiempo. Así, mediante los registros de los desplazamientos en tiempo real de las personas, los registros de compra mediante medios digitales o los registros del historial de ubicaciones por mencionar algunos ejemplos, se puede tener muestras de información relevantes sobre estos patrones y los cambios en la tendencia que sufrieron a causa de la emergencia sanitaria.

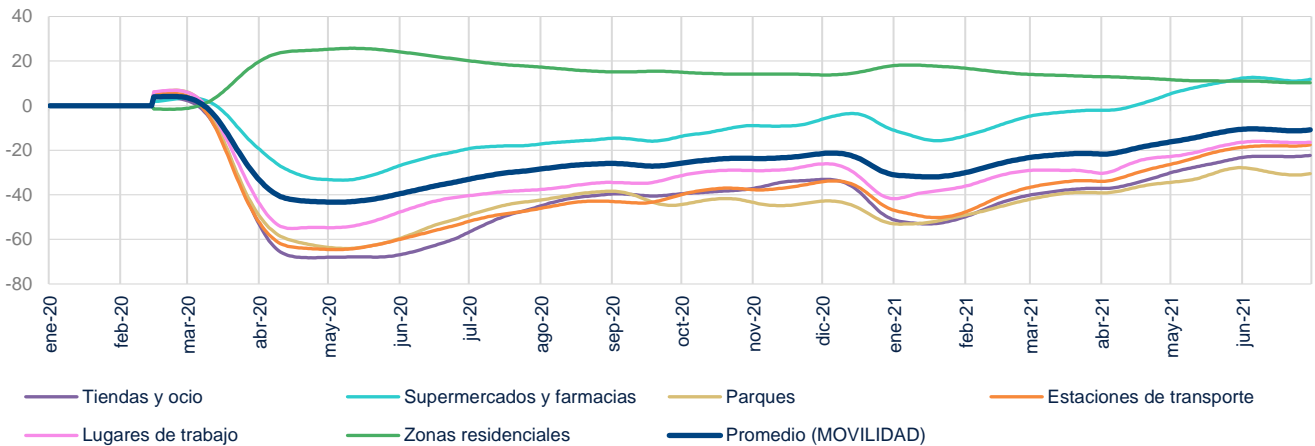
Debido a la crisis por COVID-19, desde principios del año 2020 la empresa Google comenzó la publicación de reportes con la estimación diaria de la movilidad por país, entidad y principales ciudades. Estos Informes de Movilidad Local utilizan los datos agregados y anónimos de aquellos usuarios que cuentan con el historial de ubicaciones habilitado. Dicha información permite estimar las horas punta (lo concurrido que suele estar una ubicación durante el día), el tiempo de espera (cuánto tiempo tendría que esperar un cliente para ser atendido a diferentes horas del día) y la duración de las visitas a establecimientos o ubicaciones en específicas (muestra la cantidad de tiempo que los clientes pasan habitualmente en dicha ubicación). Mediante estas estimaciones el informe muestra las tendencias de movilidad en los momentos de mayor confinamiento a causa de las políticas implementadas para contener la pandemia desde febrero de 2020 a la fecha por zonas geográficas y para diversas categorías de lugares.

Los datos del reporte de movilidad se presentan como la variación porcentual de forma diaria respecto a la línea base, según el día de la semana. La línea base es el valor de la mediana, para cada día de la semana, del periodo de cinco semanas que comprende del 3 de enero al 6 de febrero de 2020. Las categorías de lugar corresponden a aquellas que proporcionan más información para monitorear el distanciamiento social y el acceso a servicios esenciales:

- Tiendas y ocio (restaurantes, cafeterías, centros comerciales, museos, cines),
- Supermercados y farmacias (mercados, supermercados, tiendas de comida especializadas, farmacias),
- Parques (parques nacionales, playas públicas, sedes deportivas, plazas públicas, parques),
- Estaciones de transporte (estaciones de metro, autobús, tren),
- Lugares de trabajo y
- Zonas residenciales.

Para este estudio, se tienen registros de movilidad para la Ciudad de México desde el 15 de febrero de 2020, y se obtuvieron los datos hasta el 30 de junio de 2021. Los datos de movilidad se transformaron a un índice con la línea base igual a 100: bastó con sumar el valor 100 a cada uno de los datos originales. Así, los valores comprendidos del 1º de enero al 14 de febrero de 2020, que engloban a la línea base, se fijaron igual a 100. Por último, se promediaron los valores de las 6 estadísticas de la base de datos para crear una única variable, que se denominó **movilidad**, que refleje el nivel de la movilidad en la Ciudad de México.

Gráfico 4. **VARIACIÓN PORCENTUAL DE LOS INDICADORES DE MOVILIDAD DE GOOGLE VS. LÍNEA BASE, 15 DE FEBRERO DE 2020 A 30 DE JUNIO DE 2021 (%)**



Nota: Estimación mediante filtro Hodrick-Prescott.

Fuente: BBVA Research a partir de Informes de Google Mobility, Movilidad Local sobre el COVID-19.

La gráfica anterior muestra la tendencia de las diferentes categorías analizadas y el valor promedio de las seis categorías desde principios del año 2020 hasta la primera mitad del 2021. Se observa que, en la mayor parte del periodo, cinco de las seis estuvieron por debajo del nivel de referencia. Siendo la variable de Zonas residenciales la única que registró un valor por encima del de referencia en prácticamente todo el periodo. Durante los meses de mayor confinamiento (es decir marzo, abril y mayo) cinco de las seis categorías alcanzaron su nivel más bajo con respecto al nivel de referencia, y zonas residenciales registró su nivel más alto con respecto al nivel de referencia. En ese sentido y tomando en cuenta la drástica reducción en la actividad económica en México a partir de las medidas de distanciamiento social, una pregunta que surge es cuál es la elasticidad de los contaminantes en la Ciudad de México ante un cambio en 1% en el índice de movilidad urbana.

Aplicando la misma estructura de los modelos y metodologías anteriormente analizadas, simplemente se reemplaza la matriz de variables dummies por trimestre por la variable movilidad. Así, el modelo de efectos fijos queda descrito por la siguiente ecuación:

$$y_{i,t} = \alpha + X_{i,t}\beta + D_t\gamma + m_t\theta + v_i + t + \epsilon_{i,t}$$

y el modelo de efectos aleatorios por:

$$y_{i,t} = \alpha + X_{i,t}\beta + D_t\gamma + m_t\rho + t + (u_i + \epsilon_{i,t})$$

en donde:

- m_t dato de movilidad correspondiente al día t
- ρ coeficiente que mide la sensibilidad de la variable dependiente ante cambios en la movilidad.

En la tabla siguiente se muestran los resultados de ρ para los diferentes contaminantes en la ZMVM.

Tabla 4. **ELASTICIDAD DE LOS CONTAMINANTES EN LA ZMVM ANTE CAMBIOS EN EL ÍNDICE DE MOVILIDAD DE GOOGLE**

	n	Estimaciones con errores estándar de Driscoll & Kraay				FGLS con estructura de errores heterocedásticos	
		Efectos fijos		Efectos aleatorios		ρ	p-value
		ρ	p-value	ρ	p-value		
ISO2	6,417	1.205664	0.0000 ***	1.205543	0.0000 ***	1.035251	0.0000 ***
INOX	5,767	0.813432	0.0000 ***	0.811525	0.0000 ***	0.797254	0.0000 ***
INO	5,767	1.467564	0.0000 ***	1.467299	0.0000 ***	1.425463	0.0000 ***
INO2	5,767	0.585510	0.0000 ***	0.573575	0.0000 ***	0.583279	0.0000 ***
ICO	6,077	0.422730	0.0000 ***	0.422369	0.0000 ***	0.401934	0.0000 ***
IO3	6,615	-0.374755	0.0000 ***	-0.370788	0.0000 ***	-0.322600	0.0000 ***
IPM2.5	3,099	-0.182259	0.2140	-0.171892	0.2590	-0.168510	0.0000 ***
IPM10	3,842	0.131041	0.2700	0.043008	0.7290	0.059486	0.1440
IPMCO	2,233	0.395707	0.0010 ***	0.303443	0.0220 **	0.326105	0.0000 ***

Nivel de significancia: *** 1%, ** 5%, * 10%.

