



Universidad de Concepción
Facultad de Ingeniería
Programa de Doctorado en Energías

**Estudio de los efectos en la calidad del aire de grandes impactos globales al sistema energético:
Un enfoque basado en imágenes satelitales y Machine Learning.**

Tesis para optar al grado de Doctor en Energías.

Por Matias Iván Volke Oyarzun

Profesor Guía: Héctor Hito Andrés Sepúlveda Allende
Facultad de Ingeniería, Universidad de Concepción

Concepción-Chile, abril 2025

© 2025, **Matías Iván Volke Oyarzún**

Se autoriza la reproducción total o parcial, con fines académicos, incluyendo siempre la cita bibliográfica del presente documento y su autor.

Comisión Evaluadora de Tesis de Grado

Dr. Héctor Hito Andrés Sepúlveda Allende
Director de Tesis
Facultad de Ciencias Físicas y Matemáticas
Universidad de Concepción

Dr. Jorge Jiménez del Río
Evaluador Interno
Facultad de Ingeniería
Universidad de Concepción

Dr. Francisco de la Barrera Melgarejo
Evaluador Interno
Facultad de Ciencias Ambientales
Universidad de Concepción

Dr. Carlos Lara Peña
Evaluador Externo
Facultad de Ciencias
Universidad Católica de la Santísima Concepción

Agradecimientos

Mi más sincero agradecimiento al director de programa, Dr. Cristian Mardones, por su apoyo constante, orientación y confianza durante todo este proceso, especialmente, en los momentos de incertidumbre. También a mi profesor guía, Dr. Andrés Sepúlveda, le agradezco profundamente por su apoyo en este proceso. Sus conocimientos y orientación han sido esenciales para culminar esta tesis. No puedo dejar de agradecer a la comisión evaluadora, por su tiempo, dedicación y por los valiosos comentarios que han contribuido enormemente a mejorar el trabajo presentado. Finalmente agradecer enormemente a la Doctora Lisdelys Gonzalez-Rodriguez por compartir su conocimiento y su encomiable apoyo.

Esta tesis doctoral fue apoyada por el financiamiento del concurso ANID Doctorado Nacional/2019.

Índice de contenido

Capítulo 1	6
1.1. Introducción	6
1.2. Marco Teórico.....	7
1.2.1. BigData.....	7
1.2.2. Teledetección para el monitoreo de la polución atmosférica.....	7
1.2.3. Datos satelitales de Profundidad Optica de Aerosol (AOD)	10
1.2.4. Datos satelitales de Dióxido de Nitrógeno	10
1.2.5. Machine Learning (ML)	11
1.2.5.1. Aprendizaje supervisado.....	11
1.2.5.1.1. k-nearest neighbour (kNN).....	11
1.2.5.1.2. Gradient Boosting Machine (GBM)	12
1.2.5.1.3. Random Forest (RF)	13
1.2.5.1.4. Support Vector Machine (SVM)	14
1.2.5.1.5. Extreme Gradient Boosting (XGBoost)	14
1.2.5.2. Aprendizaje no supervisado.....	14
1.2.5.2.1. Algoritmos de Agrupamiento Jerárquico	15
1.2.5.2.2. Factorización de Matriz No Negativa	15
1.3. Consumo energético y Calidad del aire	15
1.4. Matrices energéticas, pobreza energética y su influencia en la calidad del aire urbano.....	20
1.5. Fuentes de datos de contaminación atmosférica	21
1.6. Hipótesis de trabajo:.....	22
1.7. Objetivos:	22
1.7.1. Objetivo general:	22
1.7.2. Objetivos específicos:.....	22
1.8. Estructura de la tesis	23
Capitulo 2:	28
Abstract.....	29
2.1. Introducción	30
2.2. Datos y metodología	32
2.2.1. Área y período de estudio.....	32
2.2.2. Recopilación de datos	35
2.2.2.1. Datos del satélite Sentinel-5P (TROPOMI)	35
2.2.2.2. Datos del satélite Aura (OMI).....	35
2.2.2.3. Conjunto de datos meteorológicos ERA5	35
2.2.2.4. Datos de movilidad (MOB).....	36
2.2.3. Análisis estadístico	36
3. Resultados.....	39
3.1. 1 ^{era} etapa: Comparación de TROPOMI NO ₂ Concentraciones en cada ciudad (2019 vs. 2020)	39
2.3.2. 2 ^{da} etapa: TropoNO ₂ revisión histórica, TROPOMI respaldado por datos de OMI y meteorología	

ERA5.....	41
2.3.3. 3 ^{era} etapa: Relación entre las concentraciones de NO ₂ y categorías de movilidad de Google y Apple	42
2.3.4. 4 ^{ta} etapa: Factorización de matrices no negativas (NMF)	43
2.4. Discusión	43
2.5. Conclusión	45
Referencias.....	46
Capitulo 3:	50
Abstract.....	51
3.1. Introducción	52
3.2. Metodología	53
3.2.1 Área de estudio	53
3.2.2 Marco metodológico	54
3.2.3 Bases de datos satelitales y de reanálisis.....	55
3.2.4 Indicadores de consumo energético	56
3.2.5 Análisis de datos y validación	56
3.3. Resultados	57
3.3.1 Concentración anual de NO ₂ troposférico durante las crisis de 2009 y 2020	57
3.3.2. Modelos de normalización meteorológica	58
3.3.3 Correlación con los Indicadores de Consumo Energético.....	61
3.3.4 Análisis de causalidad entre NL y tropoNO ₂	62
3.4. Discusión	63
3.5. Conclusión	65
Capitulo 4:	70
Abstract.....	71
4.1. Introducción	73
4.2. Metodología	75
4.2.1 Área de estudio	75
4.2.2 Marco Metodologico	76
4.2.5 Análisis de Datos.....	78
4.2.5.1 Factorización de Matrices No Negativa (NMF).....	78
4.2.5.2 Clusterización Jerárquica.....	78
4.3. Resultados	79
4.3.1 Promedios anuales de tropoNO ₂ y AOD	79
4.3.2 Correlaciones entre indicadores energéticos y proxies de contaminación atmosférica.	81
4.3.3 Análisis de factorización y clusterización	82
4.3.2.1 Relación grupos tropoNO ₂ con respecto a variables energéticas.....	83
4.3.2.2 Relación grupos AOD con respecto a variables energéticas.....	84
4.4. Discusión	84

4.5. Conclusión	87
Capítulo 5:.....	91
5.1. Conclusión	91

Índice de Figuras

Figura 1.1. Representación de la radiación dispersada o emitida captada por el satélite (Fuente: Programa de entrenamiento en Percepción Remota, NASA).....	8
Figura 1.2. Representación del paso orbital de OMI. Fuente: NASA ARSET....	¡Error! Marcador no definido.0
Figura 1.3. Representación del paso orbital de TROPOMI. Fuente: NASA ARSET.;	¡Error! Marcador no definido.1
Figura 1.4. Esquema conceptual que integra la aplicación de distintos algoritmos de aprendizaje automático para identificar relaciones entre variables, y la detección de patrones y clasificación de megaciudades considerando sus perfiles energéticos y socioeconómicos.....	13
Figura 1.5. Resumen esquemático para reflejar la relación entre el sistema energético, la contaminación atmosférica y los contextos de crisis.....	¡Error! Marcador no definido.
Figura 2.1. Área de estudio. Los círculos de colores corresponden al número de habitantes. Las series temporales de medias y diferencias semanales de tropoNO ₂ se muestran para los valores entre los años 2019 y 2020 para las seis ciudades que presentaron las diferencias más significativas. La serie va desde la semana 9, correspondiente a la primera semana de marzo, hasta la semana 26, correspondiente a la última semana de junio. El color de fondo muestra el nivel de confinamiento. Los datos poblacionales: (IBGE, 2020), (INEGI, 2020), (INEI, 2020), (DANE, 2018), (INE, 2017), (INDEC, 2020), (INEC, 2020), (INE, 2012), (INE, 2011a) y (INE, 2011b).....	344
Figura 2.2. Diagrama de caja mensual para NO ₂ troposférico Distribuciones para los años 2019 y 2020. El diagrama de caja de 2019 se muestra en verde y el de 2020 en rojo, con el valor medio marcado con un punto negro en el diagrama de caja. Los valores porcentuales por encima de cada diagrama de caja denotan la variación porcentual de NO ₂ valores entre los dos años. Allí, *, ** y *** denotan el nivel de significación estadística de la diferencia, correspondiente a significaciones bajas ($0,01 \leq p < 0,05$), medias ($0,001 \leq p < 0,01$) y altas ($p < 0,001$). Las flechas negras denotan un aumento (dirección hacia arriba) o una disminución (dirección hacia abajo) en NO ₂ (2020 menos 2019). (Para la interpretación de las referencias al color en esta leyenda de la figura, se remite al lector a la versión web de este artículo).	¡Error! Marcador no definido.7
Figura 2.3. Mapas de medias mensuales (2019 y 2020) y la diferencia entre tropoNO ₂ valores de ROIs de las seis ciudades que presentaron las diferencias más significativas para el período analizado (LIM, SCL, SAO, RIO, UIO, BOG). Los mapas corresponden al mes que mostró la diferencia más significativa en cada caso (abril – LIM, SAO, UIO y BOG; Mayo – RÍO; Junio – SCL). El valor mensual promedio para 2019 (izquierda), el valor mensual promedio para 2020 (centro) y la diferencia entre 2019 y 2020 (derecha) se indican en cada subdivisión. Los valores representados se expresan en unidades de Moléculas/cm ² . Nota: LIM: Lima; SCL: Santiago; SAO: São Pablo; RÍO: Río de Janeiro; UIO: Quito; BOG: Bogotá.	388
Figura 2.4. Gráfico resumen de los valores medios (círculo exterior) y las diferencias (círculo central) de tropoNO ₂ para el período total comprendido entre marzo y junio. Los colores verde y rojo del círculo exterior corresponden a valores medios de 2020 y 2019, respectivamente. (Para la interpretación de las referencias al color en esta leyenda de la figura, se remite al lector a la versión web de este artículo).....	411
Figure 3.1. Área de estudio: Santiago Metropolitano (33,5°S, 70,6°O). El recuadro rojo está centrado sobre Santiago y delimita el área a partir de la cual se extrajeron los datos satelitales y de reanálisis utilizados en este estudio.....	54
Fig. 3.2: Diagrama de flujo de las principales etapas del método.	¡Error! Marcador no definido.5
Fig. 3.3.: A - Serie temporal de las concentraciones promedio anuales de NO ₂ troposférico (2006-2020); B -	

Diagrama de caja que muestra la distribución de las concentraciones diarias de NO ₂ para toda la serie (2006-2020) y para los años de crisis globales con impacto en el consumo energético (2009 y 2020).	58
Fig. 3.4. Datos OMI frente a datos previstos. A- 2009; B- 2014; C- 2018; D- 2020.	60
Figura 3.5. Comparación de las series temporales de los promedios anuales de tropoNO ₂ (2006-2020) con: A - Precio del petróleo crudo (Crude Oil Price, COP); B - Consumo primario de energía fósil (Fossil Fuel Primary Energy Consumption, FFPEC); C - Consumo de energía per cápita (Per Capita Energy Use, PCEU).	61
Figura 3.6. Análisis de causalidad y fuerza de interacción entre la radiación promedio de luces nocturnas (NL) y las concentraciones de dióxido de nitrógeno troposférico (tropoNO ₂) en Santiago. (Izquierda) Resultados de Convergent Cross Mapping (CCM) que muestran una habilidad de mapeo cruzado positiva y creciente (ρ) desde NL hacia tropoNO ₂ a medida que aumenta el tamaño de la librería. (Derecha) Análisis S-Map que muestra la variación temporal en la fuerza de interacción de NL sobre tropoNO ₂ (línea roja), con la fuerza de interacción promedio representada por la línea discontinua.....	62
Figura 4.1. Localización geográfica de las 34 megaciudades consideradas en este estudio.....	75
Fig. 4.2: Diagrama de flujo que muestra los pasos principales del método: EI (Intensidad Energética), FFPEC (Consumo Primario de Energía Fósil), PCEU (Consumo de Energía Per Cápita) y NL (Luces Nocturnas), Producto Interno Bruto per cápita (PIB, en dólares constantes de 2015) e Índice de Desempeño Ambiental (EPI).	766
Fig. 4.3.: Promedios anuales de tropoNO ₂ (gráficas azules) y AOD (gráficas rojas) en (a) Norteamérica, (b) Asia, (c) África, (d) Europa, (e) Oceanía y (f) Sudamérica durante los años 2005-2022.	80
Fig. 4.4. Matrices de correlación entre los promedios anuales de AOD y tropoNO ₂ para las megaciudades estudiadas, en relación con las variables energéticas: EI (Intensidad Energética), FFPEC (Consumo Primario de Energía Fósil), PCEU (Uso de Energía Per Cápita), NL (Luces Nocturnas) y FFPI (Índice de Precios de Combustibles Fósiles). Las correlaciones positivas se representan en tonos rojos, mientras que las correlaciones negativas se muestran en tonos azules.	81
Fig. 4.5: Dendrograma de agrupamiento jerárquico basado en los componentes de NMF de tropoNO ₂ (A) y AOD (B), calculados a partir de las diferencias entre años normales y años de crisis económicas.	83

Índice de Tablas

Tabla1.1. Estudios que utilizan imágenes satelitales para el monitoreo de la contaminación atmosférica.	9
Tabla1.2. Resumen bibliográfico.....	20
Tabla 2.1. Las escalas de restricción de las actividades y la movilidad de los ciudadanos se basan en las políticas adoptadas por los gobiernos nacionales y subnacionales.	322
Tabla 2.2. Valores de correlación entre tropoNO ₂ y datos de movilidad de Google y Apple.....	422
Tabla 3.1. Lista de variables e indicadores de consumo energético.	56
Tabla 3.2: Comparación de las concentraciones promedio anuales de NO ₂ (Pmolec/cm ²) observadas y obtenidas mediante la técnica de normalización meteorológica.....	58
Tabla 3.3.: Matriz de correlación de los promedios anuales de tropoNO ₂ (2006-2020) vs: Precio del petróleo crudo (Crude Oil Price, COP), Consumo primario de energía fósil (Fossil Fuel Primary Energy Consumption, FFPEC) y Consumo de energía per cápita (Per Capita Energy Use, PCEU).	62
Table 4.1. List of Variables and indicators of Energy Consume	777

Resumen

La contaminación atmosférica en entornos urbanos, especialmente en megaciudades, está estrechamente vinculada al consumo energético basado en combustibles fósiles y constituye una de las principales amenazas para la salud y la sostenibilidad urbana. Esta tesis aborda la relación entre sistemas energéticos y calidad del aire a escala global, evaluando el impacto de crisis económicas y sanitarias en dióxido de nitrógeno (NO_2) y profundidad óptica de aerosoles (AOD) como proxy del material particulado fino mediante datos satelitales, indicadores energéticos y socioeconómicos, técnicas de aprendizaje automático y normalización meteorológica.

Si bien existen múltiples estudios sobre la relación entre energía y contaminación atmosférica, la mayoría se centra en escalas locales o regionales y emplea datos de estaciones de monitoreo terrestre o modelos de transporte químico, los cuales no permiten analizar con precisión variaciones abruptas en la contaminación durante eventos excepcionales como crisis económicas, sanitarias o geopolíticas. En particular, no existe un análisis a gran escala que examine la relación entre el sistema energético y la calidad del aire en múltiples regiones del mundo. Por ello, esta tesis tiene como objetivo evaluar el impacto de eventos globales en la calidad del aire mediante modelos estadísticos basados en datos satelitales. Primero, a partir de observaciones del satélite Sentinel-5P (TROPOMI), se evaluó el efecto de las restricciones de movilidad durante la primera ola de la pandemia de COVID-19 (marzo–junio 2020) en 12 ciudades latinoamericanas. Se detectaron reducciones estadísticamente significativas de tropo NO_2 en Lima (-47,5%), Santiago (-36,1%), São Paulo (-27%) y Río de Janeiro (-23%). La evidencia de los descensos significativos y simultáneos en las emisiones de las principales capitales de Latinoamérica, se presenta como evidencia de que esta reducción se debió a la menor movilidad urbana y no a factores meteorológicos.

Posteriormente, mediante datos de OMI (2005–2020) y modelos de normalización meteorológica basados en machine learning, se cuantificaron las variaciones de tropo NO_2 en Santiago durante la crisis financiera 2008–2009 (-3%) y la pandemia 2020 (-27%). La correlación entre tropo NO_2 y variables energéticas fue positiva y significativa, aunque las luces nocturnas (NL) no mostraron patrones lineales consistentes. Para abordar esta limitación, se aplicaron métodos de Empirical Dynamic Modeling (EDM), revelando una relación causal no lineal y variable en el tiempo entre NL y tropo NO_2 . Estos resultados muestran que eventos globales pueden inducir cambios temporales importantes en la calidad del aire, cuya magnitud y persistencia dependen de factores estructurales del sistema energético.