Fuente: BBVA Research.

Al igual que en las estimaciones de cambios de concentración durante la pandemia, se mencionan los resultados promediando los modelos de efectos fijos y variables con errores estándar de Driscoll & Kraay. Los coeficientes obtenidos por FGLS con estructura de errores heterocedásticos solo se presentan para contrastar los resultados.

Así, en el periodo comprendido del 15 de febrero de 2020 al 30 de junio de 2021, las estimaciones econométricas indican que por cada punto porcentual en el que disminuyó la movilidad en la ZMVM, disminuyó:

- 1.47% la concentración de monóxido de nitrógeno (NO),
- 1.21% la de dióxido de azufre (SO2),
- 0.81% la de óxidos de nitrógeno (NOX),
- 0.59% la de dióxido de nitrógeno (NO2),
- 0.42% la de monóxido de carbono (CO) y
- 0.40% la de partículas de fracción gruesa (PMCO)

Las estimaciones también indican que por cada punto porcentual que decreció la movilidad en el periodo analizado, aumentó la concentración de ozono (O3) en el aire de la ZMVM en 0.37%. Dicha estimación, podría responder a que, si bien hubo una reducción en las fuentes móviles sobretodo en el uso de autos particulares, ese factor tiene mayor incidencia sobre los precursores de ozono como los NOX, mientras que los COV son emitidas en su mayoría por fuentes de área (65.5%). Una parte de este aumento se puede deber al incremento de COV en el ambiente. En ese sentido, en la ZMVM los carros particulares no serían tan determinantes al respecto del nivel de ozono en la troposfera.

Por otro lado, no se encontró evidencia de la relación entre movilidad y la concentración de partículas finas (PM2.5) y partículas pequeñas (PM10). Una de las razones podría involucrar la distinción en el tipo de transporte que contribuye a las emisiones de las partículas suspendidas y el aumento de las emisiones por parte de las fuentes de área. En el caso de las partículas suspendidas, las fuentes móviles representan cerca del 40% de las emisiones; no obstante, resalta que solamente el 8.5% en PM2.5y el 14.5% en PM10 correspondan a automóviles

privados. Durante la pandemia, el transporte de carga se mantuvo en su nivel de actividad pre pandemia, por lo que, las fuentes de área pudieron contribuir también de forma más relevante en los niveles de concentración de estos contaminantes. Estudios más específicos podrían arrojar luz acerca de la hipótesis del papel de las fuentes de área en los niveles de contaminación de la ZMVM en años recientes.

6. Conclusiones y consideraciones finales

La Zona Metropolitana del Valle de México (ZMVM) es una de las urbes más pobladas del país y del mundo, las consecuencias de una mala calidad del aire representan un problema de salud pública relevante para México. Las estrategias para disminuir los niveles de concentración de los contaminantes y restaurar una calidad del aire “buena”, están conformadas por diversas medidas que plantean un proceso progresivo de reducción de los niveles de contaminación.

En ese sentido, la investigación analiza una etapa inusual y repentina de baja movilidad y cierre de actividades económicas derivadas de la pandemia por COVID-19, para realizar una evaluación del efecto de la movilidad restringida y el bajo nivel de actividad económica sobre la calidad del aire. Mediante el uso de modelos de datos panel para las variables dependientes de concentración de contaminantes y controlando por variables atmosféricas, se estimó su variación a lo largo de cinco trimestres: del segundo trimestre de 2020 al segundo trimestre de 2021. De forma simplificada, el escenario base contrafactual se construyó a partir de la tendencia de la serie del contaminante entre 2015 y 2019, condicionado por los factores climatológicos y ajustado por la diferencia en la actividad del ser humano en los diferentes días de la semana.

De acuerdo con las estimaciones, los niveles de concentración de los contaminantes de SO₂, NO_x, NO, NO₂, CO, PCMO observaron una disminución significativa en el segundo trimestre y, la mayoría, en el tercer trimestre de 2020 con respecto al escenario base de la serie de los contaminantes. Adicionalmente, la concentración de los contaminantes PM_{2.5} y PM₁₀ tuvieron cambio significativo solamente en el tercer trimestre del 2020 respecto al escenario base. No obstante, los niveles de ozono (O₃) presentaron un aumento significativo en el segundo trimestre de 2020 en comparación con el escenario base. Con la paulatina reapertura de la actividad económica y el regreso a la nueva normalidad, se observa que a partir del cuarto trimestre de 2020 la concentración en el aire de los contaminantes ya se ubican en sus niveles prepandemia.

En términos de elasticidades, los resultados obtenidos en este artículo indican que, en el periodo del 15 de febrero de 2020 al 30 de junio de 2021 en la ZMVM, la disminución de 1% en la movilidad, redujo la concentración de los contaminantes SO₂, NO, NO₂, NO_x, CO y PMCO entre 0.40% y 1.47%. En contraste, por cada punto porcentual que decreció la movilidad, los niveles de ozono (O₃) se incrementaron en 0.37%. Por otro lado, no se obtuvo evidencia estadística de afectación de las concentraciones de los contaminantes PM₁₀ y PM_{2.5} en el aire por la disminución en movilidad.

Los resultados son consistentes con otros estudios para China, India, Indonesia, Portugal y otras geografías que encuentran también mejoras en la calidad del aire debido a las reducciones de SO₂, NO₂ y CO debido al confinamiento por COVID-19, y en donde también hallan un aumento en la concentración de O₃ en ese periodo, debido posiblemente a la compleja interacción química entre los contaminantes en el aire. La literatura en otras geografías indica que los efectos de la pandemia en la concentración de PM_{2.5} y PM₁₀ fueron mixtos, y la ZMVM está entre las regiones del mundo donde no se observó durante el inicio del confinamiento una reducción de estos contaminantes. Factores ambientales, de fuente de emisión o propios de la región pueden ser la causa que explique esta situación.

En síntesis, los efectos de la pandemia, si bien temporales, fueron favorables en la disminución de los contaminantes SO₂, NO, NO₂, NO_x, CO y PM₁₀ de la ZMVM en comparación con el escenario base; sin embargo, la ineficacia sobre la reducción de O₃, PM₁₀ y PM_{2.5}, señala que es necesario implementar programas que atiendan no solo la reducción de fuentes móviles de contaminación, sino programas integrales que atiendan la contribución de emisiones de fuentes de área. Programas como Hoy No Circula contribuyen a disminuir las emisiones de fuentes móviles de manera temporal, pero si no son acompañados de programas para atender las fugas de gas L.P. en los hogares y establecimientos particulares, o si no se limita el contenido de Compuestos Orgánicos Volátiles (COV) en productos de amplio uso (cosméticos y productos domésticos, industrial, comercial y de servicios) será muy complicado que logremos las metas establecidas. De forma paralela, es importante implementar políticas públicas que reduzcan estas fuentes móviles de forma permanente como son incentivar la producción y compra de autos eléctricos e híbridos, mejoras en el transporte público, así como la construcción de nuevas viviendas cerca de los centros urbanos para reducir las distancias de traslado. Así, los episodios de contingencia ambiental seguirán siendo una normalidad en la ZMVM en los años venideros si no se atienden estas fuentes de emisión.

7. Referencias

- Barrera Ojeda, D. (2017, septiembre 8). ¿Levin Lin Chu o Im Pesaran Shin en panel de datos? [Video]. Recuperado a partir de <https://www.youtube.com/watch?v=meYgYnBD6Y>
- Chen, L. W. A., Chien, L. C., Li, Y., & Lin, G. (2020). Nonuniform impacts of COVID-19 lockdown on air quality over the United States. *Science of the Total Environment*. <http://doi.org/https://doi.org/10.1016/j.scitotenv.2020.141105>
- Coates, J., Mar, K. A., Ojha, N., & Butler, T. M. (2016). The influence of temperature on ozone production under varying NO_x conditions – a modelling study. *Atmospheric Chemistry and Physics*, 16(18), 11601–11615. <https://doi.org/10.5194/acp-16-11601-2016>
- Comisión Ambiental de la Megalópolis [CAME]. (2018, septiembre 21). IMECA: Índice Metropolitano de la Calidad del Aire. Recuperado a partir de <https://www.gob.mx/comisionambiental/es/articulos/imeca-indice-metropolitano-de-la-calidad-del-aire>
- Consejo Nacional de Población [Conapo]. (2018). Delimitación de las zonas metropolitanas de México 2015.
- Dawson, J., Adams, P., & Pandis, S. (2007). Sensitivity of ozone to summertime climate in the eastern USA: a modeling case study. *Atmospheric Environment*, 41(7), 1494–511. <https://doi.org/10.1016/j.atmosenv.2006.10.033>
- Driscoll, J. C., & Kraay, A. C. (1998). Consistent Covariance Matrix Estimation with Spatially Dependent Panel Data. *Review of Economics and Statistics*, 80(4), 549–560. <http://doi.org/10.1162/003465398557825>
- Enders, W. (2018). *Applied Econometric Time Series* (4a ed.). Wiley.
- Fardani, I., Tarlani, & Aji, R. R. (2021). Analysis of Changes in Air Quality in Major Cities Indonesia during COVID 19 Using Remote Sensing Data. *IOP Conference Series: Earth and Environmental Science*, 830(1). <http://doi.org/10.1088/1755-1315/830/1/012085>
- Google Mobility. (2021). Google COVID-19 Community Mobility Reports. Recuperado a partir de <https://www.google.com/covid19/mobility/>
- Greenstone, M., Hasenkopf, C., & Lee, K. (2022). Air Quality Life Index June 2022 Annual Update.
- Hays, S. P. (1981). The Environmental Movement. *Journal of Forest History*, 25(4), 219–221.
- He, G., Pan, Y., & Tanaka, T. (2020). The short-term impacts of COVID-19 lockdown on urban air pollution in China. *Nature Sustainability*, 3(12), 1005–1011. <http://doi.org/10.1038/s41893-020-0581-y>
- Hernandez, G., Berry, T., Wallis, S., & Poyner, D. (2017). Temperature and Humidity Effects on Particulate Matter Concentrations in a Sub-Tropical Climate during Winter. *International Proceedings of Chemical, Biological and Environmental Engineering*, 102(8). doi: 10.7763/IPCBE. 2017. V102. 8
- Hoechle, D. (2007). Robust Standard Errors for Panel Regressions with Cross-Sectional Dependence. *The Stata Journal: Promoting communications on statistics and Stata*, 7(3), 281–312. <http://doi.org/10.1177/1536867X0700700301>
- Horne, J., & Dabdub, D. (2017) Impact of global climate change on ozone, particulate matter, and secondary organic aerosol concentrations in California: a model perturbation analysis. *Atmospheric Environment*, 153, 1–17. <https://doi.org/10.1016/j.atmosenv.2016.12.049>.

- Im, K. S., Pesaran, M. H., & Shin, Y. (2003). Testing for unit roots in heterogeneous panels. *Journal of Econometrics*, 115(1), 53–74. [http://doi.org/10.1016/S0304-4076\(03\)00092-7](http://doi.org/10.1016/S0304-4076(03)00092-7)
- Instituto Nacional de Estadística y Geografía [Inegi]. (2021). Censo de Población y Vivienda 2020. Principales resultados por localidad (ITER).
- Kao, C. (1999). Spurious regression and residual-based tests for cointegration in panel data. *Journal of Econometrics*, 90(1), 1–44. [http://doi.org/10.1016/S0304-4076\(98\)00023-2](http://doi.org/10.1016/S0304-4076(98)00023-2)
- Lu, X., Zhang, L. & Shen, L. (2019). Meteorology and Climate Influences on Tropospheric Ozone: a Review of Natural Sources, Chemistry, and Transport Patterns. *Current Pollution Reports*, 5, 238–260. <https://doi.org/10.1007/s40726-019-00118-3>
- Martinez, J. (2021). Great Smog of London. *Encyclopedia Britannica*. Recuperado a partir de <https://www.britannica.com/event/Great-Smog-of-London>
- Meadows, D. H., Meadows, D. L., Randers, J., & Behrens III, W. W. (1972). *The Limits to Growth*. New York: Universe Books.
- Organización Mundial de la Salud (OMS). (2006). *Air Quality Guidelines Global Update 2005*. Germany.
- Pedroni, P. (1999). Critical Values for Cointegration Tests in Heterogeneous Panels with Multiple Regressors. *Oxford Bulletin of Economics and Statistics*, 61(s1), 653–670. <http://doi.org/10.1111/1468-0084.0610s1653>
- Pesaran, M. H. (2021). General diagnostic tests for cross-sectional dependence in panels. *Empirical Economics*, 60(1), 13–50. <http://doi.org/10.1007/s00181-020-01875-7>
- Rajput, H., & Barde, S. (2022). Assessment of Air Pollution before and during COVID-19 Pandemic Lockdown in Chhattisgarh. *Assessment of Air Pollution before and during COVID-19 Pandemic Lockdown in Chhattisgarh State, India*. IOP Conference Series: Earth and Environmental Science, 1032. <http://doi.org/10.1088/1755-1315/1032/1/012044>
- Ramasamy, J., Kumaravel, B., Palanivelraja, S., & Chockalingam, M. P. (2013). Influence of Temperature, Relative Humidity and Seasonal Variability on Ambient Air Quality in a Coastal Urban Area, *International Journal of Atmospheric Sciences*, 2013. <https://doi.org/10.1155/2013/264046>
- Secretaría de Desarrollo Social [Sedesol]. (1992). Boletín Informativo de la calidad del aire 1986-1992. Recuperado a partir de http://www.aire.cdmx.gob.mx/descargas/publicaciones/flippingbook/informe_anual_calidad_aire_1986_1992/informe_anual_calidad_aire_1986_1992.pdf
- Secretaría de Salubridad y Asistencia [SSA]. (1978). El Índice Mexicano de Calidad del Aire (IMEXCA). Recuperado a partir de <http://www.aire.cdmx.gob.mx/descargas/publicaciones/flippingbook/imexca1978/IMEXCA-1978.pdf>
- Secretaría del Medio Ambiente de la Ciudad de México [Sedema]. (2018). *Calidad del aire en la Ciudad de México, Informe 2017*.
- Secretaría del Medio Ambiente de la Ciudad de México [Sedema]. (2020). *Calidad del aire en la Ciudad de México, Informe 2018*.
- Secretaría del Medio Ambiente de la Ciudad de México [Sedema]. (2021). *Inventario de Emisiones de la Zona*

Metropolitana del Valle de México 2018. Ciudad de México.