En el último capítulo, se analizaron 34 megaciudades (2005–2022) integrando datos satelitales de tropo NO_2 (OMI) y AOD (MODIS) con indicadores energéticos, socioeconómicos y de gobernanza ambiental. tropo NO_2 mostró correlaciones más fuertes y consistentes con intensidad energética (EI), consumo per cápita (PCEU) y consumo fósil (FFPEC) que la AOD. Mediante factorización de matrices no negativas (NMF) y agrupamiento jerárquico se identificaron tres patrones principales de respuesta ante crisis globales: i) Reducciones pronunciadas y sostenidas en contaminación, asociadas a alta eficiencia energética y estricta regulación ambiental (ej. París, Tokio, Nueva York); ii) Reducciones moderadas y rápida recuperación, con mejoras temporales influenciadas por limitaciones estructurales (ej. Santiago, Atenas, Bogotá); iii) Cambios mínimos o poco sostenidos, vinculados a alta intensidad energética y baja gobernanza ambiental (ej. Beijing, Moscú, Lagos). En AOD, las ciudades desarrolladas mostraron mayor estabilidad, mientras que las dependientes de biomasa o industria no regulada registraron alta variabilidad durante crisis.

En conjunto, la tesis confirma que las crisis globales generan respuestas heterogéneas en la calidad del aire urbano, determinadas por las características energéticas, socioeconómicas y regulatorias de cada ciudad. El tropo NO_2 , por su fuerte vínculo con actividades de combustión, es un indicador más sensible que la AOD para evaluar el impacto de estos eventos. La combinación de observaciones satelitales, normalización meteorológica y machine learning permite no solo cuantificar las variaciones en periodos de crisis, sino también clasificar ciudades según su resiliencia y capacidad de respuesta. Estos hallazgos aportan una base sólida para orientar políticas de transición energética, electrificación del transporte y fortalecimiento de la gobernanza ambiental, con el fin de mejorar la calidad del aire y la resiliencia urbana frente a futuros escenarios de disrupción global.

Capítulo 1

1.1. Introducción

La reducción de la contaminación atmosférica es uno de los ejes centrales de los Objetivos de Desarrollo Sostenible (ODS) de Naciones Unidas (UN, 2015). Entre las fuentes antrópicas más relevantes de dicha contaminación, la generación y el consumo de energía ocupan un lugar prioritario (Wang et al., 2019), debido a sus impactos tanto locales como globales: desde el calentamiento global (Jacobson et al., 2022) y el deterioro de servicios ecosistémicos (Wei et al., 2017), hasta la degradación de la calidad del aire urbano. Esta última constituye un problema de salud pública de primer orden, dado que la exposición prolongada a contaminantes como el dióxido de nitrógeno (NO_2) y el material particulado fino ($\text{PM}_{2.5}$) provoca efectos severos en la salud humana, incluyendo un aumento significativo de la mortalidad prematura (Huangfu et al., 2020; Song et al., 2019; Cohen et al., 2017).

Los sistemas energéticos y la calidad del aire están vinculados por interacciones directas e indirectas (Yang et al., 2016). Las primeras corresponden a las emisiones de contaminantes criterio y de efecto invernadero derivadas de la combustión de combustibles fósiles en el transporte, la industria y el sector residencial. Las segundas incluyen factores socioeconómicos, geopolíticos y de seguridad de suministro, que moldean los patrones de uso energético y modifican, a su vez, las emisiones y su distribución espacial y temporal. En este contexto, el consumo energético en sectores como el comercial y el residencial constituye uno de los principales contribuyentes globales a las emisiones de partículas y a la mortalidad asociada a la contaminación atmosférica (Lelieveld et al., 2015).

Durante crisis globales, de origen económico, sanitario o geopolítico, estos patrones de consumo energético pueden alterarse de forma abrupta, produciendo cambios notorios en la calidad del aire. Sin embargo, la mayor parte de los estudios existentes se han realizado a escala local o regional, utilizando datos de estaciones de monitoreo terrestre o modelos de transporte químico basados en inventarios de emisiones que no capturan adecuadamente variaciones repentinas durante eventos excepcionales. A ello se suma que, para contaminantes como el NO_2 y el $\text{PM}_{2.5}$, estrechamente ligados a fuentes energéticas, se requieren datos con amplia cobertura espacial y temporal para identificar tendencias y vincularlas de forma robusta con cambios en el sistema energético.

Este vacío se hace especialmente evidente en el análisis comparativo entre regiones con distintos niveles de desarrollo, pobreza energética y estructura de matriz energética, ya que las respuestas de la calidad del aire ante cambios en el consumo energético no son homogéneas. Mientras en ciudades con alta eficiencia energética y estricta regulación ambiental (por ejemplo, Tokio, Berlín o París) las reducciones en movilidad pueden traducirse rápidamente en descensos significativos de NO_2 , en urbes con alta pobreza energética (como Dhaka o Lagos) la persistencia de fuentes domésticas e informales puede limitar la magnitud de estas reducciones. Frente a estas limitaciones, las observaciones satelitales ofrecen una alternativa única, al proporcionar información con cobertura global, alta resolución espacial y continuidad temporal. Esto permite monitorear de manera sistemática contaminantes como el NO_2 troposférico (tropoNO_2) y la profundidad óptica de aerosoles (AOD), facilitando análisis comparativos y la detección de patrones globales y regionales.

En este contexto, el objetivo general de esta tesis es evaluar el impacto de eventos globales sobre la calidad del aire en megaciudades, en relación con cambios en los sistemas energéticos, mediante el uso de datos satelitales y modelos estadísticos avanzados. De este objetivo general se desprenden tres objetivos específicos:

- Evaluar el comportamiento de contaminantes atmosféricos (tropoNO_2 y AOD) durante crisis globales como la pandemia de COVID-19 y la crisis financiera de 2008–2009, utilizando datos satelitales y técnicas de normalización meteorológica.
- Aplicar técnicas de Machine Learning (ML) para identificar relaciones entre variaciones en la contaminación atmosférica y eventos de crisis, integrando información satelital, meteorológica y energética.
- Identificar patrones y tendencias en las series temporales (2005–2022) de tropoNO_2 y AOD, y clasificar megaciudades según su respuesta durante crisis globales, considerando sus perfiles energéticos y socioeconómicos.

La relevancia de este trabajo radica en que permite comparar la respuesta de diferentes contextos socioeconómicos frente a crisis globales, aportando información clave para el diseño de estrategias de mitigación y políticas energéticas adaptadas a la realidad de cada ciudad. Además, el enfoque propuesto, basado en datos satelitales y modelos estadísticos, representa una herramienta innovadora para el monitoreo de la calidad del aire, aplicable incluso en regiones con limitada o nula

cobertura de estaciones de monitoreo terrestre, y útil para anticipar el impacto de futuras transiciones energéticas como la electromovilidad o la descarbonización de la matriz energética.

1.2. Marco Teórico

1.2.1. BigData

El término big data surgió a mediados de la década de 1990 (Li et al., 2016) y se popularizó en 2006 (Moed, 2012), describiendo conjuntos de datos de tal volumen, variedad y velocidad que resultan imposibles de manejar con herramientas convencionales (Laney, 2001). En las ciencias de la Tierra, el crecimiento del geo-big data ha transformado la forma en que observamos y comprendemos el planeta, con volúmenes de almacenamiento que ya superan decenas de petabytes y tasas de transmisión de cientos de terabytes por día (Reichstein et al., 2019). Estas bases de datos integran información de teledetección multiescala, observaciones in situ, sensores autónomos, modelación numérica y fuentes socioeconómicas, lo que exige métodos capaces de integrar múltiples escalas espaciales, temporales y espectrales, y de procesar flujos no lineales y altamente heterogéneos (Liu, 2015; Li et al., 2016). El desafío es mayor si consideramos que la capacidad para recopilar y generar datos crece mucho más rápido que nuestra habilidad para asimilarlos, analizarlos y extraer conocimiento útil en tiempo casi real, especialmente cuando se requiere integrar disciplinas y detectar patrones subyacentes.

En el caso de la calidad del aire, este tipo de datos es clave, ya que el aire es un recurso esencial para la vida y su deterioro constituye una de las amenazas más graves para la salud y el medio ambiente (Blacksmith Institute, 2008). La contaminación atmosférica, impulsada por el crecimiento urbano, el transporte y las actividades industriales, afecta especialmente a niños y personas mayores, provocando desde irritaciones y reacciones alérgicas hasta enfermedades respiratorias, cardiovasculares, daño neurológico y cáncer (Kang et al., 2018). A nivel ambiental, contribuye a la degradación de la capa de ozono, a la formación de lluvia ácida, al deterioro de ecosistemas y al cambio climático. Tradicionalmente, su evaluación y predicción se ha basado en métodos físicos y estadísticos que, aunque útiles, presentan limitaciones: baja capacidad para predecir extremos, dificultad para establecer umbrales, escasa adaptabilidad a cambios temporales y un tratamiento homogéneo de datos antiguos y recientes, lo que limita su precisión y valor predictivo (Niharika et al., 2017).

El avance de la capacidad de cómputo, el desarrollo de plataformas de procesamiento distribuido y la irrupción de la inteligencia artificial ofrecen oportunidades inéditas para superar esas limitaciones. Tecnologías como el aprendizaje automático (Machine Learning) y el aprendizaje profundo (Deep Learning) permiten explotar mejor la estructura espacio-temporal de los datos, modelar relaciones no lineales y combinar observaciones satelitales, registros in situ y salidas de modelos atmosféricos (Mele et al., 2020; Fu et al., 2023; Anggraini et al., 2024). En este contexto, plataformas como Google Earth Engine (Gorelick et al., 2017), Amazon Web Services, Microsoft Azure o Google Cloud Platform proporcionan entornos de procesamiento masivo que integran repositorios históricos de datos satelitales (Landsat, MODIS, Sentinel, NOAA, ALOS, entre otros) y herramientas de análisis avanzadas, permitiendo abordar estudios a escala global y con alta resolución temporal. Estas soluciones no solo democratizan el acceso a datos y algoritmos, sino que también posibilitan integrar modelos predictivos que incorporen el contexto meteorológico y socioeconómico, mejorando la capacidad de anticipar episodios críticos de contaminación y de evaluar el impacto de cambios en el consumo energético sobre la calidad del aire.

En síntesis, el uso de big data en el monitoreo de la calidad del aire no solo responde a un desafío técnico, sino que constituye una oportunidad estratégica para comprender patrones complejos, evaluar desigualdades en la exposición y apoyar el diseño de intervenciones más efectivas y adaptadas a las realidades socioeconómicas de cada región.

1.2.2. Teledetección para el monitoreo de la polución atmosférica

En la última década, el uso de datos satelitales para el análisis de la calidad del aire y su impacto en la salud pública se ha incrementado notablemente, impulsado por inversiones en satélites de observación de la Tierra y por iniciativas que promueven su uso efectivo por parte de las comunidades científicas y de gestión ambiental (Duncan et al., 2021). Estos datos ofrecen una cobertura espacial global que complementa las mediciones in situ, superando las limitaciones de las redes de monitoreo terrestre, que suelen estar concentradas en zonas urbanas y presentan grandes vacíos en áreas rurales y países de ingresos bajos y medios, donde incluso pueden no existir mediciones regulares de contaminantes como $PM_{2.5}$ (Shaddick et al., 2020).

La teledetección satelital permite identificar regiones con mayores niveles de contaminación, analizar tendencias a lo largo de décadas y rastrear el transporte de contaminantes a escalas regionales e intercontinentales (van Donkelaar et al., 2021). Sin embargo, las mediciones satelitales suelen corresponder a concentraciones integradas en la columna atmosférica, por lo que requieren modelos adicionales para estimar los valores a nivel superficial, que son los relevantes para la salud humana (Liu et al., 2020). Este reto es especialmente importante para $PM_{2.5}$, que no puede medirse directamente desde el espacio, sino inferirse a partir de indicadores como la profundidad óptica de aerosoles (AOD), combinados con variables

meteorológicas, de uso del suelo y topográficas (Duncan et al., 2021). El proceso de retrodispersión y captura de la radiación se ilustra en la Figura 1.1.

El vínculo entre AOD y $PM_{2.5}$ varía espacial y temporalmente, por lo que el uso combinado de datos satelitales, observaciones de superficie y modelos de transporte químico mejora sustancialmente la precisión y cobertura de las estimaciones (van Donkelaar et al., 2021; Li et al., 2021). Entre los enfoques más avanzados para este propósito destacan los métodos de machine learning—incluyendo Random Forest (RF), Gradient Boosting, Support Vector Regression (SVR) y redes neuronales profundas— que superan a menudo a los modelos estadísticos clásicos y a los modelos de transporte químico en términos de capacidad predictiva, especialmente en contextos de alta variabilidad espacial y temporal (Zhang et al., 2020; Fu et al., 2023). Estos métodos han mostrado valores de R^2 superiores a 0.8 en validaciones cruzadas frente a datos de superficie, y son menos sensibles a problemas de colinealidad, datos atípicos y vacíos de información (Duncan et al., 2021).

Un caso ilustrativo del potencial de esta integración de datos fue la pandemia de COVID-19, que representó un “experimento natural” sin precedentes debido a la drástica reducción de actividades industriales y de transporte durante los confinamientos. Diversos estudios detectaron descensos significativos en NO_2 y $PM_{2.5}$ mediante datos satelitales combinados con modelado estadístico y machine learning, cuantificando el impacto directo de la disminución de emisiones sobre la calidad del aire (Bauwens et al., 2020; Li et al., 2021; Venter et al., 2020). Estos resultados no solo evidencian la sensibilidad de la atmósfera a cambios en la actividad humana, sino que también ofrecen información clave para diseñar políticas de mitigación más efectivas, adaptadas a realidades socioeconómicas específicas.

En conjunto, la combinación de teledetección, redes de monitoreo in situ, modelos de transporte químico y algoritmos de aprendizaje automático constituye una estrategia robusta para caracterizar, predecir y mitigar la contaminación atmosférica. Este enfoque multifuente y multiescala no solo mejora la comprensión científica, sino que también fortalece la capacidad de respuesta de los tomadores de decisiones, proporcionando una base empírica sólida para intervenciones que protejan la salud pública y reduzcan desigualdades ambientales a nivel global.




Figura 1.1. Representación de la radiación dispersada o emitida captada por el satélite (Fuente: Programa de entrenamiento en Percepción Remota, NASA)

A continuación, se adjunta Tabla 1.1 con investigaciones relevantes que utilizan la teledetección satelital para el monitoreo de la polución atmosférica.

Tabla 1.1. Estudios que utilizan imágenes satelitales para el monitoreo de la contaminación atmosférica.

Referencia	Contaminante / Indicador	Sensor / Misión	Escala espacial / temporal	Hallazgo clave
van Donkelaar et al. (2016)	PM _{2.5} (estimaciones globales)	MODIS, MISR, SeaWiFS + GEOS-Chem	Global; multianual (1998–2014)	Marco global para derivar PM _{2.5} desde AOD satelital y CTM; base para evaluación sanitaria.
van Donkelaar et al. (2021)	PM _{2.5} (mejoras con ML)	MODIS/MISR/MAIAC + ML + GEOS-Chem	Global; 1998–2019	Integración de ML mejora la precisión y consistencia espacio-temporal de PM _{2.5} global.
Shaddick et al. (2018)	PM _{2.5} (exposición global)	Fusión satélite-modelos-monitores (ML)	Global; 1998–2016	Modelo de integración de datos (ML) para mapas consistentes de PM _{2.5} con incertidumbre.
Wei et al. (2023).	AOD (MODIS/MAIAC) + fusión datos	PM _{2.5} (estimado)	Global, 1 km, diario	Primer mapa global diario a 1 km de PM _{2.5} con cobertura completa, útil para evaluación sanitaria y tendencias finas en el espacio-tiempo
Hilboll et al. (2013)	NO ₂ (tendencias de largo plazo)	GOME, SCIAMACHY, OMI (multisensor)	Global; 1996–2011	Descensos en NO ₂ sobre países industrializados y aumentos sobre Asia/ME; tendencias robustas.
Georgoulas et al. (2022)	NO ₂ (VCD multi-sensor estandarizado)	GOME/SCIAMACHY/GOME-2/OMI	Global; 1995–2020	Serie VCD homogénea para análisis de tendencias y comparación inter-sensor confiable.
Goldberg et al. (2020)	NO ₂ (cambios por COVID-19)	OMI (Aura)	Global/Regional; 2020	Separación de señal por confinamientos vs. meteorología; descensos significativos en urbes.
Venter et al. (2020)	NO ₂ , PM _{2.5} , O ₃ (confinamientos)	TROPOMI/OMI + otras fuentes	Global; 2020 (mar-may)	Evidencia global de mejoras sustanciales en NO ₂ y PM _{2.5} durante confinamientos; O ₃ mixto.
Qu et al. (2021)	PM _{2.5} (cambios durante COVID)	AOD satelital + ML	China (Delta del Yangtsé); 2019–2020	ML (RF/SVR/ANN) para recuperar PM _{2.5} de alta resolución y cuantificar reducciones.
Duncan et al. (2021)	Revisión aplicaciones satélite-salud	Multiplataformas	Global; revisión 2010s–2020	Fortalezas/limitaciones de satélite para salud/calidad del aire; recomendaciones operativas.
Hammer et al. (2020)	PM _{2.5} (productos globales V4.GL/GWR)	MODIS C6.1, MISR v23, MAIAC, SeaWiFS + GEOS-Chem	Global; 1998–2019	Derivaciones globales PM _{2.5} (con y sin monitores vía GWR), ampliamente usadas en salud.
Geddes et al. (2016)	NO ₂ (tendencias urbanas)	Principalmente OMI	Global (ciudades); 2005–2014	Tendencias urbanas de NO ₂ y vínculos con políticas/emisiones a escala de ciudad.