Secretaría del Medio Ambiente de la Ciudad de México [Sedema]. (2022). Programa para Prevenir y Responder a Contingencias Ambientales Atmosféricas en la Ciudad de México. Recuperado a partir de <http://www.aire.cdmx.gob.mx/default.php?opc=%27YqBhnmU=%27>

Secretaría del Medio Ambiente de la Ciudad de México [Sedema], Secretaría del Medio Ambiente del Gobierno del Estado de México [Smagem], Secretaría de Medio Ambiente y Recursos Naturales del Gobierno del Estado de Hidalgo [Semarnath], & Secretaría de Medio Ambiente y Recursos Naturales [Semarnat]. (2021). Programa de Gestión para Mejorar la Calidad del Aire de la Zona Metropolitana del Valle de México (ProAire ZMVM 2021-2030). Ciudad de México.

Secretaría del Medio Ambiente del Gobierno del Distrito Federal [Sedema]. (2012). Calidad del aire en la Ciudad de México, Informe Anual 2011.

Servicio Meteorológico Nacional [SMN]. (2021). Glosario técnico. Recuperado a partir de <https://smn.conagua.gob.mx/es/smn/glosario>

Shen, F., Hegglin, M. I., Luo, Y., Yuan, Y., Wang, B., Flemming, J., ... Ge, X. (2020). Disentangling drivers of air pollutant and health risk changes during the COVID-19 lockdown in China. <http://doi.org/10.1038/s41612-022-00276-0>

Sistema de Monitoreo Atmosférico de la Ciudad de México [Simat]. (2021). Mosaico histórico del índice aire y salud (nom-172-semarnat-2019) del promedio móvil de 8 horas de O3 en la zona metropolitana de la Ciudad de México (1990-2021). Recuperado a partir de http://www.aire.cdmx.gob.mx/descargas/estadisticas/indicadores/mosaicos/mosaico_ozono_indice_aire_salud_8h.pdf

Skirienė, A. F., & Stasiškienė, Ž. (2021). COVID-19 and air pollution: Measuring pandemic impact to air quality in five European countries. *Atmosphere*, 12(3). <http://doi.org/10.3390/atmos12030290>

Slezakova, K., & Pereira, M. C. (2021). 2020 COVID-19 lockdown and the impacts on air quality with emphasis on urban, suburban and rural zones. *Scientific Reports*, 11(1). <http://doi.org/10.1038/s41598-021-99491-7>

Velazquez, M. A. (2010). Los Movimientos Ambientales en México. En I. Bizberg & F. coordinadores Zapata (Eds.), *Movimientos sociales* (1a. ed., p. 395). México, D.F.: El Colegio de México.

Venter, Z. S., Aunan, K., Chowdhury, S., & Lelieveld, J. (2020). COVID-19 lockdowns cause global air pollution declines. *Proceedings of the National Academy of Sciences of the United States of America*, 117(32), 18984–18990. <http://doi.org/10.1073/pnas.2006853117>

Wang, J., & Ogawa, S. (2015). Effects of Meteorological Conditions on PM2.5 Concentrations in Nagasaki, Japan. *International Journal of Environmental Research and Public Health*, 12(8), 9089-9101. doi: 10.3390/ijerph120809089

Westerlund, J. (2005). New Simple Tests for Panel Cointegration. *Econometric Reviews*, 24(3), 297–316. <http://doi.org/10.1080/07474930500243019>

Wooldridge, J. M. (2010). *Introducción a la econometría. Un enfoque moderno* (4a ed.). Cengage Learning.

World Meteorological Organization [WMO], & United Nations Environment Programme [UNEP]. (2011). Integrated Assessment of Black Carbon and Tropospheric Ozone. Recuperado a partir de https://library.wmo.int/index.php?lvl=notice_display&id=12414#.YWc0wH2ZIr0

Xian, T., Li, Z., & Wei, J. (2021). Changes in Air Pollution Following the COVID-19 Epidemic in Northern China: The Role of Meteorology. *Frontiers in Environmental Science*, 9(March), 1–9. <http://doi.org/10.3389/fenvs.2021.654651>

Yang, Q., Yuan, Q., Li, T., Shen, H., & Zhang, L. (2017). The Relationships between PM2.5 and Meteorological Factors in China: Seasonal and Regional Variations. *International Journal of Environmental Research and Public Health*, 14(12), 1510. doi: 10.3390/ijerph14121510

8. Anexos

8.1. Pruebas de raíces unitarias

Tabla A1. **Resultados de las pruebas Im-Pesaran-Shin de raíces unitarias para datos en panel**

	Im-Pesaran-Shin Dickey-Fuller	Im-Pesaran-Shin Dickey-Fuller Aumentada			
		Con medias en sección cruzada		Sin medias en sección cruzada	
		Rezagos promedio en ADF por AIC	p-value	Rezagos promedio en ADF por AIC	p-value
Variables dependientes					
SO2	0.0000	0.44	0.0000	0.50	0.0000
NOX	0.0000	0.57	0.0000	0.71	0.0000
NO	0.0000	0.79	0.0000	0.79	0.0000
NO2	0.0000	0.50	0.0000	0.86	0.0000
CO	0.0000	0.67	0.0000	1.00	0.0000
O3	0.0000	0.94	0.0000	1.00	0.0000
PM2.5	0.0000	0.38	0.0000	1.00	0.0000
PM10	0.0000	0.70	0.0000	0.90	0.0000
PMCO	0.0000	0.83	0.0000	1.00	0.0000
Variables de control					
RH	0.0000	0.81	0.0000	0.94	0.0000
TMP	0.0000	0.81	0.0000	0.94	0.0000
WSP	0.0000	0.56	0.0000	0.69	0.0000
PP	0.0000	1.00	0.0000	-	-

Nota: Ho, todos los paneles contienen raíces unitarias; Ha, algunos paneles son estacionarios.
Fuente: BBVA Research.

8.2. Pruebas de cointegración

Tabla A2. **Resultados de las pruebas de cointegración Pedroni, Kao y Westerlund para los datos en panel, periodo de 2015 a 2019**

		Prueba de Pedroni con tendencia lineal Kernel de Bartlett y selección automática de rezagos mediante Newey-West					
Variables dependientes	Variables de control	Phillips-Perron modificado		Phillips-Perron		Dickey-Fuller aumentada	
		Estadístico t	p-value	Estadístico t	p-value	Estadístico t	p-value
ISO2	IRH ITMP IWSP IPP	-425.6581	0.0000	-114.42	0.0000	-109.21	0.0000
INOX	IRH ITMP IWSP IPP	-389.8922	0.0000	-113.34	0.0000	-114.51	0.0000
INO	IRH ITMP IWSP IPP	-449.4896	0.0000	-126.93	0.0000	-124.82	0.0000
INO2	IRH ITMP IWSP IPP	-338.8417	0.0000	-97.24	0.0000	-96.33	0.0000
ICO	IRH ITMP IWSP IPP	-372.3813	0.0000	-99.00	0.0000	-91.47	0.0000
IO3	IRH ITMP IWSP IPP	-400.2677	0.0000	-105.63	0.0000	-97.15	0.0000
IPM2.5	IRH ITMP IWSP IPP	-259.9122	0.0000	-67.37	0.0000	-62.11	0.0000
IPM10	IRH ITMP IWSP IPP	-265.9315	0.0000	-78.20	0.0000	-73.73	0.0000
IPMCO	IRH ITMP IWSP IPP	-207.4452	0.0000	-57.27	0.0000	-53.50	0.0000