1.2.3. Datos satelitales de Profundidad Óptica de Aerosol (AOD)

La profundidad óptica de aerosol (AOD) es un indicador de la calidad del aire que puede observarse a partir de la teledetección por satélite, y se define como la medida del contenido columnar de aerosoles atmosféricos. Numerosos estudios han encontrado una correlación positiva entre el AOD basado en satélites y el material particulado de superficie (Ibrahim et al., 2022). Por tanto, las recuperaciones basadas en satélites de la profundidad óptica de los aerosoles (AOD) se emplean ampliamente para monitorizar o derivar Material Particulado a gran escala (Song et al., 2019; Yao et al., 2018; Liu et al., 2022). AOD mide la densidad de la columna de partículas atmosféricas y se correlaciona con las concentraciones de MP2.5. Varios productos AOD se derivan de la recuperación de satélites en órbitas sincrónicas con el sol o geostacionarias. Mientras que los productos AOD de los satélites sincrónicos con el sol tienden a tener resoluciones espaciales más altas, los satélites geostacionarios generan AOD de resoluciones temporales más finas. Los espectrorradiómetros de imágenes de resolución moderada (MODIS) se encuentran en los satélites sincrónicos con el sol de Terra y Aqua. Sus productos AOD tienen resoluciones espaciales finas, como el MODIS 3 K a una resolución espacial de 3 km y el AOD de implementación de corrección atmosférica multiángulo (MAIAC) a una resolución espacial de 1 km (Xiao et al., 2017). En este estudio, se recolectaron los productos MODIS Collection 6 MAIAC AOD (MCD19A2) con una resolución espacial de 1 km, solo se utilizan las recuperaciones de MAIAC AOD a 550 nm y que pasan el filtro de calidad recomendado (Lu et al., 2021).

1.2.4. Datos satelitales de Dióxido de Nitrógeno

Las observaciones satelitales de las columnas de NO₂ troposférico se han utilizado ampliamente para inferir emisiones de NO_x y sus tendencias (Silvern et al., 2019). Se destacan dos instrumentos satelitales para la captura de la columna troposférica de NO₂: OMI y TROPOMI.

El Ozone Monitoring Instrument (OMI) está a bordo del satélite Aura (Levelt et al., 2006). OMI es un espectrómetro UV-VIS que mide los valores de la columna troposférica de NO₂. El manual de usuario en línea de NASA para los productos de OMI (Giovanni, 2014) contiene detalles sobre el filtrado de datos, una definición del análisis y los algoritmos del método de espectroscopia de absorción óptica diferencial (DOAS), así como los procedimientos de control de calidad para el filtrado y etiquetado de datos. Fue lanzado en 2004, tiene una resolución en el nadir de 13x24 km² y tiene una cobertura global diaria. Su paso orbital se representa en la Figura 1.2.




Figura 1.2. Representación del paso orbital de OMI. Fuente: NASA ARSET.

TROPOMI es un espectrómetro de imágenes de retrodispersión solar pasiva, que permite la adquisición de imágenes en ocho bandas espectrales, abarcando desde el ultravioleta (UV) y visible hasta el infrarrojo cercano (NIR) y el infrarrojo de onda corta (SWIR) (Lorente et al., 2019). Este instrumento tiene una resolución espacial de 7 × 3.5 km² (a lo largo y a través de la trayectoria del satélite) (Virghileanu et al., 2020). Sentinel-5P proporciona datos en tiempo real de múltiples gases traza (O₃, SO₂, NO₂, CO y CH₄). Su paso orbital se representa en la Figura 1.3.




Figura 1.3. Representación del paso orbital de TROPOMI. Fuente: NASA ARSET.

1.2.5. Machine Learning (ML)

Machine Learning (ML) es un subconjunto de la inteligencia artificial. Se define como un conjunto de métodos que pueden detectar patrones en los datos y utilizar los patrones descubiertos para predecir datos futuros, o para tomar otro tipo de decisiones (Ma et al., 2020). Normalmente, el aprendizaje automático se divide en supervisado y no supervisado.

En el aprendizaje supervisado, el algoritmo se entrena utilizando un conjunto de datos que incluye tanto entradas (features) como salidas conocidas (etiquetas). El objetivo es que el modelo aprenda una función que “mapea” las entradas a las salidas correctas. Una vez entrenado, el modelo puede hacer predicciones sobre nuevos datos. Por otra parte, en el aprendizaje no supervisado, el algoritmo trabaja con datos sin etiquetar, es decir, no tiene información sobre cuál debería ser la salida. El objetivo aquí es descubrir patrones o estructuras subyacentes en los datos sin la necesidad de etiquetas predefinidas.

Recientemente, los métodos de aprendizaje automático han sido un enfoque alternativo para abordar el problema de la no linealidad y mejorar el rendimiento de modelos predictivos. Se han utilizado métodos de ML para el análisis espacio-temporal de la contaminación atmosférica y el estudio de las posibles causas (Ali et al., 2014; Orun et al., 2018). Sin embargo, aunque los métodos de aprendizaje automático han generado resultados satisfactorios de modelado en problemas no lineales, no se ha avanzado en evaluar relaciones relevantes de las variables causales. Por lo tanto, se requiere un marco metodológico que utiliza los algoritmos de aprendizaje automático y que permita entender relaciones con variables auxiliares como las energéticas.

Las metodologías de ML se pueden utilizar para desacoplar los efectos meteorológicos en las concentraciones registradas de contaminantes atmosféricos (Vu et al., 2019). Estas técnicas basadas en el aprendizaje automático tienen un mejor rendimiento que los modelos estadísticos tradicionales (Grange et al., 2019). En esta tesis aplicamos una técnica de aprendizaje automático para desacoplar el papel de las condiciones meteorológicas en la calidad del aire.

Los métodos de aprendizaje automático más utilizados incluyen neural networks (ANN, Bocco et al. 2007), decision trees (DT; Pal and Mather 2003, k-nearest neighbour (KNN; Franco-Lopez, Ek, and Bauer 2001), random forest (RF; Belgiu and Drăguț 2016), support vector machine (SVM; Mountrakis, Im, and Ogole 2011), gradient boosting machine (GBM; Natekin and Knoll 2013), extreme gradient boosting (XGB; Chen and Guestrin 2016) y un subconjunto de clasificación emergente basado en redes neuronales profundas (DNN; Sublime y Kalinicheva 2019).

La mayoría de las técnicas de aprendizaje automático aplicadas al campo de la teledetección se clasifican en dos enfoques principales: supervisado y no supervisado. Las siguientes subsecciones presentan ambos enfoques, las cuales se resumen en el esquema de la Figura 1.4.

1.2.5.1. Aprendizaje supervisado

Las técnicas de aprendizaje supervisado requieren que las muestras de datos estén etiquetadas. A continuación, se presentan algunos ejemplos de su uso en teledetección. Los métodos más utilizados se describen a continuación:

1.2.5.1.1. k-nearest neighbour (kNN)

k-Nearest Neighbor (kNN) es un método de aprendizaje supervisado no paramétrico ampliamente utilizado en clasificación

y regresión (Thanh y Kappas, 2017). Su principio fundamental consiste en identificar las k muestras más cercanas a una muestra desconocida, utilizando una métrica de distancia, como la euclidiana. En el caso de clasificación, la clase de la muestra desconocida se asigna en función de la mayoría de clases presentes entre sus k vecinos más cercanos. Para problemas de regresión, se utiliza la media de los valores de las k muestras vecinas para predecir el valor de salida (Akbulut et al., 2017). El valor del parámetro k desempeña un papel crucial en la precisión del modelo, ya que un k demasiado pequeño puede generar sobreajuste, mientras que un k demasiado grande puede provocar un subajuste (Qian et al., 2014).

1.2.5.1.2. Gradient Boosting Machine (GBM)

Gradient Boosting Machine (GBM) es un enfoque que utiliza técnicas de boosting para generar un modelo predictivo basado en un promedio ponderado de múltiples subconjuntos de datos muestreados repetidamente. Este método aplica un proceso iterativo de optimización por gradiente para reducir los errores en una serie de árboles de decisión, consolidándose en un único modelo predictivo (Shiferaw et al., 2019). En los modelos GBM, es fundamental ajustar varios parámetros clave para maximizar su rendimiento. Estos incluyen:

- `n.trees`: el número de iteraciones de boosting realizadas, lo que equivale al número total de árboles en el modelo.
- `interaction.depth`: la profundidad máxima de los árboles, que indica el número de divisiones o nodos que puede tener cada árbol.
- `shrinkage`: también conocido como tasa de aprendizaje, controla la contribución de cada árbol adicional al modelo final, reduciendo su impacto para evitar sobreajuste.
- `n.minobsinnode`: el número mínimo de observaciones requeridas en los nodos terminales de los árboles.

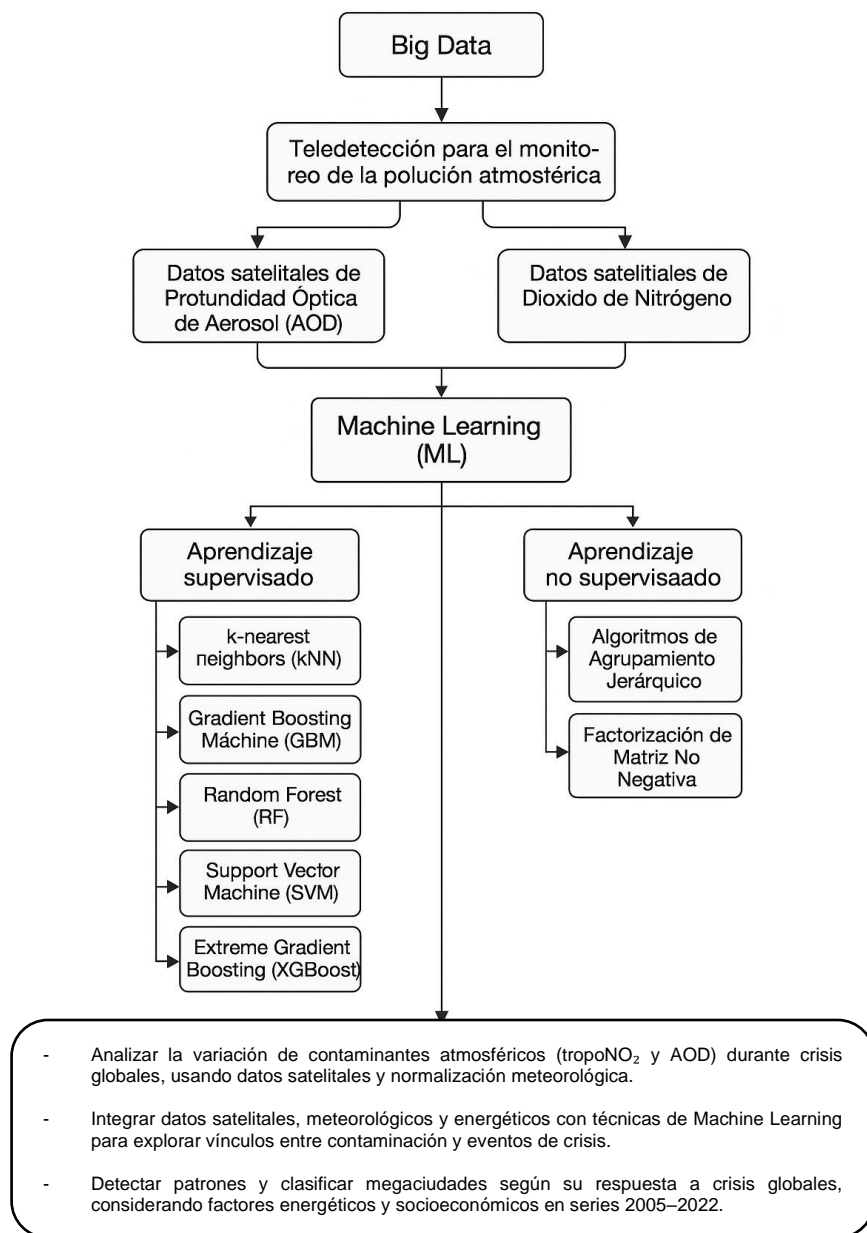


Figura 1.4. Esquema conceptual que integra la aplicación de distintos algoritmos de aprendizaje automático para identificar relaciones entre variables, y la detección de patrones y clasificación de megaciudades considerando sus perfiles energéticos y socioeconómicos.

1.2.5.1.3. Random Forest (RF)

Random Forest (RF) es un algoritmo de aprendizaje supervisado que combina información de un conjunto (ensemble) de árboles de decisión, utilizando subconjuntos aleatorios de variables para entrenar y clasificar los datos (Breiman, 2001; He et al., 2017). Los árboles votan para determinar la etiqueta asignada a muestras desconocidas, lo que permite superar el problema de que cualquier árbol individual sea subóptimo. Al incorporar un gran número de árboles, el modelo tiende hacia un óptimo global (Rodríguez-Galiano et al., 2012). El conjunto de árboles de decisión, o "bosque", se construye a partir de los datos de entrenamiento seleccionados mediante bootstrap sampling, donde únicamente se utiliza el 66% (aproximadamente 2/3) de los datos originales de entrenamiento para cada árbol, elegidos de forma aleatoria. Además, durante la construcción de los árboles, las variables predictoras utilizadas para dividir los nodos también se seleccionan aleatoriamente (Naidoo et al., 2012). Como se detalla en He et al. (2017), la configuración del algoritmo de Random Forest requiere ajustar dos parámetros principales:

- Número de árboles (n.trees): determina el tamaño del bosque; un mayor número de árboles suele mejorar la

estabilidad y precisión del modelo, aunque incrementa el costo computacional.

- Número de variables aleatorias por división (mtry): especifica cuántas variables predictoras se consideran en cada división de nodo, afectando la diversidad y la capacidad de generalización del modelo.

Estos ajustes permiten equilibrar la complejidad del modelo y su capacidad predictiva, haciéndolo robusto frente al sobreajuste y eficaz para manejar grandes volúmenes de datos con alta dimensionalidad.

1.2.5.1.4. Support Vector Machine (SVM)

Support Vector Machine (SVM) es un algoritmo de aprendizaje supervisado que se centra únicamente en las muestras de entrenamiento más cercanas al límite óptimo de separación entre clases en el espacio de características (Vapnik, 1995). Estas muestras, conocidas como vectores de soporte, definen el hiperplano que maximiza el margen (es decir, la separación) entre las clases (Mountrakis et al., 2011a).

En muchos casos, los límites de decisión lineales no son suficientes para clasificar categorías de alta complejidad con precisión. Para abordar este problema, SVM utiliza técnicas como las funciones kernel, que introducen variables adicionales para optimizar el modelo y permiten mapear relaciones no lineales a un espacio de mayor dimensión (ya sea euclidiano o de Hilbert). La elección de la función kernel (lineal, radial, polinómica, entre otras) influye significativamente en los resultados del análisis, por lo que debe seleccionarse cuidadosamente junto con otros parámetros del modelo (Kavzoglu y Colkesen, 2009). Otro parámetro fundamental de SVM es el parámetro de costo (C), que controla el impacto de las clasificaciones erróneas en los datos de entrenamiento. Este parámetro regula el nivel de tolerancia a las violaciones de clasificación en datos no separables, equilibrando la rigidez del modelo frente a la maximización del margen (Lu y Weng, 2007). Ajustar adecuadamente el parámetro C ayuda a encontrar un equilibrio entre un margen amplio y un bajo número de errores de clasificación (Melgani y Bruzzone, 2004).