		Prueba con residual de Kao Kernel de Bartlett y selección automática de rezagos mediante Newey-West				Prueba Westerlund con tendencia lineal	
Variables dependientes	Variables de control	Dickey-Fuller		Dickey-Fuller aumentada		Razón de varianzas	
		Estadístico t	p-value	Estadístico t	p-value	Estadístico	p-value
ISO2	IRH ITMP IWSP IPP	-91.9900	0.0000	-70.41	0.0000	-5.85	0.0000
INOX	IRH ITMP IWSP IPP	-65.0911	0.0000	-53.63	0.0000	-5.51	0.0000
INO	IRH ITMP IWSP IPP	-66.3607	0.0000	-51.89	0.0000	-5.63	0.0000
INO2	IRH ITMP IWSP IPP	-61.1683	0.0000	-52.04	0.0000	-5.37	0.0000
ICO	IRH ITMP IWSP IPP	-45.7378	0.0000	-33.55	0.0000	-4.79	0.0000
IO3	IRH ITMP IWSP IPP	-68.6726	0.0000	-50.59	0.0000	-5.65	0.0000
IPM2.5	IRH ITMP IWSP IPP	-44.0663	0.0000	-34.50	0.0000	-4.20	0.0000
IPM10	IRH ITMP IWSP IPP	-53.0631	0.0000	-42.56	0.0000	-4.63	0.0000
IPMCO	IRH ITMP IWSP IPP	-40.2554	0.0000	-33.36	0.0000	-3.35	0.0004

Prueba Pedroni y Kao: Ho, no hay cointegración; Ha, todos los paneles están cointegrados.

Prueba Westerlund: Ho, no hay cointegración; Ha, algunos paneles están cointegrados.

Fuente: BBVA Research.

8.3. Estimaciones de los modelos de panel de datos

Tabla B1. Estimaciones para la variable dependiente log Dióxido de azufre (ISO2)

ISO2	Estimaciones con errores estándar de Driscoll & Kraay					FGLS con estructura de errores heterocedásticos			
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.145833	0.2130		-0.288553	0.0120	**	-0.229763	0.0000	***
ITMP	-0.774329	0.0000	***	-0.639818	0.0010	***	-0.598480	0.0000	***
IWSP	-0.654135	0.0000	***	-0.836702	0.0000	***	-0.859064	0.0000	***
IPP	-0.054076	0.0000	***	-0.046141	0.0000	***	-0.051017	0.0000	***
diasem_1l									
1	0.000000			0.000000					
2	0.013337	0.7430		0.011759	0.7730		0.013509	0.5000	
3	0.005754	0.9050		0.005785	0.9040		0.007005	0.7270	
4	0.014810	0.7680		0.019278	0.7010		0.023232	0.2450	
5	-0.018702	0.7210		-0.012715	0.8070		-0.007510	0.7070	
6	-0.010140	0.8370		-0.007837	0.8730		-0.009782	0.6240	
7	-0.043127	0.2950		-0.045516	0.2700		-0.043587	0.0290	**
trim20t1	0.204063	0.0500	**	0.243223	0.0190	**	0.233359	0.0000	***
trim20t2	-0.286564	0.0110	**	-0.235646	0.0430	**	-0.244715	0.0000	***
trim20t3	-0.353453	0.0000	***	-0.297768	0.0010	***	-0.319895	0.0000	***
trim20t4	0.092160	0.4090		0.148727	0.1910		0.140899	0.0000	***
trim21t1	-0.053834	0.7520		-0.035677	0.8300		-0.026365	0.4320	
trim21t2	-0.046904	0.6940		-0.034150	0.7610		-0.044841	0.1970	
trend	-0.000146	0.0010	***	-0.000205	0.0000	***	-0.000198	0.0000	***
cons	4.249140	0.0000	***	4.634072	0.0000	***	4.290935	0.0000	***
Observaciones		28,277			28,277			28,277	
Grupos		16			16			16	
Prob > F		0.0000			0.0000				
R2 within		0.1437							
R2 overall					0.1490				
Prob > chi2								0.0000	

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

Tabla B2. Estimaciones para la variable dependiente log Óxidos de nitrógeno (INOX)

INOX	Estimaciones con errores estándar de Driscoll & Kraay						FGLS con estructura de errores heterocedásticos		
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.358449	0.0000	***	-0.505778	0.0000	***	-0.475042	0.0000	***
ITMP	-0.495056	0.0000	***	-0.432415	0.0000	***	-0.438352	0.0000	***
IWSP	-0.949254	0.0000	***	-0.805850	0.0000	***	-0.847012	0.0000	***
IPP	-0.022975	0.0000	***	-0.013345	0.0000	***	-0.015338	0.0000	***
diasem_1l									
1	0.000000			0.000000					
2	0.072163	0.0000	***	0.069373	0.0000	***	0.069344	0.0000	***
3	0.078756	0.0000	***	0.076728	0.0000	***	0.076194	0.0000	***
4	0.075236	0.0000	***	0.070390	0.0000	***	0.068748	0.0000	***
5	0.080380	0.0000	***	0.079027	0.0000	***	0.077741	0.0000	***
6	-0.063649	0.0000	***	-0.061500	0.0000	***	-0.068596	0.0000	***
7	-0.319350	0.0000	***	-0.316924	0.0000	***	-0.322554	0.0000	***
trim20t1	0.064316	0.0550	*	0.027577	0.4830		0.039531	0.0010	***
trim20t2	-0.325878	0.0000	***	-0.375481	0.0000	***	-0.348441	0.0000	***
trim20t3	-0.176973	0.0000	***	-0.198373	0.0000	***	-0.181156	0.0000	***
trim20t4	0.023155	0.5290		0.023780	0.5710		0.035739	0.0050	***
trim21t1	0.011189	0.7440		-0.064220	0.2300		-0.032005	0.0230	**
trim21t2	0.018509	0.6110		-0.071660	0.0710	*	-0.024085	0.0950	*
trend	-0.000148	0.0000	***	-0.000163	0.0000	***	-0.000176	0.0000	***
cons	7.123959	0.0000	***	7.482077	0.0000	***	7.404003	0.0000	***
Observaciones	25,164			25,164			25,164		
Grupos	14			14			14		
Prob > F	0.0000			0.0000					
R2 within	0.6151								
R2 overall				0.4413					
Prob > chi2							0.0000		

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

Tabla B3. **Estimaciones para la variable dependiente log Monóxido de nitrógeno (INO)**

INO	Estimaciones con errores estándar de Driscoll & Kraay						FGLS con estructura de errores heterocedásticos		
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.403398	0.0000	***	-0.555061	0.0000	***	-0.548712	0.0000	***
ITMP	-0.709665	0.0000	***	-0.560351	0.0000	***	-0.556724	0.0000	***
IWSP	-1.309106	0.0000	***	-1.238595	0.0000	***	-1.289016	0.0000	***
IPP	-0.047762	0.0000	***	-0.039185	0.0000	***	-0.040035	0.0000	***
diasem_1l									
1	0.000000			0.000000					
2	0.107202	0.0000	***	0.105516	0.0000	***	0.101878	0.0000	***
3	0.107753	0.0000	***	0.106832	0.0000	***	0.104296	0.0000	***
4	0.099805	0.0000	***	0.097262	0.0000	***	0.094874	0.0000	***
5	0.108696	0.0000	***	0.109892	0.0000	***	0.105996	0.0000	***
6	-0.130816	0.0000	***	-0.127812	0.0000	***	-0.133543	0.0000	***
7	-0.605916	0.0000	***	-0.604317	0.0000	***	-0.610739	0.0000	***
trim20t1	0.127197	0.0600	*	0.087152	0.2360		0.109518	0.0000	***
trim20t2	-0.623682	0.0000	***	-0.680876	0.0000	***	-0.647784	0.0000	***
trim20t3	-0.193474	0.0010	***	-0.234881	0.0000	***	-0.218138	0.0000	***
trim20t4	0.016025	0.8340		0.005195	0.9480		0.025458	0.2880	
trim21t1	-0.029395	0.7130		-0.131571	0.2030		-0.081521	0.0020	***
trim21t2	-0.036329	0.6280		-0.146479	0.0820	*	-0.087673	0.0010	***
trend	-0.000234	0.0000	***	-0.000251	0.0000	***	-0.000262	0.0000	***
cons	7.099890	0.0000	***	7.280787	0.0000	***	7.328837	0.0000	***
Observaciones	25,164			25,164			25,164		
Grupos	14			14			14		
Prob > F	0.0000			0.0000					
R2 within	0.4846								
R2 overall				0.3767					
Prob > chi2							0.0000		

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

Tabla B4. **Estimaciones para la variable dependiente log Dióxido de nitrógeno (INO2)**

INO2	Estimaciones con errores estándar de Driscoll & Kraay						FGLS con estructura de errores heterocedásticos		
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.318375	0.0000	***	-0.477341	0.0000	***	-0.422976	0.0000	***
ITMP	-0.353348	0.0000	***	-0.326047	0.0000	***	-0.377845	0.0000	***
IWSP	-0.764800	0.0000	***	-0.573042	0.0000	***	-0.611415	0.0000	***
IPP	-0.007985	0.0000	***	0.003035	0.2850		-0.000467	0.6330	
diasem_1l									
1	0.000000			0.000000					
2	0.049600	0.0000	***	0.046026	0.0000	***	0.047643	0.0000	***
3	0.059072	0.0000	***	0.056384	0.0000	***	0.057624	0.0000	***
4	0.057635	0.0000	***	0.051275	0.0000	***	0.052138	0.0000	***
5	0.060353	0.0000	***	0.057640	0.0000	***	0.058619	0.0000	***
6	-0.033889	0.0010	***	-0.031854	0.0040	***	-0.036719	0.0000	***
7	-0.191647	0.0000	***	-0.188483	0.0000	***	-0.193744	0.0000	***
trim20t1	0.045009	0.1220		0.009874	0.7740		0.019770	0.0460	**
trim20t2	-0.228529	0.0000	***	-0.276614	0.0000	***	-0.259585	0.0000	***
trim20t3	-0.177082	0.0000	***	-0.186639	0.0000	***	-0.177687	0.0000	***
trim20t4	0.028994	0.3360		0.038578	0.3090		0.037836	0.0000	***
trim21t1	0.024709	0.3810		-0.042374	0.3280		-0.027934	0.0140	**
trim21t2	0.025347	0.5000		-0.060498	0.1000	*	-0.023782	0.0390	**
trend	-0.000109	0.0000	***	-0.000125	0.0000	***	-0.000130	0.0000	***
cons	5.961103	0.0000	***	6.435844	0.0000	***	6.388660	0.0000	***
Observaciones	25,164			25,164			25,164		
Grupos	14			14			14		
Prob > F	0.0000			0.0000					
R2 within	0.5898								
R2 overall				0.3755					
Prob > chi2							0.0000		

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

Tabla B5. Estimaciones para la variable dependiente log Monóxido de carbono (ICO)

ICO	Estimaciones con errores estándar de Driscoll & Kraay						FGLS con estructura de errores heterocedásticos		
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.273084	0.0000	***	-0.329061	0.0000	***	-0.287494	0.0000	***
ITMP	-0.267030	0.0000	***	-0.107118	0.0350	**	-0.190283	0.0000	***
IWSP	-0.925116	0.0000	***	-0.929379	0.0000	***	-0.917682	0.0000	***
IPP	-0.014101	0.0000	***	-0.011986	0.0000	***	-0.012288	0.0000	***
diasem_1l									
1	0.000000			0.000000					
2	0.030700	0.0030	***	0.029509	0.0040	***	0.032707	0.0000	***
3	0.032577	0.0090	***	0.032962	0.0090	***	0.036952	0.0000	***
4	0.030527	0.0180	**	0.031224	0.0160	**	0.029347	0.0000	***
5	0.043966	0.0010	***	0.046497	0.0010	***	0.047155	0.0000	***
6	-0.076516	0.0000	***	-0.074097	0.0000	***	-0.083480	0.0000	***
7	-0.184487	0.0000	***	-0.183349	0.0000	***	-0.195499	0.0000	***
trim20t1	0.070402	0.0460	**	0.079935	0.0300	**	0.094388	0.0000	***
trim20t2	-0.141075	0.0000	***	-0.120556	0.0010	***	-0.115984	0.0000	***
trim20t3	0.024027	0.4570		0.054336	0.1400		0.048124	0.0000	***
trim20t4	0.170922	0.0000	***	0.214209	0.0000	***	0.187464	0.0000	***
trim21t1	0.309205	0.0000	***	0.313643	0.0000	***	0.295556	0.0000	***
trim21t2	0.269158	0.0000	***	0.264358	0.0000	***	0.252893	0.0000	***
trend	-0.000438	0.0000	***	-0.000476	0.0000	***	-0.000479	0.0000	***
cons	2.116274	0.0000	***	1.930885	0.0000	***	2.010873	0.0000	***
Observaciones	27,024			27,024			27,024		
Grupos	15			15			15		
Prob > F	0.0000			0.0000					
R2 within	0.5760								
R2 overall				0.5219					
Prob > chi2							0.0000		

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

Tabla B6. **Estimaciones para la variable dependiente log Ozono (IO3)**

IO3	Estimaciones con errores estándar de Driscoll & Kraay						FGLS con estructura de errores heterocedásticos		
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.400268	0.0000	***	-0.367620	0.0000	***	-0.372423	0.0000	***
ITMP	0.939158	0.0000	***	0.620808	0.0000	***	0.730776	0.0000	***
IWSP	-0.068160	0.0120	**	0.136450	0.0000	***	0.063454	0.0000	***
IPP	0.004727	0.2400		0.006475	0.1200		0.005529	0.0000	***
diasem_1l									
1	0.000000			0.000000					
2	-0.002706	0.8320		-0.002407	0.8550		-0.003146	0.6770	
3	-0.022131	0.1840		-0.024708	0.1540		-0.024625	0.0010	***
4	-0.003047	0.8490		-0.009514	0.5680		-0.007766	0.3040	
5	-0.019984	0.2340		-0.028780	0.0980	*	-0.026174	0.0010	***
6	0.035943	0.0150	**	0.032909	0.0330	**	0.032618	0.0000	***
7	0.083832	0.0000	***	0.084747	0.0000	***	0.083313	0.0000	***
trim20t1	-0.061727	0.1200		-0.092303	0.0370	**	-0.083283	0.0000	***
trim20t2	0.183728	0.0000	***	0.160148	0.0000	***	0.163686	0.0000	***
trim20t3	-0.023798	0.6110		-0.052954	0.2990		-0.044700	0.0000	***
trim20t4	0.034519	0.5290		-0.004722	0.9320		0.006080	0.5920	
trim21t1	-0.026394	0.5800		-0.033603	0.5470		-0.029263	0.0210	**
trim21t2	0.051763	0.4510		0.035207	0.6580		0.041749	0.0010	***
trend	-0.000028	0.1930		0.000009	0.6960		-0.000001	0.9030	
cons	2.345150	0.0000	***	2.943445	0.0000	***	2.702558	0.0000	***
Observaciones	29,624			29,624			29,624		
Grupos	16			16			16		
Prob > F	0.0000			0.0000					
R2 within	0.3121								
R2 overall				0.2184					
Prob > chi2							0.0000		