Una ventaja notable de SVM es que no asume una distribución estadística conocida de los datos. Esto resulta particularmente útil en imágenes de teledetección, donde las distribuciones son a menudo desconocidas y las suposiciones de normalidad no siempre representan con precisión la dispersión de los píxeles en cada clase.

1.2.5.1.5. Extreme Gradient Boosting (XGBoost)

Extreme Gradient Boosting (XGBoost) es un algoritmo relativamente reciente descrito por primera vez por Chen y Guestrin (2016). Forma parte de la familia de algoritmos de boosting y utiliza un enfoque de ensamble basado en árboles. Su función principal es ajustar la clasificación de las muestras en cada iteración de manera aditiva, mejorando continuamente las predicciones realizadas por clasificadores débiles al corregir los errores del modelo anterior. Las muestras clasificadas incorrectamente reciben mayores pesos en la siguiente iteración, obligando al modelo a enfocarse en ellas para mejorar su rendimiento. El resultado final es un modelo robusto que combina las mejoras acumuladas de todos los árboles generados previamente (Georganos et al., 2018).

El entrenamiento de XGBoost requiere la definición de una función objetivo, que incluye dos componentes: la pérdida de entrenamiento, que mide la precisión predictiva del modelo, y la regularización, que controla su complejidad para prevenir sobreajuste (Chen y Guestrin, 2016). En este sentido, existen varios parámetros claves para optimizar el modelo:

- eta: también conocido como tasa de aprendizaje, controla la velocidad a la que el modelo aprende los patrones en los datos. Este parámetro reduce los pesos de las características en cada iteración para alcanzar el mejor óptimo. Valores más bajos de eta conducen a un aprendizaje más lento, pero suelen mejorar la precisión.
- gamma: regula la complejidad del modelo mediante la regularización, ayudando a prevenir el sobreajuste al penalizar divisiones en los árboles que no mejoran significativamente la función objetivo.
- max_depth: define la profundidad máxima de los árboles. Profundidades mayores permiten capturar patrones complejos, pero aumentan el riesgo de sobreajuste (Abdi, 2020).

Además, hay otros parámetros que influyen en menor medida en el rendimiento del modelo; sin embargo, en esta investigación se utilizaron sus valores predeterminados (Georganos et al., 2018).

XGBoost es especialmente eficaz para manejar grandes conjuntos de datos y características de alta dimensionalidad, siendo una herramienta poderosa y flexible en tareas de clasificación y regresión.

1.2.5.2. Aprendizaje no supervisado

En el aprendizaje no supervisado, las muestras de datos no contienen etiquetas y se agrupan en función de sus similitudes (Rivera et al., 2022). Estos algoritmos clasifican u organizan los objetos según características comunes y reconocimiento de patrones. El proceso de agrupamiento suele seguir una fase de extracción o selección de características, que implica definir una medida o función para luego proceder a la validación del agrupamiento. En esta etapa, los resultados se someten a criterios de evaluación e interpretación. Estos métodos buscan agrupar las muestras de datos de manera que los elementos dentro de un clúster sean más similares entre sí que aquellos que están en clústeres diferentes. Desde un punto de vista intuitivo, este problema tiene un objetivo claro: agrupar correctamente un conjunto de datos sin etiquetas. Se han desarrollado múltiples algoritmos y medidas de similitud que varían en función de cómo se define la semejanza entre objetos y de la eficiencia computacional en lograr la agrupación final. Los algoritmos pueden clasificarse en varios grupos,

pero solo describiremos el jerárquico que será utilizado en las metodologías de los capítulos.

En muchos casos, los datos presentan una alta dimensionalidad, lo que dificulta la aplicación eficiente de algoritmos de aprendizaje no supervisado. Para abordar este problema, se emplean técnicas de reducción de dimensionalidad, que permiten transformar un conjunto de datos de alta dimensión en una representación más compacta sin perder información relevante. Métodos como el Análisis de Componentes Principales (PCA, por sus siglas en inglés) y la Factorización de Matriz No Negativa (NMF, por sus siglas en inglés) son ampliamente utilizados en este contexto. Estas técnicas no solo ayudan a reducir la carga computacional de los algoritmos de agrupamiento, sino que también pueden mejorar la calidad de los clústeres al eliminar redundancias y preservar la estructura de los datos más relevante.

1.2.5.2.1. Algoritmos de Agrupamiento Jerárquico

En los algoritmos de Clustering Jerárquico, los objetos de datos se dividen en niveles en un formato jerárquico (Btissam, 2015). Los clústeres se forman iterativamente mediante un enfoque de arriba hacia abajo (top-down) o de abajo hacia arriba (bottom-up) para generar un dendrograma que representa la estructura jerárquica de los clústeres formulados (Saxena et al., 2017). El enfoque de abajo hacia arriba se conoce como método aglomerativo, mientras que el enfoque de arriba hacia abajo se denomina método divisivo. En el método aglomerativo, los clústeres se forman a partir de objetos individuales que se fusionan iterativamente en clústeres más grandes, generando diferentes niveles en la jerarquía hasta que todos los objetos forman un único clúster o se cumple un criterio de detención. En el método divisivo, ocurre lo contrario: el clúster que contiene todos los objetos se divide iterativamente hasta que cada objeto forma un clúster individual o se alcanza el criterio de detención. La fusión o división se realiza en función de la similitud o disimilitud entre los elementos del clúster. En el clustering jerárquico, la fusión o división de subconjuntos de puntos se lleva a cabo generalizando la distancia entre puntos individuales a la distancia entre subconjuntos de puntos. Esto se determina utilizando una medida de proximidad denominada métrica de enlace (linkage metric). Existen tres métricas básicas de enlace utilizadas en el clustering jerárquico: el enlace simple, el enlace promedio y el enlace completo (Saxena et al., 2017; Olson, 1995; Jain et al., 1999; Murtagh, 1985).

El algoritmo de clustering jerárquico utiliza una matriz de conectividad, donde se construyen las métricas de enlace utilizadas para la agrupación. La construcción de la matriz de similitud se logra encontrando la similitud entre cada par de puntos de datos. Luego, el criterio de enlace se calcula determinando la distancia por pares entre los clústeres. La métrica de similitud se usa para determinar la distancia entre los conjuntos de clústeres y también para definir la forma de los mismos.

1.2.5.2.2. Factorización de Matriz No Negativa

La Factorización de Matriz No Negativa (NMF, por sus siglas en inglés) es un enfoque de aprendizaje no supervisado que ha sido aplicado con éxito en diversas disciplinas. Sin embargo, pocos estudios en el campo de las ciencias atmosféricas han adoptado metodologías basadas en NMF para comprender la relación entre las concentraciones de contaminantes, los efectos climáticos y los aspectos sociales (Liang et al., 2021; Ma et al., 2021). Similar al Análisis de Componentes Principales (PCA) y al Análisis de Componentes Independientes (ICA), el objetivo de NMF es describir los datos observados utilizando un número limitado de componentes esenciales, pero con la restricción de que las entradas sean no negativas (Gaujoux y Seoighe, 2010). Debido a esta restricción de no negatividad, los componentes siempre se combinan de manera aditiva, lo que permite obtener una representación completa de los datos originales (ver Brunet et al., 2004 y Wang et al., 2006 para más detalles). Este método innovador permite explicar los datos observados mediante un número reducido de componentes o factores esenciales, facilitando la interpretación de patrones subyacentes en conjuntos de datos complejos.

1.3. Consumo energético y Calidad del aire

La reducción de la contaminación atmosférica es una de las principales metas asociadas a los Objetivos de Desarrollo Sostenible (UN. 2015). Una de las principales fuentes antrópicas de contaminación del aire corresponde a la generación y el consumo de energía (Wang et al., 2019), con impactos tanto locales como globales. Entre estos destacan el calentamiento global (Jacobson et al., 2022), el deterioro de los servicios ecosistémicos (Wei et al., 2017) y la mala calidad del aire en ciudades. La mala calidad del aire involucra un menoscabo del bienestar y salud humana (Wang et al., 2017). Por tanto, los procesos energéticos y la calidad del aire describen relaciones directas e indirectas (Yang et al., 2016). Entre las directas se destaca el consumo de energía, estrechamente relacionado con las emisiones de contaminantes criterio y de efecto invernadero. Los factores indirectos, como variables socioeconómicas, geopolíticas o de seguridad de suministro, afectan en los patrones de uso y consumo de energía, impactando a su vez las emisiones del sistema y su impacto en la calidad del aire (Ver esquema conceptual de la Figura 1.5.). Los eventos de crisis globales pueden modificar los patrones de consumo energético, afectando sectores clave como el transporte, el consumo residencial, comercial e industrial. Como resultado, las crisis pueden generar fluctuaciones en la contaminación atmosférica, dependiendo de la reducción o

intensificación del uso de combustibles fósiles.

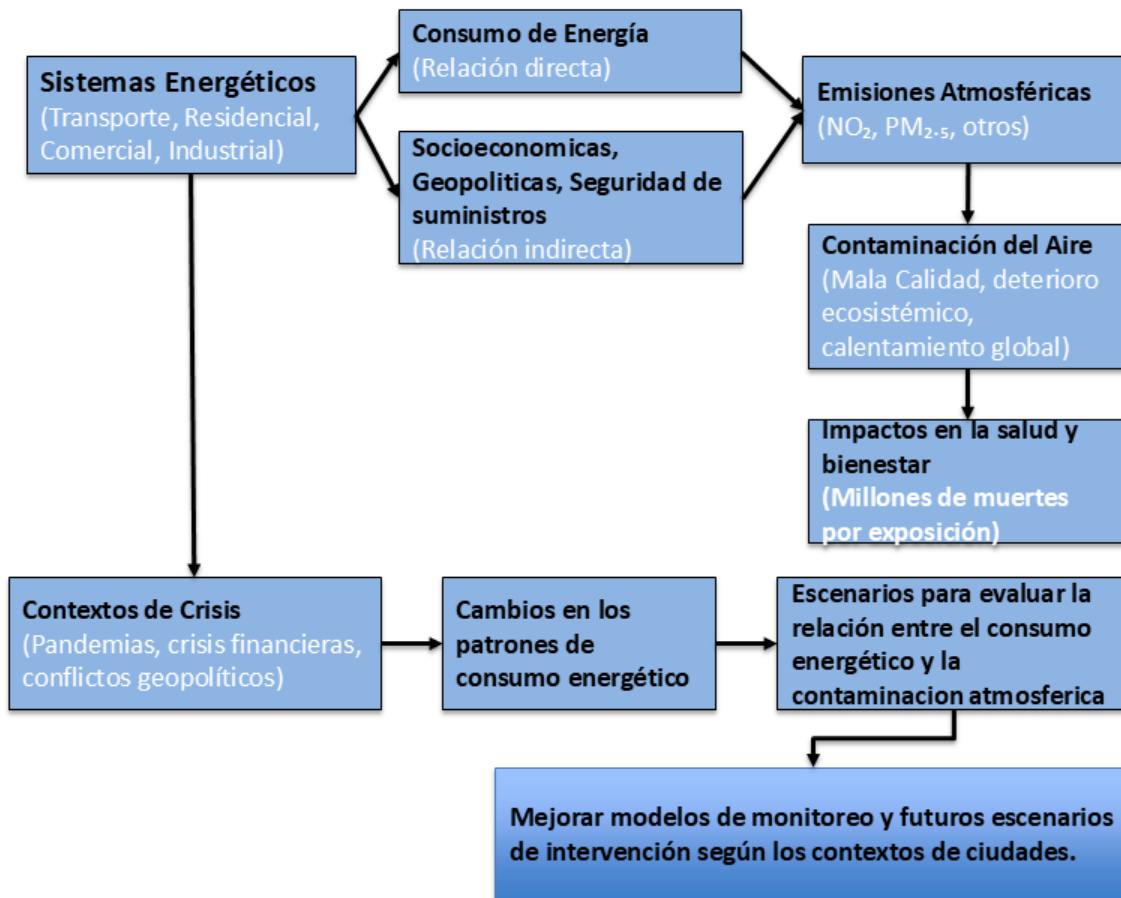


Figura 1.5. Resumen esquemático para reflejar la relación entre el sistema energético, la contaminación atmosférica y los contextos de crisis

Algunas de las presiones inmediatas derivadas de la crisis energética global han disminuido, pero los mercados energéticos, la geopolítica y la economía mundial presentan inestabilidad y el riesgo de mayores perturbaciones está siempre presente (Akadiri et al., 2019). El sector energético es uno de los principales causantes del aire contaminado que más del 90 % de la población mundial se ve obligada a respirar y que está vinculado a más de 6 millones de muertes prematuras al año. Las tendencias positivas en la mejora al acceso a la electricidad y a una cocina no contaminante se han ralentizado o incluso revertido en algunos países (World Energy Outlook 2023). En este complejo contexto, la aparición de una nueva economía de energía limpia, liderada por la energía solar fotovoltaica y los vehículos eléctricos, ofrece esperanza para el futuro. La inversión en energías limpias ha aumentado un 40 % desde 2020. El impulso a favor de la reducción de las emisiones es un motivo clave, aunque no existe un consenso del real efecto sobre la calidad del aire.

Diversos estudios han realizado análisis localizados, limitados a una región o un país específico, para comprender la dinámica y relaciones causa-efecto entre el sistema energético y la calidad del aire. Sin embargo, debido al carácter local de la mayoría de los trabajos, los resultados suelen ser contradictorios y difíciles de extrapolar a regiones más extensas o a escala global. Inclusive, no son concluyentes en cuanto a la real significancia del consumo energético en la calidad del aire. Por ejemplo, en Chih-Sheng Lee et al. (2018), los datos de las estaciones de monitoreo de Taiwán se utilizaron para evaluar la tendencia a largo plazo (2005-2015) de NO₂ y SO₂ en 6 ciudades. Estos datos de contaminantes atmosféricos fueron vinculados a variables como Producto Interno Bruto (PIB), el número de vehículos, el consumo de energía y la producción industrial. Después de desestacionalizar los datos y utilizar una media móvil de 7 meses, el análisis de tendencias reveló una tendencia decreciente que osciló entre 0,15 y 0,57 ppb/año (R² de 0,33 a 0,85) para NO₂ y 0,06 a

0,45 ppb/año (R2 de 0,32 a 0,92) para el SO₂. Las reducciones correspondientes al período de 10 años resultaron entre 4 y 42% para el NO₂ y del 22 a 52% para SO₂. Por lo tanto, evidenciaron una clara tendencia de reducción en los contaminantes atmosféricos, a pesar del crecimiento en el número de vehículos y el consumo de energía.

Con el fin de verificar la preponderancia del consumo energético en las concentraciones de contaminantes atmosféricos, es necesario encontrar formas de evaluar los sistemas energéticos (Martins et al., 2019). Los enfoques utilizados suelen definir un conjunto de indicadores a aplicar, y luego se puede evaluar y comparar con variables de calidad del aire. Algunos indicadores energéticos son aplicables a escala global y otros en un área local, como un país (IAE).

En la misma línea, Zhou et al. (2018) aplicaron un análisis de regresión espacial para evaluar las direcciones y la fuerza de asociación entre los factores socioeconómicos y las concentraciones de MP_{2.5}, utilizando datos recopilados de 945 estaciones de monitoreo en 190 ciudades chinas en 2014. Entre los factores socioeconómicos, seleccionaron variables referidas al crecimiento económico, la densidad de población, la estructura industrial, las emisiones industriales de hollín (polvo), la densidad de carreteras, la apertura comercial y el consumo de energía. Los resultados indicaron que el promedio anual de MP_{2.5} fue de $61 \pm 20 \mu\text{g}/\text{m}^3$. Los resultados mostraron que las densidades de población, la proporción de la industria secundaria, las emisiones industriales de hollín (polvo) y la densidad de las carreteras tuvieron una influencia positivamente significativa en las concentraciones de MP_{2.5}, mientras que el incremento del PIB per cápita ejerció una influencia negativa significativa. En contraste, el consumo de energía no demostró una relación significativa con las concentraciones de MP_{2.5} a escala nacional. También en China, Qi et al. (2022) investigaron las características de evolución espacio-temporal de concentraciones de MP_{2.5} durante 1998-2019 mediante análisis espacial. Los autores estudiaron los efectos de la urbanización multidimensional en las concentraciones de MP_{2.5}, y analizaron los factores dominantes en las ocho regiones económicas de China, concluyendo que las concentraciones de MP_{2.5} tienen diferencias regionales significativas en China. Estas diferencias están influenciadas por factores socioeconómicos como la densidad de población, el consumo de energía y la estructura industrial que generan efectos significativos en las concentraciones de MP_{2.5}.