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

Tabla B7. **Estimaciones para la variable dependiente log Partículas finas (IPM2.5)**

IPM2.5	Estimaciones con errores estándar de Driscoll & Kraay						FGLS con estructura de errores heterocedásticos		
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.254584	0.0000	***	-0.305832	0.0000	***	-0.296719	0.0000	***
ITMP	0.146831	0.1360		0.056551	0.5190		0.052738	0.0450	**
IWSP	-0.853151	0.0000	***	-0.678341	0.0000	***	-0.672960	0.0000	***
IPP	-0.029257	0.0000	***	-0.025059	0.0000	***	-0.024575	0.0000	***
diasem_1l									
1	0.000000			0.000000					
2	0.035895	0.0560	*	0.036086	0.0540	*	0.037177	0.0040	***
3	0.054325	0.0140	**	0.053026	0.0170	**	0.052940	0.0000	***
4	0.059616	0.0080	***	0.053830	0.0180	**	0.052733	0.0000	***
5	0.055650	0.0200	**	0.050015	0.0400	**	0.049781	0.0000	***
6	0.038933	0.0820	*	0.038462	0.0930	*	0.038988	0.0020	***
7	-0.049239	0.0090	***	-0.047740	0.0120	**	-0.048501	0.0000	***
trim20t1	-0.034465	0.5660		-0.070932	0.2620		-0.062807	0.0010	***
trim20t2	0.106066	0.1080		0.085600	0.2140		0.087370	0.0000	***
trim20t3	-0.175032	0.0030	***	-0.202617	0.0010	***	-0.194916	0.0000	***
trim20t4	-0.074243	0.1770		-0.101514	0.0960	*	-0.091519	0.0000	***
trim21t1	-0.004489	0.9380		-0.043144	0.4790		-0.031000	0.1410	
trim21t2	0.039720	0.7280		-0.014717	0.9000		-0.001239	0.9570	
trend	-0.000071	0.0060	***	-0.000066	0.0160	**	-0.000067	0.0000	***
cons	4.209517	0.0000	***	4.557517	0.0000	***	4.532097	0.0000	***
Observaciones	12,979			12,979			12,979		
Grupos	8			8			8		
Prob > F	0.0000			0.0000					
R2 within	0.3145								
R2 overall				0.2847					
Prob > chi2							0.0000		

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

Tabla B8. **Estimaciones para la variable dependiente log Partículas gruesas y finas (IPM10)**

IPM10	Estimaciones con errores estándar de Driscoll & Kraay						FGLS con estructura de errores heterocedásticos		
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.531665	0.0000	***	-0.533426	0.0000	***	-0.516724	0.0000	***
ITMP	-0.002074	0.9760		0.002816	0.9650		-0.004921	0.8060	
IWSP	-0.568089	0.0000	***	-0.512579	0.0000	***	-0.507371	0.0000	***
IPP	-0.047180	0.0000	***	-0.047297	0.0000	***	-0.047380	0.0000	***
diasem_1l									
1	0.000000			0.000000					
2	0.061767	0.0000	***	0.062825	0.0000	***	0.063526	0.0000	***
3	0.080894	0.0000	***	0.081284	0.0000	***	0.082338	0.0000	***
4	0.088576	0.0000	***	0.088193	0.0000	***	0.088754	0.0000	***
5	0.074842	0.0000	***	0.074485	0.0000	***	0.075034	0.0000	***
6	0.000423	0.9810		0.000888	0.9600		0.003542	0.7320	
7	-0.136562	0.0000	***	-0.135741	0.0000	***	-0.136317	0.0000	***
trim20t1	0.091369	0.0650	*	0.083043	0.0910	*	0.089599	0.0000	***
trim20t2	0.034021	0.4830		0.059072	0.2400		0.060683	0.0000	***
trim20t3	-0.127190	0.0120	**	-0.132712	0.0100	***	-0.128101	0.0000	***
trim20t4	0.022020	0.6180		0.026118	0.5710		0.028858	0.0610	*
trim21t1	0.062481	0.2080		0.041463	0.3950		0.044519	0.0080	***
trim21t2	-0.059453	0.5270		-0.081907	0.3780		-0.089497	0.0000	***
trend	-0.000102	0.0000	***	-0.000112	0.0000	***	-0.000109	0.0000	***
cons	6.175417	0.0000	***	6.146420	0.0000	***	6.107070	0.0000	***
Observaciones	16,410			16,410			16,410		
Grupos	10			10			10		
Prob > F	0.0000			0.0000					
R2 within	0.4595								
R2 overall				0.4204					
Prob > chi2							0.0000		

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.

Tabla B9. Estimaciones para la variable dependiente log Partículas de fracción gruesa (IPMCO)

IPMCO	Estimaciones con errores estándar de Driscoll & Kraay						FGLS con estructura de errores heterocedásticos		
	Efectos fijos			Efectos aleatorios			Coef.	p-value	
	Coef.	p-value		Coef.	p-value				
IRH	-0.543094	0.0000	***	-0.566824	0.0000	***	-0.558915	0.0000	***
ITMP	-0.051891	0.4870		0.166056	0.0230	**	0.172762	0.0000	***
IWSP	-0.278737	0.0000	***	-0.286314	0.0000	***	-0.298684	0.0000	***
IPP	-0.070872	0.0000	***	-0.072111	0.0000	***	-0.070609	0.0000	***
diasem_1l									
1	0.000000			0.000000					
2	0.076497	0.0000	***	0.077796	0.0000	***	0.077464	0.0000	***
3	0.098299	0.0000	***	0.100442	0.0000	***	0.100715	0.0000	***
4	0.114586	0.0000	***	0.117597	0.0000	***	0.116233	0.0000	***
5	0.093270	0.0000	***	0.098501	0.0000	***	0.097258	0.0000	***
6	-0.022359	0.2380		-0.018316	0.3390		-0.018810	0.2100	
7	-0.238449	0.0000	***	-0.235598	0.0000	***	-0.235267	0.0000	***
trim20t1	0.121489	0.0050	***	0.136161	0.0030	***	0.121504	0.0000	***
trim20t2	-0.138841	0.0140	**	-0.121626	0.0380	**	-0.137279	0.0000	***
trim20t3	-0.256206	0.0000	***	-0.254873	0.0000	***	-0.261036	0.0000	***
trim20t4	-0.060773	0.1820		-0.040263	0.4320		-0.047683	0.0340	**
trim21t1	-0.064125	0.2820		-0.083437	0.1730		-0.088836	0.0000	***
trim21t2	-0.454381	0.0000	***	-0.506286	0.0000	***	-0.545919	0.0000	***
trend	-0.000042	0.0770	*	-0.000076	0.0030	***	-0.000065	0.0000	***
cons	5.324981	0.0000	***	4.837152	0.0000	***	4.814951	0.0000	***
Observaciones	9,153			9,153			9,153		
Grupos	6			6			6		
Prob > F	0.0000			0.0000					
R2 within	0.5443								
R2 overall				0.5008					
Prob > chi2							0.0000		

Nivel de significancia: *** 1%, ** 5%, * 10%.
Fuente: BBVA Research.