Otros estudios locales como los de Khan et al. (2020) y Ali et al. (2021) que utilizaron como área de estudio a Pakistán analizaron la relación entre consumo energético y emisiones de contaminantes. Encontraron correlaciones significativas entre el consumo energético y la degradación de la calidad del aire. También con un enfoque localizado, Yuping et al. (2021), evaluó los efectos dinámicos de la globalización, el consumo de energía renovable, el consumo de energía no renovable y el crecimiento económico en los niveles de emisión de dióxido de carbono en Argentina durante el período 1970-2018. Sus resultados revelan que un aumento del 1% en el nivel de consumo de energía no renovable per cápita produce un aumento en los niveles de emisiones per cápita en 0.215% y 0.460% a corto y largo plazo, respectivamente. Por otro lado, un aumento del 1% en las cifras de consumo de energía renovable per cápita se asocia con una disminución de los niveles de emisión en un 0,008% y 0,006% a corto y largo plazo, respectivamente. Resultados similares se informaron en los estudios de Pata (2021) para los Estados Unidos, Zafar et al. (2019b) para las economías emergentes. La revisión anterior nos muestra que la caracterización de la relación entre dos sistemas complejos como el energético y la contaminación atmosférica no es fácil de representar y los comportamientos no son lineales. Claramente, los enfoques locales no han sido capaces de arrojar un patrón común en la influencia del consumo energético en la contaminación del aire. Entonces, pese a los avances notables en la investigación local, se requiere un enfoque más amplio para comprender la dinámica y las relaciones causa-efecto entre los dos sistemas mencionados. Se requiere un análisis más generalizado para obtener conclusiones más sólidas y aplicables a diferentes contextos. Además, nuevos análisis deben considerar o diferenciar los efectos energéticos de los efectos de otros componentes y situaciones que también afectan la contaminación del aire, de manera de obtener resultados más precisos del aporte en la contaminación atmosférica del sector energético. Periodos de crisis, donde el sector energético es particularmente sensible, pueden ser periodos de análisis para identificar la significancia de este sector en la contaminación atmosférica.

Como se discute a continuación, algunos investigadores han tratado de identificar los pesos del sistema energético en la calidad del aire en períodos excepcionales, en los cuales se han verificado cambios sustanciales en los patrones de consumo de energía impulsados por eventos geopolíticos, económicos o sociales de gran magnitud y envergadura. Se ha postulado que un legado de las crisis globales que han generado crisis energéticas a nivel mundial puede ser el dar lugar al inicio del fin de la era de los combustibles fósiles (World Energy Outlook 2023), y generar un escenario para el estudio de la relación entre la demanda de energía y la calidad del aire. Entre los estudios que estudian esta relación, destacan los centrados en las crisis mundiales del petróleo en las décadas de 1970 y 1980 (Lonergan et al. (1990); Mukhopadhyay et al. (1999); Hunt et al. (2006)), las crisis energéticas después de la crisis financiera de 2008-2009 (Sinha et al. (2015); Kayalar et al. (2017); Sadorsky et al. (2020)) y las conmociones después del desastre de Fukushima (Vivoda et al. (2012); Hayashi et al. (2013); Aruga et al. (2020)). El foco de estos trabajos está en demostrar que las crisis financieras son factores impulsores en los cambios de los patrones de consumo energéticos. Si bien esta información es útil para obtener una comprensión más profunda de cómo los factores que afectan las condiciones económica-sociales producen cambios notorios en el sistema energético, no se centran en las implicancias en la contaminación del aire producida por los cambios en el consumo energético.

Diferentes tipos de crisis generan diferentes impactos en el consumo energético y en la contaminación atmosférica. Las crisis financieras están asociadas a la baja en la demanda en los sectores de consumo energético, lo que se asocia a una menor emisión de contaminantes. Sin embargo, durante este tipo de eventos, se suelen recurrir a combustibles de menor calidad que generan mayor nivel de emisiones de determinados contaminantes. Las restricciones o cuarentenas generadas

por la pandemia generó una reducción de la movilidad, reduciendo notoriamente las emisiones del sector transporte. Además, debido a las restricciones existieron menos consumo energético en el sector comercial e industrial, pero existió aumentos en el sector residencial (Volke et al. 2023). Las crisis geopolíticas como la guerra ruso-ucraniana tienen efectos en la disponibilidad de energéticos, que se suplen por alternativas que pueden un componente mayor o menor de contaminantes atmosféricos.

Otros estudios si han analizado los efectos ambientales durante crisis globales, buscando patrones comunes entre ellas, así como el efecto de los cambios en el consumo energético y sus efectos en materia de contaminación del aire (Sindosi et al. (2019); Akadiri et al. (2019); Pacca et al., 2020; Wang et al., 2022). Sin embargo, los trabajos han evaluado efectos locales, resultando en conclusiones contradictorias.

Athanasios et al. (2015) mediante un análisis de regresión de datos de contaminación en Grecia revelaron que la reducción de NO₂ y SO₂ durante el periodo 2000-2007, se aceleró significativamente durante el periodo de crisis económica (a partir de 2008), acelerándose en $2,3 \pm 0,2$ ppbv/año y $0,7 \pm 0,1$ ppbv/año, respectivamente. Los científicos también concluyeron que la recesión económica de 2008-2009 en Grecia se tradujo en una disminución significativa de la concentración de material particulado, con una caída promedio anual del 10% a nivel nacional. Sin embargo, los autores revelaron que, en algunos sectores, debido a la crisis, familias recurrieron a la leña y biomasa de bajo costo aumentando los niveles de partículas en suspensión en Atenas, Tesalónica y otras ciudades (con inclusive concentraciones superiores a 80 ug m⁻³ de PM₁ durante mañanas y en algunos momentos excediendo los 150 ug m⁻³ en las tardes). En otro estudio realizado en Grecia, Sindosi et al. (2019), investigaron el régimen de contaminación del aire en el noroeste de ese país durante la crisis financiera griega. Utilizaron patrones anuales, semanales y diarios para MP₁₀, MP_{2.5}, NO₂ y O₃, y caracterizaron la calidad del aire según el Índice Europeo de Calidad del Aire de la Agencia Europea de Medio Ambiente. Encontraron resultados dispares para los diferentes contaminantes. Durante los años de crisis financiera hubo un aumento de las bandas "Pobre" y "Muy Pobre" para MP₁₀, atribuyéndolo a que los materiales convencionales para calefacción residencial (principalmente gasóleo de calefacción) fueron reemplazados por otros más baratos (principalmente madera). Se registró una reducción en la frecuencia de las bandas con calidad de aire "Buena" y "Regular" para el primer período de crisis financiera (hasta 2012) con respecto a MP_{2.5} y O₃. En contraste, en cuanto a NO₂ la calidad del aire mejoró.

Monteiro et al. (2018), estudiaron la contaminación del aire en las ciudades de Lisboa y Oporto, encontrando una reducción en el consumo de energía después de la crisis de 2007, con una correlación positiva entre el uso de energía y las emisiones de MP₁₀ y NO₂. Además, encontraron una tendencia negativa de concentración de contaminación en los 5 años posteriores a la crisis. Los autores postulan, a modo de generalización, que las crisis podrían inducir cambios en el comportamiento de los consumidores y a consecuencia un impacto significativo en la disminución a mediano plazo en las emisiones de gases contaminantes.

Como se desprende de la discusión previa, las distintas investigaciones realizadas en orden a dilucidar las interrelaciones entre comportamiento de los sistemas energéticos y la calidad del aire sigue siendo materia de controversia. Los resultados de las distintas investigaciones no permiten extrapolar o generalizar tendencias, por cuanto la mayoría de los trabajos han focalizado zonas específicas cuyas variaciones en la calidad del aire en determinados períodos de tiempo, si bien pueden verse influidas por cambios en los patrones de consumo de energía, también pueden verse afectadas por factores particulares para dicha región. Entre estos factores, juegan un papel relevante las condiciones meteorológicas, las normativas medioambientales de cada ciudad y el nivel de calidad en las redes de monitoreo de contaminantes ambientales para cada región. Por tanto, ampliar la escala espacio temporal de análisis sería de gran ayuda para entender de mejor manera la relación entre estos sistemas complejos.

En esta línea, Pacca et al. (2020), investigaron empíricamente el impacto de las crisis financieras en las emisiones de contaminantes atmosféricos (CO₂, SO₂, NO_x y MP_{2.5}), en más de 150 países durante el periodo 1970-2014. Los resultados muestran que, durante el periodo inmediatamente posterior a las crisis, como consecuencia de las crisis financieras, las emisiones anuales disminuyeron para todos los gases excepto para MP_{2.5}. En particular, observaron que las emisiones de CO₂, SO₂ y NO_x disminuyeron en 2,6, 1,8 y 1,7% respectivamente. Sin embargo, a medio plazo, después de uno o dos años, las crisis financieras causan un efecto no significativo en las emisiones, o en algunos casos, como países en desarrollo, incluso condujeron a un aumento del 1-2%, anulando el beneficio inicial. El análisis también muestra que el efecto de las crisis es distinto según los de ingresos del país. Los resultados indican que las crisis financieras tienen un impacto negativo y estadísticamente significativo en las emisiones de CO₂ solo para países de ingresos altos y medianos altos (reducción del 3,1 y 5,7%, respectivamente); SO₂ y NO_x se ven afectados negativa y significativamente por las crisis en los países de ingresos altos y medianos bajos, mientras que ninguno grupo de ingresos mostró un efecto estadísticamente significativo de las crisis económicas en las concentraciones de PM_{2.5}.

En otro estudio de gran alcance, Xin et al. (2022) examinaron teóricamente y empíricamente el impacto de crisis generadas por incertidumbre de la política económica en la contaminación por MP_{2.5} en 25 países. Los resultados, apoyados en la utilización de series de tiempo extensas, muestran que, con el aumento de la incertidumbre de la política económica, la contaminación por MP_{2.5} de los países ha disminuido significativamente debido a reducción de las inversiones en producción. Sin embargo, el aumento de la incertidumbre de la política económica puede obstaculizar las actividades de innovación de las empresas, lo que a su vez puede aumentar la contaminación. Por lo tanto, el impacto de la incertidumbre de la política económica en la contaminación por PM_{2.5} dependería del efecto combinado de estos dos efectos diferentes. Así, la incertidumbre de la política económica suele tener un efecto heterogéneo en la contaminación por MP_{2.5} de los

países. En comparación con los países que tienen un mayor insumo de investigación y desarrollo, el aumento de la incertidumbre de la política económica hace que la reducción de la contaminación por $MP_{2.5}$ en países con inversiones en investigación y desarrollo relativamente más bajas sea mayor.

Bajo esta mirada más global, un evento que fue de un enorme impacto global y que, probablemente puede reflejar mejor como se relacionan dos sistemas complejos como el sistema energético y la calidad del aire, es el periodo de restricciones debido a la pandemia COVID-19. El impacto de la pandemia actual en la actividad económica y la demanda de energía ha sido inesperadamente grave, incluso en comparación con la crisis financiera de 2008-2009 (Suehiro et al., 2020; Tahir et al., 2020; Sruthi, 2020). Algunos expertos incluso sugieren que el mundo no experimentó un estado de emergencia tan inusual desde la Segunda Guerra Mundial (Chakraborty y Maity, 2020). El confinamiento total (cuarentenas) redujo la demanda de electricidad en un promedio del 20% a nivel mundial durante los meses más críticos en 2020 (Aktar et al., 2021). La pandemia ha ejercido profundas y extensas influencias en la economía, la sociedad, el consumo energético y el medio ambiente (Klemeš et al., 2020; Tahir y Batool, 2020). Como industria pilar esencial, el sector energético es extremadamente sensible a las conmociones externas como la pandemia de COVID-19 por sus diversas relaciones con los sectores empresarial, industrial y de transporte (Hosseini, 2020; Lin y Su, 2020). La reducción en el consumo de energía disminuyó directamente las emisiones de contaminantes atmosféricos como NO_x , SO_2 , CO , $MP_{2.5}$, y MP_{10} , lo que resultó en una mejora de la calidad del aire. En Liu et al. (2021) muestran que, durante el primer semestre de la pandemia, el NO_2 cayo precipitadamente (23-37%) en relación con el período anterior al confinamiento, seguido por MP_{10} (14–20%), SO_2 (2–20%), $MP_{2.5}$ (7-16%), y CO (7-11%). La reducción significativa en la combustión de combustibles fósiles, especialmente en el sector transporte, contribuyó directamente a la disminución de las emisiones de gases de efecto invernadero (GEI) y emisiones de contaminantes atmosféricos como el NO_2 o el MP (Safarian et al., 2020; Zhang et al., 2020). Según Filonchik et al. (2020), este efecto fue más marcado en zonas con mayores niveles de contaminantes en el aire, como es el caso de regiones industriales de la llanura del norte de China y el delta del río Yangtze (Balsalobre-Lorente et al., 2020). Por otro lado, durante el mismo período, las emisiones de $MP_{2.5}$ y MP_{10} cayeron 29,8% y 22,8%, respectivamente en São Paulo, Brasil, en comparación con los niveles anteriores de 2015-2019 (Yuri et al., 2020).

Se han notificado variaciones en las concentraciones de contaminantes atmosféricos en Europa (Muhammad et al., 2020; Tobías et al., 2020), Asia (Shi y Brasseur, 2020; Wang y otros, 2020; Xu et al., 2020), África (Otmani et al., 2020), ciudades estadounidenses (Goldberg et al., 2020; Berman y Ebisu, 2020), y en todo el mundo (Tang et al., 2021) debido al drástico cierre de las actividades económicas y sociales. En América Latina, varios estudios han analizado el comportamiento de los contaminantes del aire, por ejemplo, en Brasil (Dantas et al., 2020; Krecl et al., 2020; Nakada y Urban, 2020; Siciliano et al., 2020), Ecuador (Pacheco et al., 2020), Argentina (Bolaño-Ortiz et al., 2020), Colombia (Mendez-Espinosa et al., 2020), Perú (Rojas et al., 2021; Velayarce et al., 2022), Chile (Toro et al., 2021) y México (Hernández-Paniagua et al., 2021; Peralta et al., 2021).

La evidencia antes mostrada señala que, aunque el impacto del cambio en el consumo energético y/o la composición de éste en la contaminación del aire ha sido estudiado en la literatura (resumen bibliográfico en Tabla 1.2.), el alcance de la mayoría de los trabajos aborda principalmente escalas locales a regionales. Se observa la carencia de investigaciones que aborden la escala global. Hasta el momento, no se tiene un estudio que permita evaluar con una gran cobertura espacial los eventuales efectos en la calidad del aire de grandes impactos en el sistema energético. Esta necesidad se ha vuelto aún más crucial dado que, comparando los estudios presentados, se observan resultados contradictorios entre distintas investigaciones, probablemente derivados de la escala de trabajo y las particularidades específicas de las distintas áreas de estudio y temporalidad de los análisis, no replicables a otras realidades. Más aún, los países desempeñan diferentes roles en materia de contaminación según este caracterizado su consumo energético, el cual está influenciado por su economía, el uso de energía limpia y su inversión en nuevos proyectos energéticos (World Energy Outlook 2023). Es importante considerar las particularidades individuales de los datos utilizados para el análisis, en particular los correspondientes a calidad del aire que presentan limitaciones en representatividad espacial y homogenización de los datos. En consecuencia, para lograr una comprensión más adecuada y sistémica de las relaciones complejas entre los sistemas energético y atmosférico, se requiere abordar investigaciones que aborden la escala global, con mayor resolución espacio temporal. Otra limitación importante en el estado del arte, es que no se suelen abordar modelos estadísticos de agrupación, factorización y regresión para la búsqueda de patrones o análisis de comportamiento en las series de tiempo de los datos energéticos y de contaminación que permitan caracterizar de mejor manera las relaciones entre sistemas distintos. Se deben proponer metodologías más avanzadas de minería de datos para obtener la máxima información posible de datos a una escala global.

Tabla 1.2. Resumen bibliográfico.

Investigación	Contaminante	Región	Periodo	Resultado
Lee et al. (2018)	NO ₂ y SO ₂	Taiwan	2005-2015	Aumento en el consumo de energía y reducción de contaminantes atmosféricos
Zhou et al. (2018)	MP2.5	China	2010-2016	A través de un análisis de regresión: Densidad de población, carreteras e industrias secundarias tuvieron influencia significativa. PIB per cápita ejerció una influencia negativa significativa. Consumo energético no mostro significancia.
Qi et al. (2022)	MP2.5	China	1998-2019	A través del estudio de las características espacio-temporales: El consumo de energía genera efectos significativos en las concentraciones de MP2.5.
Khan et al. (2019); Ali et al. (2021); Pata et al. (2021)	MP2.5 , NO ₂ y SO ₂	Pakistan Pakistan USA	2005-2018 2010-2020 2009-2019	A través de análisis de series de tiempo de estaciones de monitoreo terrestre: Diferentes grados de significancia en la relación entre el consumo energético y la degradación de la calidad del aire.
Athanasios et al (2015)	MP2.5, NO ₂ y SO ₂	Grecia	2000-2012	A través de un análisis de regresión, revelo que la reducción de NO ₂ y SO ₂ durante el periodo 2000-2007 se aceleró significativamente durante el periodo de crisis económica. Sin embargo, en sectores donde se recurrió al uso de biomasa de bajo costo debido a la crisis, existió un aumento del material particulado.
Sindosi et al. (2019)	PM ₁₀ , PM _{2.5} , NO ₂ y O ₃	Grecia	2005-2010	Analizaron patrones anuales, semanales y diarios para PM ₁₀ , PM _{2.5} , NO ₂ y O ₃ , encontrando resultados dispares para los distintos contaminantes. Para el material particulado, las concentraciones aumentaron durante la crisis, atribuibles a que los materiales de calefacción fueron reemplazados por alternativas más baratas. Por otra parte, el NO ₂ , mejoro sustancialmente en sus niveles.
Monteiro et al (2018)	MP2.5 y NO ₂	Portugal	2000-2014	A través de análisis de series de tiempo de estaciones de monitoreo terrestre: Encontraron que la reducción en el consumo de energía durante la crisis de 2008-2009 tuvo una correlación positiva con la reducción de contaminación en las ciudades de Lisboa y Oporto.
Pacca et al (2020) y Xin et al (2022)	MP2.5 , NO ₂ ,O ₃ y SO ₂	Varios países	Series de tiempo extensas	Mostraron que, como consecuencias a crisis financieras, las emisiones disminuyeron para todos los contaminantes, pero esta situación suele variar dependiendo de la disponibilidad y calidad de la información de contaminación como también del nivel de desarrollo e ingresos de cada país, especialmente para el MP2.5.

1.4. Matrices energéticas, pobreza energética y su influencia en la calidad del aire urbano

La matriz energética de una ciudad, es decir, la combinación de fuentes primarias que abastecen su demanda— constituye un factor clave en la generación de contaminantes atmosféricos, particularmente dióxido de nitrógeno (NO₂) y material particulado fino (PM_{2.5}). Estas emisiones provienen en gran medida de la combustión de combustibles fósiles en sectores como el transporte, la industria y la generación de energía eléctrica (Liu et al., 2020; Goldberg et al., 2020). Sin embargo, el impacto de dicho consumo energético sobre la calidad del aire no es homogéneo, sino que está mediado por factores socioeconómicos, entre los que destaca la pobreza energética.

La pobreza energética, entendida como la falta de acceso a energía asequible, confiable y limpia, condiciona tanto las fuentes de emisiones como la magnitud de su aporte a la atmósfera (Bouzarovski & Petrova, 2015). En ciudades con baja pobreza energética y matrices diversificadas hacia energías limpias como Berlín, Tokio, París o Nueva York, las correlaciones entre consumo energético per cápita y niveles de NO₂ suelen ser fuertes, pero se ven moderadas por bajas intensidades energéticas, alta eficiencia tecnológica y políticas ambientales estrictas que reducen AOD y PM_{2.5} (Tan et al., 2021; Zhou et al., 2021). En contraste, en contextos con alta pobreza energética como Dhaka, Lagos o Kinshasa, una proporción sustancial de las emisiones procede de fuentes no reguladas, como la combustión doméstica de biomasa, la

incineración de residuos y el uso de combustibles residenciales ineficientes (Khan et al., 2023; Islam et al., 2025). Estas prácticas no solo incrementan la contaminación local, sino que también limitan la efectividad de políticas centradas únicamente en la reducción de consumo energético formal.

La respuesta de las ciudades ante crisis globales refuerza esta diferenciación. Durante la crisis financiera de 2008–2009 y la pandemia de COVID-19, urbes con matrices más limpias y baja pobreza energética mostraron reducciones pronunciadas y sostenidas en los niveles de NO_2 y, en menor medida, en AOD, impulsadas por la drástica disminución de la movilidad y la actividad económica (Bauwens et al., 2020; Le Quéré et al., 2020). Por el contrario, en contextos con alta pobreza energética, la reducción fue limitada, ya que las fuentes domésticas e informales continuaron operando e incluso aumentaron durante el confinamiento (Otmani et al., 2020; Gkatzelis et al., 2021).

Esta relación entre pobreza energética, matriz de consumo y calidad del aire sugiere que las estrategias de mitigación deben adaptarse al contexto socioeconómico y estructural de cada ciudad. En las urbes con mayor pobreza energética, la mejora de la calidad del aire pasa por garantizar acceso a energía limpia y asequible, regulando y sustituyendo las fuentes domésticas más contaminantes. En las ciudades desarrolladas, en cambio, las prioridades se centran en la electrificación del transporte, la expansión de energías renovables y la mejora continua de la eficiencia energética (Zhang et al., 2021; Calvo et al., 2022).

En este sentido, integrar el análisis de datos satelitales de contaminantes atmosféricos con indicadores energéticos y socioeconómicos, ofrece una vía prometedora para comprender las dinámicas diferenciales de contaminación urbana y anticipar su comportamiento ante futuras crisis. Este enfoque multidimensional permitirá no solo evaluar el impacto de políticas ambientales y energéticas, sino también diseñar intervenciones más equitativas y efectivas para la transición hacia entornos urbanos más saludables y resilientes.

1.5. Fuentes de datos de contaminación atmosférica

Hasta el momento, las investigaciones realizadas siguen metodologías tradicionales para el análisis de la calidad del aire. Usualmente, para estudios de contaminantes se utilizan principalmente datos de una o varias estaciones de monitoreo para un área / ciudad, lo que no permite que se capture la variación espacial dentro del área. Es y sería importante poder caracterizar de mejor manera la distribución de la contaminación del aire y sus efectos en la salud, también en ciudades más pequeñas, áreas suburbanas y rurales, donde vive una gran fracción de la población y que podrían mostrar mayores riesgos de referencia debido a un menor acceso a los centros de salud o condiciones socioeconómicas más desfavorecidas. Una alternativa para capturar la variabilidad de la contaminación atmosférica en áreas extensas son los modelos de transporte químico atmosférico (CTM). Estos representan (1) las emisiones de fuentes antropogénicas y naturales, (2) la química atmosférica y (3) los procesos de transporte, dilución y deposición. Los modelos de transporte químico se utilizan ampliamente para evaluar la respuesta de la calidad del aire a las políticas de control de emisiones (Wang et al., 2014; Daskalakis et al., 2016; Sourì et al., 2016; Chen et al., 2019). Sin embargo, su baja capacidad de adaptación para episodios particulares/extremos, no los hace una opción válida para capturar las variaciones en las concentraciones de contaminación en esos casos. Eventos extremos, como erupciones volcánicas (Kristiansen et al., 2016; Wilkins et al., 2016; Beckett et al., 2020), incendios forestales (Liu et al., 2010), olas de calor (Churkina et al., 2017; Zhao et al., 2019) o periodo de pandemia (Volke et al., 2023), juegan un papel particularmente importante en este sentido, ya que tales eventos pueden exponer sesgos del modelo o procesos faltantes. Además, existen grandes incertidumbres en los inventarios de emisiones y en los propios modelos, que inevitablemente afectan los resultados de los modelos de transporte químico (Li et al., 2017; Gao et al., 2018).

Para superar la deficiencia de cobertura espaciotemporal de las observaciones de contaminantes atmosféricos como el NO_2 y $\text{MP}_{2.5}$, y como alternativa a los modelos de transporte químico, los datos de teleobservación por satélite se han utilizado para estimar las concentraciones de estos contaminantes en superficie (Fang et al., 2016; Wei et al., 2019). En general, para $\text{MP}_{2.5}$, se han utilizado mediciones satelitales de profundidad óptica de aerosol (AOD), para ayudar a predecir las concentraciones de material particulado a nivel del suelo en lugares o períodos sin mediciones (de Hoogh et al., 2018; Di et al., 2016; Kloog et al., 2012; Lee et al., 2015; Stafoggia et al., 2016). AOD cuantifica la cantidad de luz absorbida o dispersada por partículas en suspensión, por lo que representa un parámetro relevante para predecir la variabilidad de PM, aunque imperfecto, siendo una estimación columnar mientras que las concentraciones de material particulado se miden a nivel del suelo. En el caso del NO_2 , la reciente disponibilidad del NO_2 troposférico, gracias a los datos de los instrumentos a bordo de plataformas de satélites como el Instrumento de Vigilancia del Ozono (OMI) y el Instrumento de Vigilancia Troposférica (TROPOMI) han demostrado un alto grado de precisión en la cuantificación de NO_2 troposférico sobre las ciudades, como lo demuestran Prunet et al. (2020). Lamsal et al. (2021) describió el potencial de las columnas de NO_2 troposférico recuperado por OMI para inferir las concentraciones de NO_2 a nivel del suelo a diferentes escalas espaciales y temporales sobre América del Norte. Otros estudios que han utilizados datos satelitales desde OMI para desarrollar modelos de NO_2 fueron llevados a cabo por Lee et al. (2018) y Zhan et al. (2022) que utilizaron datos de OMI para estimar las concentraciones de NO_2 diario en Nueva Inglaterra, EE.UU., para los años 2005-2010 y en China para 2013-2016, respectivamente. Por lo tanto, los datos satelitales proporcionan una fuente de datos homogénea y global, y pueden mejorar enormemente la comprensión de cambios de tendencia y la distribución espacial de contaminantes atmosféricos. Van Donkelaar (2021), desarrollo y aplico una metodología para estimaciones mensuales de $\text{MP}_{2.5}$ durante

el período 1998-2019, que combina recuperaciones satelitales de la profundidad óptica del aerosol (productos satelitales de MAIAC MODIS), modelos de transporte químico (modelos de transporte químico GEOS-Chem) y mediciones terrestres para permitir la caracterización de la exposición estacional y episódica, así como ayudar a la gestión de la calidad del aire. Esta base de datos global entrega una buena herramienta para la evaluación de cambios en la calidad del aire durante episodios de crisis durante las últimas décadas. Otros estudios, también se han basado en datos satélites para comprender los cambios en las concentraciones de contaminantes durante periodos excepcionales. Por ejemplo, durante la pandemia, estudios han indicado que los niveles de contaminación disminuyeron en China (Liu et al., 2020; Zhang et al., 2020). También se han observado disminuciones similares en el norte de Italia (Virghileanu et al., 2020), India (Vadrevu et al., 2020), España (Tobías et al., 2020), Brasil (Nakada y Urban, 2020; Tobías et al., 2020), y Europa Occidental (Bauwens et al., 2020).

Por tanto, con el objetivo de mejorar los enfoques anteriores en cuanto a una mayor robustez y generalización del análisis de contaminantes atmosféricos durante periodos de crisis, se están utilizando datos de contaminación atmosféricos derivados de imágenes satelitales. Su cobertura global, permite poder medir las concentraciones de contaminantes atmosféricos con una escala única y comparable para todas las regiones del planeta durante los periodos de cambios “excepcionales”. En el contexto COVID-19, Volke et al. (2023), utilizó imágenes del instrumento TROPOMI sobre las principales ciudades de Latinoamérica, para comparar los cambios en los niveles de NO₂ en el periodo marzo-junio de 2020 con respecto al mismo periodo de 2019. También encontró una alta correlación entre la disminución de NO₂ satelital con la reducción de la movilidad de la población, siendo esto claramente vinculable a uno de los sectores de consumo energético más relevantes como el sector transporte. Estudios recientes, también han tenido en cuenta fenómenos como la guerra entre Ucrania y Rusia para el análisis de las variaciones en los consumos energéticos y sus efectos en la calidad del aire a través de datos satelitales (Wieczorek, 2023). Se señala que, según la actividad antropogénica, la producción y distribución de energía, la industria, la red de transporte o la agricultura se presentan diferentes impactos en el nivel de concentración de gases en específico (Wieczorek, 2023). La ciudad de Kiev es una referencia característica, para la cual se registró una disminución del 33% en la concentración de NO₂ en 2022 (Chengxin et al., 2023). Por otra parte, se registró un aumento del SO₂ en 2022 en la costa polaca. Esto puede estar relacionado con el aumento del transporte marítimo de recursos energéticos, que hasta ahora se han enviado a través de un gasoducto desde Rusia. Otro caso se refiere a varias zonas que conectan ambos países para los cuales se presenta una tendencia al aumento del NO₂. Según datos de la Guardia de Fronteras polaca, aproximadamente 10 millones de refugiados han cruzado la frontera polaco-ucraniana desde el 24 de febrero de 2022 (<https://www.strazgraniczna.pl/>). La migración masiva de la población y el creciente movimiento de suministros por transporte marítimo provocan la liberación de contaminantes adicionales en el aire.

1.6. Hipótesis de trabajo:

Las variaciones en el consumo energético durante crisis globales provocan cambios significativos en las concentraciones de PM_{2.5} y NO₂ en megaciudades, cuyas respuestas se agrupan según sus condiciones socioeconómicas y matrices energéticas. Identificar estos patrones permitirá diseñar intervenciones futuras adaptadas a cada contexto, optimizando su impacto en la calidad del aire.

1.7. Objetivos:

1.7.1. Objetivo general:

Analizar cómo los cambios en el consumo energético durante crisis globales afectan las concentraciones de PM_{2.5} y NO₂ en megaciudades de América, Europa, África, Oceanía y Asia, mediante datos satelitales, variables meteorológicas y energéticas, identificando el grado de afectación y si las respuestas se agrupan según patrones socioeconómicos y características de sus matrices energéticas.

1.7.2. Objetivos específicos:

Objetivo 1: Cuantificar el efecto de las restricciones de movilidad durante la primera ola de la pandemia de COVID-19 sobre las concentraciones de NO₂ en ciudades clave de América Latina, evaluando el grado de reducción y su relación con cambios en el consumo energético.

Objetivo 2: Identificar la relación entre consumo energético y concentraciones de NO₂ troposférico en Santiago de Chile mediante un enfoque multimétodo, estimando el grado de afectación según periodos de crisis y años normales.

Objetivo 3: Detectar y clasificar patrones globales en series temporales (2005–2022) de NO₂ troposférico y AOD en megaciudades, vinculando las variaciones observadas con variables energéticas y socioeconómicas, para identificar

agrupaciones según su respuesta ante crisis globales y cambios en patrones de consumo.

1.8. Estructura de la tesis

Cada objetivo específico de la tesis está asociado a un capítulo específico que abarcan el estudio de la interacción entre los sistemas de consumo energético y la contaminación atmosférica. Para abordar el primer objetivo, se desarrollo en el capítulo 2: "Impact of mobility restrictions on NO₂ concentrations in key Latin American cities during the first wave of the COVID-19 pandemic". El Segundo objetivo fue abordado en el Capítulo 3: "Assessing the Influence of Energy Consumption on Tropospheric NO₂ in Santiago, Chile: A Multi-Method Approach Using Satellite Data". El tercer objetivo fue abordado en el capítulo 4: "Clustering Time Series Analysis of Tropospheric NO₂ and AOD Satellite Data in Global Megacities: Exploring Patterns Linked to Energy-Related Variables". Finalmente, en el Capítulo 5 se desarrolla una conclusión general de esta tesis.