8.4. Concentraciones históricas de ozono en la ZMVM

Tabla C1. Promedio móvil de 8 horas de ozono en la ZMVM, 1990-2021

LEYENDA		
Calidad del aire	Concentración (ppb)	COLOR
Buena	0 - 51	Verde
Regular	52 - 70	Amarillo
Mala	71 - 92	Naranja
Muy Mala	93 - 114	Rojo
Extremadamente Mala	>=115	Púrpura



Mosaico de ozono, cada celda corresponde a la concentración del valor máximo del promedio de ocho horas registrado por día entre 1990 y 2021. Para fines comparativos, el color de la celda indica la calidad del aire de acuerdo con los rangos del índice Aire y Salud vigentes a 2021.



Fuente: Sistema de Monitoreo Atmosférico de la Ciudad de México (Simat), 2021).

Documentos de trabajo

2022

22/09 **Luis Antonio Espinosa Carrasco, Juan José Li Ng:** México | ¿El confinamiento por COVID-19 redujo la contaminación del aire?

22/08 **Ángel de la Fuente:** La liquidación de 2020 del sistema de financiación de las comunidades autónomas de régimen común.

22/07 **Ángel de la Fuente y Pep Ruiz Aguirre:** Series largas de VAB y empleo regional por sectores, 1955-2020. Actualización de RegData-Sect hasta 2020.

22/06 **Guillermo Jr. Cárdenas Salgado, Juan José Li Ng, Héctor Ortega Rosas, Susana Ramos Villaseñor, Carlos Serrano Herrera, Elmer Solano Flores:** ¿Los SMS nudges promueven la salud financiera?

22/05 **Shulin Shen, Le Xia, Yulin Shuai, Da Gao:** Measuring news media sentiment using Big Data for Chinese stock markets.

22/04 **Ángel de la Fuente:** Las finanzas autonómicas en 2021 y entre 2003 y 2021.

22/03 **José E. Boscá, José Cano, Javier Ferri:** Covid-19 in Spain during 2021: what have vaccines achieved and what is the health cost of vaccine hesitancy?.

22/02 **Adriana Haring and Mario Iparraguirre:** Argentina. Futuro de los sectores post pandemia.

22/01 **Ángel de la Fuente:** Series largas de algunos agregados económicos y demográficos regionales: actualización de RegData hasta 2020 (RegData y RegData Dem versión 6.1-2020).

2021

21/11 **Ángel de la Fuente and Rafael Doménech:** Cross-country data on skills and the quality of schooling: a selective survey.

21/10 **Ángel de la Fuente:** La evolución de la financiación de las comunidades autónomas de régimen común, 2002-2019.

21/09 **Ángel de la Fuente:** La liquidación de 2019 del sistema de financiación de las comunidades autónomas de régimen común.

21/08 **Rodolfo Méndez-Marcano:** A global vector autoregressive model for banking stress testing.

21/07 **Ali B. Barlas, Seda Guler Mert, Berk Orkun Isa, Alvaro Ortiz, Tomasa Rodrigo, Baris Soybilgen and Ege Yazgan:** Big Data Information and Nowcasting: Consumption and Investment from Bank Transactions in Turkey.

21/06 **Ángel de la Fuente y Rafael Doménech:** El nivel educativo de la población en España y sus regiones: actualización hasta 2019.

21/05 **Saidé Salazar, Jaime Oliver, Álvaro Ortiz, Tomasa Rodrigo and Ignacio Tamarit:**

ESP/ Patrones de Consumo de Efectivo vs Tarjeta en México: una aproximación Big Data.

ING / Cash Vs Card Consumption Patterns in Mexico: A Machine Learning Approach.

21/04 **Ángel de la Fuente:** La financiación autonómica en 2020: una primera aproximación y una propuesta de cara a 2021.

21/03 **Ángel de la Fuente:** Las finanzas autonómicas en 2020 y entre 2003 y 2020.

21/02 **Joxe Mari Barrutiabengoa, J. Julián Cubero and Rodolfo Méndez-Marcano:** Output-side GHG Emissions Intensity: A consistent international indicator.

21/01 **Ángel de la Fuente y Pep Ruiz:** Series largas de VAB y empleo regional por sectores, 1955-2019 Actualización de *RegData-Sect* hasta 2019.

HAGA CLIC PARA ACCEDER A LOS DOCUMENTOS DE TRABAJO PUBLICADOS EN
Español e Inglés

AVISO LEGAL

El presente documento no constituye una "Recomendación de Inversión" según lo definido en el artículo 3.1 (34) y (35) del Reglamento (UE) 596/2014 del Parlamento Europeo y del Consejo sobre abuso de mercado ("MAR"). En particular, el presente documento no constituye un "Informe de Inversiones" ni una "Comunicación Publicitaria" a los efectos del artículo 36 del Reglamento Delegado (UE) 2017/565 de la Comisión de 25 de abril de 2016 por el que se completa la Directiva 2014/65/UE del Parlamento Europeo y del Consejo en lo relativo a los requisitos organizativos y las condiciones de funcionamiento de las empresas de servicios de inversión ("MiFID II").

Los lectores deben ser conscientes de que en ningún caso deben tomar este documento como base para tomar sus decisiones de inversión y que las personas o entidades que potencialmente les puedan ofrecer productos de inversión serán las obligadas legalmente a proporcionarles toda la información que necesiten para esta toma de decisión.

El presente documento, elaborado por el Departamento de BBVA Research, tiene carácter divulgativo y contiene datos u opiniones referidas a la fecha del mismo, de elaboración propia o procedentes o basadas en fuentes que consideramos fiables, sin que hayan sido objeto de verificación independiente por BBVA. BBVA, por tanto, no ofrece garantía, expresa o implícita, en cuanto a su precisión, integridad o corrección.

El contenido de este documento está sujeto a cambios sin previo aviso en función, por ejemplo, del contexto económico o las fluctuaciones del mercado. BBVA no asume compromiso alguno de actualizar dicho contenido o comunicar esos cambios.

BBVA no asume responsabilidad alguna por cualquier pérdida, directa o indirecta, que pudiera resultar del uso de este documento o de su contenido.

Ni el presente documento, ni su contenido, constituyen una oferta, invitación o solicitud para adquirir, desinvertir u obtener interés alguno en activos o instrumentos financieros, ni pueden servir de base para ningún contrato, compromiso o decisión de ningún tipo.

El contenido del presente documento está protegido por la legislación de propiedad intelectual. Queda expresamente prohibida su reproducción, transformación, distribución, comunicación pública, puesta a disposición, extracción, reutilización, reenvío o la utilización de cualquier naturaleza, por cualquier medio o procedimiento, salvo en los casos en que esté legalmente permitido o sea autorizado expresamente por BBVA en su sitio web www.bbvarresearch.com.

Este informe ha sido elaborado por:

Economista Senior

Luis Antonio Espinosa Carrasco
luisantonio.espinosa.carrasco@bbva.com

Economista Senior

Juan José Li Ng
juan.li@bbva.com

Todos los análisis, opiniones, errores y omisiones son responsabilidad únicamente de los autores.

Se agradecen los comentarios y revisión realizados por:

Economista Líder

Julián Cubero Calvo
juan.cubero@bbva.com

Economista

Jose Antonio Montero Guillen
joseantonio.montero.guillen.becas@bbva.com

INTERESADOS DIRIGIRSE A:

BBVA Research – BBVA: Paseo de la Reforma 510, Colonia Juárez, C.P. 06600 Ciudad de México, México.
Tel.: +52 55 5621 3434
bbvaresearch@bbva.com www.bbvaresearch.com