Referencias

- Abadie, L. M. (2021). Energy Market Prices in Times of COVID-19: The Case of Electricity and Natural Gas in Spain. *Energies* 2021, Vol. 14, Page 1632, 14(6), 1632. <https://doi.org/10.3390/EN14061632>
- Acheampong, A. O. (2018). Economic growth, CO₂ emissions and energy consumption: What causes what and where? *Energy Economics*, 74, 677–692. <https://doi.org/10.1016/J.ENECO.2018.07.022>
- Agbede, E. A., Bani, Y., Azman-Saini, W. N. W., & Naseem, N. A. M. (2021). The impact of energy consumption on environmental quality: empirical evidence from the MINT countries. *Environmental Science and Pollution Research International*, 28(38), 54117–54136. <https://doi.org/10.1007/S11356-021-14407-2>
- Akadiri, S. Saint, Adebayo, T. S., Nakorji, M., Mwakapwa, W., Inusa, E. M., & Izuchukwu, O. O. (2022). Impacts of globalization and energy consumption on environmental degradation: what is the way forward to achieving environmental sustainability targets in Nigeria? *Environmental Science and Pollution Research*, 29(40), 60426–60439. <https://doi.org/10.1007/S11356-022-20180-7/TABLES/3>
- Akadiri, S. Saint, Bekun, F. V., & Sarkodie, S. A. (2019). Contemporaneous interaction between energy consumption, economic growth and environmental sustainability in South Africa: What drives what? *Science of The Total Environment*, 686, 468–475. <https://doi.org/10.1016/J.SCITOTENV.2019.05.421>
- Aktar, M. A., Alam, M. M., & Al-Amin, A. Q. (2021). Global economic crisis, energy use, CO₂ emissions, and policy roadmap amid COVID-19. *Sustainable Production and Consumption*, 26, 770–781. <https://doi.org/10.1016/J.SPC.2020.12.029>
- Araki, S., Shima, M., & Yamamoto, K. (2018). Spatiotemporal land use random forest model for estimating metropolitan NO₂ exposure in Japan. *Science of The Total Environment*, 634, 1269–1277. <https://doi.org/10.1016/J.SCITOTENV.2018.03.324>
- Aruga, K., Islam, M. M., & Jannat, A. (2020). Effects of COVID-19 on Indian Energy Consumption. *Sustainability* 2020, Vol. 12, Page 5616, 12(14), 5616. <https://doi.org/10.3390/SU12145616>
- Chen, J., Wang, P., Cui, L., Huang, S., & Song, M. (2018). Decomposition and decoupling analysis of CO₂ emissions in OECD. *Applied Energy*, 231, 937–950. <https://doi.org/10.1016/J.APENERGY.2018.09.179>
- Chen, W., Zhang, S., Li, R., & Shahabi, H. (2018). Performance evaluation of the GIS-based data mining techniques of best-first decision tree, random forest, and naïve Bayes tree for landslide susceptibility modeling. *Science of The Total Environment*, 644, 1006–1018. <https://doi.org/10.1016/J.SCITOTENV.2018.06.389>
- Cummins, N., Baird, A., & Schuller, B. W. (2018). Speech analysis for health: Current state-of-the-art and the increasing impact of deep learning. *Methods*, 151, 41–54. <https://doi.org/10.1016/J.YMETH.2018.07.007>
- Dahir, A. M., & Mahi, M. (2022). Does energy efficiency improve environmental quality in BRICS countries? Empirical evidence using dynamic panels with heterogeneous slopes. *Environmental Science and Pollution Research*, 29(8), 12027–12042. <https://doi.org/10.1007/S11356-021-16410-Z/TABLES/9>
- Darynova, Z., Amouei Torkmahalleh, M., Abdrakhmanov, T., Sabyrzhan, S., Sagynov, S., Hopke, P. K., & Kushta, J. (2020). SO₂ and HCHO over the major cities of Kazakhstan from 2005 to 2016: influence of political, economic and industrial changes. *Scientific Reports* 2020 10:1, 10(1), 1–8. <https://doi.org/10.1038/s41598-020-69344-w>
- de Bem, P. P., de Carvalho, O. A., Guimarães, R. F., & Gomes, R. A. T. (2020). Change Detection of Deforestation in the Brazilian Amazon Using Landsat Data and Convolutional Neural Networks. *Remote Sensing* 2020, Vol. 12, Page 901, 12(6), 901. <https://doi.org/10.3390/RS12060901>
- de la Barrera, F., Barraza, F., Favier, P., Ruiz, V., & Quense, J. (2018). Megafires in Chile 2017: Monitoring multiscale environmental impacts of burned ecosystems. *Science of The Total Environment*, 637–638, 1526–1536. <https://doi.org/10.1016/J.SCITOTENV.2018.05.119>
- Di, Q., Amini, H., Shi, L., Kloog, I., Silvern, R., Kelly, J., Sabath, M. B., Choirat, C., Koutrakis, P., Lyapustin, A., Wang, Y., Mickley, L. J., & Schwartz, J. (2019). An ensemble-based model of PM_{2.5} concentration across the contiguous United States with high spatiotemporal resolution. *Environment International*, 130, 104909. <https://doi.org/10.1016/J.ENVINT.2019.104909>
- Eslami, E., Salman, A. K., Choi, Y., Sayeed, A., & Lops, Y. (2020). A data ensemble approach for real-time air quality forecasting using extremely randomized trees and deep neural networks. *Neural Computing and Applications*, 32(11), 7563–7579. <https://doi.org/10.1007/S00521-019-04287-6/FIGURES/9>
- Fang, W., Zhong, B., Zhao, N., Love, P. E. D., Luo, H., Xue, J., & Xu, S. (2019). A deep learning-based approach for mitigating falls from height with computer vision: Convolutional neural network. *Advanced Engineering Informatics*, 39, 170–177. <https://doi.org/10.1016/J.AEI.2018.12.005>

- Gao, H., Yang, W., Wang, J., & Zheng, X. (2020). Analysis of the Effectiveness of Air Pollution Control Policies Based on Historical Evaluation and Deep Learning Forecast: A Case Study of Chengdu-Chongqing Region in China. *Sustainability* 2021, Vol. 13, Page 206, 13(1), 206. <https://doi.org/10.3390/SU13010206>
- Geng, T., Ju, T., Li, B., An, B., & Su, H. (2023). Prediction of the Tropospheric NO₂ Column Concentration and Distribution Using the Time Sequence-Based versus Influencing Factor-Based Random Forest Regression Model. *Sustainability* 2023, Vol. 15, Page 2748, 15(3), 2748. <https://doi.org/10.3390/SU15032748>
- Ghahremanloo, M., Lops, Y., Choi, Y., Jung, J., Mousavinezhad, S., & Hammond, D. (2022). A comprehensive study of the COVID-19 impact on PM_{2.5} levels over the contiguous United States: A deep learning approach. *Atmospheric Environment*, 272, 118944. <https://doi.org/10.1016/J.ATMOSENV.2022.118944>
- Grange, S. K., & Carslaw, D. C. (2019). Using meteorological normalisation to detect interventions in air quality time series. *Science of The Total Environment*, 653, 578–588. <https://doi.org/10.1016/J.SCITOTENV.2018.10.344>
- Grange, S. K., Carslaw, D. C., Lewis, A. C., Boleti, E., & Hueglin, C. (2018). Random forest meteorological normalisation models for Swiss PM₁₀ trend analysis. *Atmospheric Chemistry and Physics*, 18(9), 6223–6239. <https://doi.org/10.5194/ACP-18-6223-2018>
- Griffin, D., Sioris, C., Chen, J., Dickson, N., Kovachik, A., De Graaf, M., Nanda, S., Veefkind, P., Dammers, E., McLinden, C. A., Makar, P., & Akingunola, A. (2020). The 2018 fire season in North America as seen by TROPOMI: Aerosol layer height intercomparisons and evaluation of model-derived plume heights. *Atmospheric Measurement Techniques*, 13(3), 1427–1445. <https://doi.org/10.5194/AMT-13-1427-2020>
- Gu, K., Zhou, Y., Sun, H., Dong, F., & Zhao, L. (2021). Spatial distribution and determinants of PM_{2.5} in China's cities: fresh evidence from IDW and GWR. *Environmental Monitoring and Assessment*, 193(1), 1–22. <https://doi.org/10.1007/S10661-020-08749-6/FIGURES/8>
- Gui, K., Che, H., Zeng, Z., Wang, Y., Zhai, S., Wang, Z., Luo, M., Zhang, L., Liao, T., Zhao, H., Li, L., Zheng, Y., & Zhang, X. (2020). Construction of a virtual PM_{2.5} observation network in China based on high-density surface meteorological observations using the Extreme Gradient Boosting model. *Environment International*, 141, 105801. <https://doi.org/10.1016/J.ENVINT.2020.105801>
- Güngör, H., Abu-Goodman, M., Olanipekun, I. O., & Usman, O. (2021). Testing the environmental Kuznets curve with structural breaks: the role of globalization, energy use, and regulatory quality in South Africa. *Environmental Science and Pollution Research*, 28(16), 20772–20783. <https://doi.org/10.1007/S11356-020-11843-4/TABLES/6>
- Hammer, M. S., Van Donkelaar, A., Li, C., Lyapustin, A., Sayer, A. M., Hsu, N. C., Levy, R. C., Garay, M. J., Kalashnikova, O. V., Kahn, R. A., Brauer, M., Apte, J. S., Henze, D. K., Zhang, L., Zhang, Q., Ford, B., Pierce, J. R., & Martin, R. V. (2020). Global Estimates and Long-Term Trends of Fine Particulate Matter Concentrations (1998-2018). *Environmental Science and Technology*, 54(13), 7879–7890. https://doi.org/10.1021/ACS.EST.0C01764/ASSET/IMAGES/LARGE/ES0C01764_0007.JPEG
- Hao, Y., Peng, H., Temulun, T., Liu, L. Q., Mao, J., Lu, Z. N., & Chen, H. (2018). How harmful is air pollution to economic development? New evidence from PM_{2.5} concentrations of Chinese cities. *Journal of Cleaner Production*, 172, 743–757. <https://doi.org/10.1016/J.JCLEPRO.2017.10.195>
- Huang, F., Zhang, J., Zhou, C., Wang, Y., Huang, J., & Zhu, L. (2020). A deep learning algorithm using a fully connected sparse autoencoder neural network for landslide susceptibility prediction. *Landslides*, 17(1), 217–229. <https://doi.org/10.1007/S10346-019-01274-9/TABLES/4>
- Huang, W., Li, S., Ravan, S., & Wieczorek, B. (2023). Air Pollution Patterns Mapping of SO₂, NO₂, and CO Derived from TROPOMI over Central-East Europe. *Remote Sensing* 2023, Vol. 15, Page 1565, 15(6), 1565. <https://doi.org/10.3390/RS15061565>
- Hung, N. T., Trang, N. T., & Thang, N. T. (2022). Quantile relationship between globalization, financial development, economic growth, and carbon emissions: evidence from Vietnam. *Environmental Science and Pollution Research*, 29(40), 60098–60116. <https://doi.org/10.1007/S11356-022-20126-Z/FIGURES/3>
- Itahashi, S., Yamamura, Y., Wang, Z., & Uno, I. (2022). Returning long-range PM_{2.5} transport into the leeward of East Asia in 2021 after Chinese economic recovery from the COVID-19 pandemic. *Scientific Reports* 2022 12:1, 12(1), 1–11. <https://doi.org/10.1038/s41598-022-09388-2>
- Jacobson, M. Z., von Krauland, A. K., Coughlin, S. J., Dukas, E., Nelson, A. J. H., Palmer, F. C., & Rasmussen, K. R. (2022). Low-cost solutions to global warming, air pollution, and energy insecurity for 145 countries. *Energy & Environmental Science*, 15(8), 3343–3359. <https://doi.org/10.1039/D2EE00722C>
- Jiang, Y., Zhou, Z., & Liu, C. (2019). Does economic policy uncertainty matter for carbon emission? Evidence from US sector level data. *Environmental Science and Pollution Research*, 26(24), 24380–24394. <https://doi.org/10.1007/S11356-019-05627-8/TABLES/7>
- Khan, I., Hou, F., & Le, H. P. (2021). The impact of natural resources, energy consumption, and population growth on environmental quality: Fresh evidence from the United States of America. *Science of The Total Environment*, 754, 142222. <https://doi.org/10.1016/J.SCITOTENV.2020.142222>
- Khan, M. K., Khan, M. I., & Rehan, M. (2020). The relationship between energy consumption, economic growth and carbon dioxide emissions in Pakistan. *Financial Innovation*, 6(1), 1–13. <https://doi.org/10.1186/S40854-019-0162-0/FIGURES/2>
- Leal Filho, W., Tripathi, S. K., Andrade Guerra, J. B. S. O. D., Giné-Garriga, R., Orlovic Lovren, V., & Willats, J. (2018). Using the sustainable development goals towards a better understanding of sustainability challenges. <https://doi.org/10.1080/13504509.2018.1505674>
- Lee, C. S., Chang, K. H., & Kim, H. (2018a). Long-term (2005–2015) trend analysis of PM_{2.5} precursor gas NO₂ and SO₂ concentrations in Taiwan. *Environmental Science and Pollution Research*, 25(22), 22136–22152. <https://doi.org/10.1007/S11356-018-2273-Y/FIGURES/9>
- Lee, C. S., Chang, K. H., & Kim, H. (2018b). Long-term (2005–2015) trend analysis of PM_{2.5} precursor gas NO₂ and SO₂ concentrations in Taiwan. *Environmental Science and Pollution Research*, 25(22), 22136–22152. <https://doi.org/10.1007/S11356-018-2273-Y/FIGURES/9>
- Lee, C. S., Chang, K. H., & Kim, H. (2018c). Long-term (2005–2015) trend analysis of PM_{2.5} precursor gas NO₂ and SO₂ concentrations in Taiwan. *Environmental Science and Pollution Research*, 25(22), 22136–22152. <https://doi.org/10.1007/S11356-018-2273-Y/FIGURES/9>
- Levy, R. C., Mattoo, S., Munchak, L. A., Remer, L. A., Sayer, A. M., Patadia, F., & Hsu, N. C. (2013). The Collection 6 MODIS aerosol

- products over land and ocean. *Atmospheric Measurement Techniques*, 6(11), 2989–3034. <https://doi.org/10.5194/AMT-6-2989-2013>
- Levy, Robert C., Mattoo, S., Sawyer, V., Shi, Y., Colarco, P. R., Lyapustin, A. I., Wang, Y., & Remer, L. A. (2018). Exploring systematic offsets between aerosol products from the two MODIS sensors. *Atmospheric Measurement Techniques*, 11(7), 4073–4092. <https://doi.org/10.5194/AMT-11-4073-2018>
- Li, Hongming, Habes, M., Wolk, D. A., & Fan, Y. (2019). A deep learning model for early prediction of Alzheimer's disease dementia based on hippocampal magnetic resonance imaging data. *Alzheimer's & Dementia*, 15(8), 1059–1070. <https://doi.org/10.1016/J.JALZ.2019.02.007>
- Li, Huimin, Yang, Y., Wang, H., Li, B., Wang, P., Li, J., & Liao, H. (2021). Constructing a spatiotemporally coherent long-term PM2.5 concentration dataset over China during 1980–2019 using a machine learning approach. *Science of The Total Environment*, 765, 144263. <https://doi.org/10.1016/J.SCITOTENV.2020.144263>
- Li, L., & Wu, J. (2021). Spatiotemporal estimation of satellite-borne and ground-level NO2 using full residual deep networks. *Remote Sensing of Environment*, 254, 112257. <https://doi.org/10.1016/J.RSE.2020.112257>
- Li, T., Shen, H., Yuan, Q., Zhang, X., & Zhang, L. (2017). Estimating Ground-Level PM2.5 by Fusing Satellite and Station Observations: A Geo-Intelligent Deep Learning Approach. *Geophysical Research Letters*, 44(23), 11,985–11,993. <https://doi.org/10.1002/2017GL075710>
- Li, Z., Peng, F., Niu, B., Li, G., Wu, J., & Miao, Z. (2018). Water Quality Prediction Model Combining Sparse Auto-encoder and LSTM Network. *IFAC-PapersOnLine*, 51(17), 831–836. <https://doi.org/10.1016/J.IFACOL.2018.08.091>
- Lin, X., Liao, Y., & Hao, Y. (2018). The burden associated with ambient PM2.5 and meteorological factors in Guangzhou, China, 2012–2016: A generalized additive modeling of temporal years of life lost. *Chemosphere*, 212, 705–714. <https://doi.org/10.1016/J.CHEMOSPHERE.2018.08.129>
- Liu, F., Wang, M., & Zheng, M. (2021). Effects of COVID-19 lockdown on global air quality and health. *Science of The Total Environment*, 755, 142533. <https://doi.org/10.1016/J.SCITOTENV.2020.142533>
- Lyapustin, A., Wang, Y., Laszlo, I., Kahn, R., Korokin, S., Remer, L., Levy, R., & Reid, J. S. (2011). Multiangle implementation of atmospheric correction (MAIAC): 2. Aerosol algorithm. *Journal of Geophysical Research: Atmospheres*, 116(D3). <https://doi.org/10.1029/2010JD014986>
- Lyapustin, Alexei, Martonchik, J., Wang, Y., Laszlo, I., & Korokin, S. (2011). Multiangle implementation of atmospheric correction (MAIAC): 1. Radiative transfer basis and look-up tables. *Journal of Geophysical Research: Atmospheres*, 116(D3). <https://doi.org/10.1029/2010JD014985>
- Lyapustin, Alexei, Wang, Y., Korokin, S., & Huang, D. (2018). MODIS Collection 6 MAIAC algorithm. *Atmospheric Measurement Techniques*, 11(10), 5741–5765. <https://doi.org/10.5194/AMT-11-5741-2018>
- Ma, J., Cheng, J. C. P., Lin, C., Tan, Y., & Zhang, J. (2019). Improving air quality prediction accuracy at larger temporal resolutions using deep learning and transfer learning techniques. *Atmospheric Environment*, 214, 116885. <https://doi.org/10.1016/J.ATMOENV.2019.116885>
- Maciej Serda, Becker, F. G., Cleary, M., Team, R. M., Holtermann, H., The, D., Agenda, N., Science, P., Sk, S. K., Hinnebusch, R., Hinnebusch, A. R., Rabinovich, I., Olmert, Y., Uld, D. Q. G. L. Q., Ri, W. K. H. U., Lq, V., Frxqwu, W. K. H., Zklfk, E., Edvhg, L. V, ... فاطمي, ح. (2013). Synteza i aktywność biologiczna nowych analogów tiosemikarbazonowych chelatorów żelaza. *Uniwersytet Śląski*, 7(1), 343–354. <https://doi.org/10.2/JQUERY.MIN.JS>
- Magro, C., Nunes, L., Gonçalves, O. C., Neng, N. R., Nogueira, J. M. F., Rego, F. C., & Vieira, P. (2021). Atmospheric trends of CO and CH4 from extreme wildfires in Portugal using sentinel-5P TROPOMI level-2 data. *Fire*, 4(2), 25. <https://doi.org/10.3390/FIRE4020025/S1>
- Mao, W., Wang, W., Jiao, L., Zhao, S., & Liu, A. (2021). Modeling air quality prediction using a deep learning approach: Method optimization and evaluation. *Sustainable Cities and Society*, 65, 102567. <https://doi.org/10.1016/J.SCS.2020.102567>
- Muhammad, B. (2019). Energy consumption, CO2 emissions and economic growth in developed, emerging and Middle East and North Africa countries. *Energy*, 179, 232–245. <https://doi.org/10.1016/J.ENERGY.2019.03.126>
- Munir, Q., Lean, H. H., & Smyth, R. (2020). CO2 emissions, energy consumption and economic growth in the ASEAN-5 countries: A cross-sectional dependence approach. *Energy Economics*, 85, 104571. <https://doi.org/10.1016/J.ENERGY.2019.104571>
- Pacca, L., Antonarakis, A., Schröder, P., & Antoniadis, A. (2020). The effect of financial crises on air pollutant emissions: An assessment of the short vs. medium-term effects. *Science of The Total Environment*, 698, 133614. <https://doi.org/10.1016/J.SCITOTENV.2019.133614>
- Petetin, H., Bowdalo, D., Soret, A., Guevara, M., Jorba, O., Serradell, K., & Pérez García-Pando, C. (2020). Meteorology-normalized impact of the COVID-19 lockdown upon NO2 pollution in Spain. *Atmospheric Chemistry and Physics*, 20(18), 11119–11141. <https://doi.org/10.5194/ACP-20-11119-2020>
- Pirgaip, B., & Dinçergök, B. (2020). Economic policy uncertainty, energy consumption and carbon emissions in G7 countries: evidence from a panel Granger causality analysis. *Environmental Science and Pollution Research*, 27(24), 30050–30066. <https://doi.org/10.1007/S11356-020-08642-2/TABLES/6>
- Plappert, M., Mandery, C., & Asfour, T. (2018). Learning a bidirectional mapping between human whole-body motion and natural language using deep recurrent neural networks. *Robotics and Autonomous Systems*, 109, 13–26. <https://doi.org/10.1016/J.ROBOT.2018.07.006>
- Qi, G., Wang, Z., Wei, L., & Wang, Z. (2022a). Multidimensional effects of urbanization on PM2.5 concentration in China. *Environmental Science and Pollution Research*, 29(51), 77081–77096. <https://doi.org/10.1007/S11356-022-21298-4/FIGURES/6>
- Qi, G., Wang, Z., Wei, L., & Wang, Z. (2022b). Multidimensional effects of urbanization on PM2.5 concentration in China. *Environmental Science and Pollution Research*, 29(51), 77081–77096. <https://doi.org/10.1007/S11356-022-21298-4/FIGURES/6>
- Ren, X., Mi, Z., & Georgopoulos, P. G. (2020). Comparison of Machine Learning and Land Use Regression for fine scale spatiotemporal estimation of ambient air pollution: Modeling ozone concentrations across the contiguous United States. *Environment International*, 142, 105827. <https://doi.org/10.1016/J.ENVINT.2020.105827>
- Sadorsky, P. (2020). Energy Related CO2 Emissions before and after the Financial Crisis. *Sustainability 2020*, Vol. 12, Page 3867, 12(9),

3867. <https://doi.org/10.3390/SU12093867>

- Sayed, A., Lops, Y., Choi, Y., Jung, J., & Salman, A. K. (2021). Bias correcting and extending the PM forecast by CMAQ up to 7 days using deep convolutional neural networks. *Atmospheric Environment*, 253, 118376. <https://doi.org/10.1016/J.ATMOSENV.2021.118376>
- Sewak, M., Sahay, S. K., & Rathore, H. (2020). An Overview of Deep Learning Architecture of Deep Neural Networks and Autoencoders. *Journal of Computational and Theoretical Nanoscience*, 17(1), 182–188. <https://doi.org/10.1166/JCTN.2020.8648>
- Sindosi, O., Markozannes, G., Rizos, E., & Ntzani, E. (2019). Effects of economic crisis on air quality in Ioannina, Greece. <https://doi.org/10.1080/10934529.2019.1592534>, 54(8), 768–781. <https://doi.org/10.1080/10934529.2019.1592534>
- Singh, H., Kumar, A., Balyan, L. K., & Singh, G. K. (2019). A novel optimally weighted framework of piecewise gamma corrected fractional order masking for satellite image enhancement. *Computers & Electrical Engineering*, 75, 245–261. <https://doi.org/10.1016/J.COMPELECENG.2017.11.014>
- Tiba, S., & Omri, A. (2017). Literature survey on the relationships between energy, environment and economic growth. *Renewable and Sustainable Energy Reviews*, 69, 1129–1146. <https://doi.org/10.1016/J.RSER.2016.09.113>
- Tong, D., Pan, L., Chen, W., Lamsal, L., Lee, P., Tang, Y., Kim, H., Kondragunta, S., & Stajner, I. (2016). Impact of the 2008 Global Recession on air quality over the United States: Implications for surface ozone levels from changes in NO_x emissions. *Geophysical Research Letters*, 43(17), 9280–9288. <https://doi.org/10.1002/2016GL069885>
- Tong, T., Ortiz, J., Xu, C., & Li, F. (2020). Economic growth, energy consumption, and carbon dioxide emissions in the E7 countries: A bootstrap ARDL bound test. *Energy, Sustainability and Society*, 10(1), 1–17. <https://doi.org/10.1186/S13705-020-00253-6/FIGURES/2>
- Van Donkelaar, A., Hammer, M. S., Bindle, L., Brauer, M., Brook, J. R., Garay, M. J., Hsu, N. C., Kalashnikova, O. V., Kahn, R. A., Lee, C., Levy, R. C., Lyapustin, A., Sayer, A. M., & Martin, R. V. (2021a). Monthly Global Estimates of Fine Particulate Matter and Their Uncertainty. *Environmental Science and Technology*, 55(22), 15287–15300. https://doi.org/10.1021/ACS.EST.1C05309/ASSET/IMAGES/LARGE/ES1C05309_0007.JPEG
- Van Donkelaar, A., Hammer, M. S., Bindle, L., Brauer, M., Brook, J. R., Garay, M. J., Hsu, N. C., Kalashnikova, O. V., Kahn, R. A., Lee, C., Levy, R. C., Lyapustin, A., Sayer, A. M., & Martin, R. V. (2021b). Monthly Global Estimates of Fine Particulate Matter and Their Uncertainty. *Environmental Science and Technology*, 55(22), 15287–15300. https://doi.org/10.1021/ACS.EST.1C05309/ASSET/IMAGES/LARGE/ES1C05309_0007.JPEG
- Van Donkelaar, A., Martin, R. V., Levy, R. C., da Silva, A. M., Krzyzanowski, M., Chubarova, N. E., Semutnikova, E., & Cohen, A. J. (2011). Satellite-based estimates of ground-level fine particulate matter during extreme events: A case study of the Moscow fires in 2010. *Atmospheric Environment*, 45(34), 6225–6232. <https://doi.org/10.1016/J.ATMOSENV.2011.07.068>
- Volke, M. I., Abarca-del-Rio, R., & Ulloa-Tesser, C. (2023). Impact of mobility restrictions on NO₂ concentrations in key Latin American cities during the first wave of the COVID-19 pandemic. *Urban Climate*, 48, 101412. <https://doi.org/10.1016/J.UCLIM.2023.101412>
- Wang, C. H., Padmanabhan, P., & Huang, C. H. (2022). The impacts of the 1997 Asian financial crisis and the 2008 global financial crisis on renewable energy consumption and carbon dioxide emissions for developed and developing countries. *Heliyon*, 8(2). <https://doi.org/10.1016/J.HELIYON.2022.E08931>
- Wang, X. C., Klemeš, J. J., Dong, X., Fan, W., Xu, Z., Wang, Y., & Varbanov, P. S. (2019). Air pollution terrain nexus: A review considering energy generation and consumption. *Renewable and Sustainable Energy Reviews*, 105, 71–85. <https://doi.org/10.1016/J.RSER.2019.01.049>
- Wei, J., Huang, W., Li, Z., Xue, W., Peng, Y., Sun, L., & Cribb, M. (2019). Estimating 1-km-resolution PM_{2.5} concentrations across China using the space-time random forest approach. *Remote Sensing of Environment*, 231, 111221. <https://doi.org/10.1016/J.RSE.2019.111221>
- Xiao, Q., Geng, G., Cheng, J., Liang, F., Li, R., Meng, X., Xue, T., Huang, X., Kan, H., Zhang, Q., & He, K. (2021). Evaluation of gap-filling approaches in satellite-based daily PM_{2.5} prediction models. *Atmospheric Environment*, 244, 117921. <https://doi.org/10.1016/J.ATMOSENV.2020.117921>
- Xin, D., & Xin, L. (2022a). The impact of economic policy uncertainty on PM_{2.5} pollution—evidence from 25 countries. *Environmental Science and Pollution Research*, 29(25), 38126–38142. <https://doi.org/10.1007/S11356-022-18599-Z/TABLES/8>
- Xin, D., & Xin, L. (2022b). The impact of economic policy uncertainty on PM_{2.5} pollution—evidence from 25 countries. *Environmental Science and Pollution Research*, 29(25), 38126–38142. <https://doi.org/10.1007/S11356-022-18599-Z/TABLES/8>
- Xin, D., & Xin, L. (2022c). The impact of economic policy uncertainty on PM_{2.5} pollution—evidence from 25 countries. *Environmental Science and Pollution Research*, 29(25), 38126–38142. <https://doi.org/10.1007/S11356-022-18599-Z/TABLES/8>
- Xue, Z., Gupta, P., & Christopher, S. (2021). Satellite-based estimation of the impacts of summertime wildfires on PM_{2.5} concentration in the United States. *Atmospheric Chemistry and Physics*, 21(14), 11243–11256. <https://doi.org/10.5194/ACP-21-11243-2021>
- Yang, B., Ali, M., Nazir, M. R., Ullah, W., & Qayyum, M. (2020). Financial instability and CO₂ emissions: cross-country evidence. *Air Quality, Atmosphere and Health*, 13(4), 459–468. <https://doi.org/10.1007/S11869-020-00809-7/TABLES/3>
- Yu, M., & Liu, Q. (2021). Deep learning-based downscaling of tropospheric nitrogen dioxide using ground-level and satellite observations. *Science of The Total Environment*, 773, 145145. <https://doi.org/10.1016/J.SCITOTENV.2021.145145>
- Yuping, L., Ramzan, M., Xincheng, L., Murshed, M., Awosusi, A. A., BAH, S. I., & Adebayo, T. S. (2021). Determinants of carbon emissions in Argentina: The roles of renewable energy consumption and globalization. *Energy Reports*, 7, 4747–4760. <https://doi.org/10.1016/J.EGYR.2021.07.065>
- Zhang, H., Zhan, Y., Li, J., Chao, C. Y., Liu, Q., Wang, C., Jia, S., Ma, L., & Biswas, P. (2021). Using Kriging incorporated with wind direction to investigate ground-level PM_{2.5} concentration. *Science of The Total Environment*, 751, 141813. <https://doi.org/10.1016/J.SCITOTENV.2020.141813>
- Zhang, Q., Xue, D., Liu, X., Gong, X., & Gao, H. (2019). Process analysis of PM_{2.5} pollution events in a coastal city of China using CMAQ. *Journal of Environmental Sciences*, 79, 225–238. <https://doi.org/10.1016/J.JES.2018.09.007>
- Zhou, C., Chen, J., & Wang, S. (2018). Examining the effects of socioeconomic development on fine particulate matter (PM_{2.5}) in China's cities using spatial regression and the geographical detector technique. *Science of The Total Environment*, 619–620, 436–445. <https://doi.org/10.1016/J.SCITOTENV.2017.11.124>

- Zhou, Y., Chang, F. J., Chang, L. C., Kao, I. F., & Wang, Y. S. (2019). Explore a deep learning multi-output neural network for regional multi-step-ahead air quality forecasts. *Journal of Cleaner Production*, 209, 134–145. <https://doi.org/10.1016/J.JCLEPRO.2018.10.243>
- Zou, Q., & Shi, J. (2020). The heterogeneous effect of socioeconomic driving factors on PM2.5 in China's 30 province-level administrative regions: Evidence from Bayesian hierarchical spatial quantile regression. *Environmental Pollution*, 264, 114690. <https://doi.org/10.1016/J.ENVPOL.2020.114690>
- Zuo, R., Xiong, Y., Wang, J., & Carranza, E. J. M. (2019). Deep learning and its application in geochemical mapping. *Earth-Science Reviews*, 192, 1–14. <https://doi.org/10.1016/J.EARSCIREV.2019.02.023>

Capítulo 2:

Impact of mobility restrictions on NO₂ concentrations in key Latin American cities during the first wave of the COVID-19 pandemic

Capítulo basado en:

Volke, M. I., Abarca-del-Rio, R., & Ulloa-Tesser, C. (2023). Impact of mobility restrictions on NO₂ concentrations in key Latin American cities during the first wave of the COVID-19 pandemic. *Urban Climate*, 48, 101412.

Impact of mobility restrictions on NO₂ concentrations in key Latin American cities during the first wave of the COVID-19 pandemic

Matias I. Volke ^a, Rodrigo Abarca-del-Rio ^b, Claudia Ulloa-Tesser ^c

^a Energy Doctoral Program, Faculty of Engineering, Universidad de Concepción, Concepción 4030000, Chile

^b Department of Geophysics, Faculty of Physical and Mathematical Sciences, University of Concepcion, Concepcion, Chile

^c Environmental Engineering Department, Faculty of Environmental Science and EULA Center, Universidad de Concepción, Chile

Abstract

Between March and June 2020, activity in the major cities of Latin America declined due to containment efforts implemented by local governments to avoid the rapid spread of COVID-19. Our study compared 2020 with the previous year and demonstrated a considerable drop in tropospheric NO₂ levels obtained by the SENTINEL 5P satellite in major Latin American cities. Lima (47.5%), Santiago (36.1%), São Paulo (27%), Rio de Janeiro (23%), Quito (18.6%), Bogota (17.5%), Buenos Aires (16.6%), Guayaquil (15.3%), Medellin (14.2%), La Paz (9.5%), Belo Horizonte (7.8%), Mexico (7.6%) and Brasilia (5.9%) registered statistically significant decreases in NO₂ concentrations during the study period. In addition, we analyzed mobility data from Google and Apple reports as well as meteorological information from atmospheric reanalysis data along with satellite fields between 2011 and 2020, and performed a refined multivariate analysis (non-negative matrix approximation) to show that this decrease was associated with a reduction in population mobility rather than meteorological factors. Our findings corroborate the argument that confinement scenarios may indicate how air pollutant concentrations can be effectively reduced and managed.

Resumen

Entre marzo y junio de 2020, la actividad en las principales ciudades de América Latina disminuyó debido a los esfuerzos de contención implementados por los gobiernos locales para evitar la rápida propagación del COVID-19. Nuestro estudio comparó 2020 con el año anterior y demostró una disminución considerable del NO₂ troposférico niveles obtenidos por el satélite SENTINEL 5P en las principales ciudades de América Latina. Lima (47,5%), Santiago (36,1%), São Paulo (27%), Río de Janeiro (23%), Quito (18,6%), Bogotá (17,5%), Buenos Aires (16,6%), Guayaquil (15,3%), Medellín (14,2%), La Paz (9,5%), Belo Horizonte (7,8%), México (7,6%) y Brasilia (5,9%) registraron disminuciones estadísticamente significativas en las concentraciones de NO₂ durante el periodo de estudio. Además, analizamos los datos de movilidad de los informes de Google y Apple, así como la información meteorológica de los datos de reanálisis atmosférico junto con los campos satelitales entre 2011 y 2020, y realizamos un análisis multivariante refinado (aproximación de matriz no negativa) para mostrar que esta disminución se asoció con una reducción de la movilidad de la población más que con factores meteorológicos. Nuestros hallazgos corroboran el argumento de que los escenarios de confinamiento pueden indicar cómo se pueden reducir y gestionar eficazmente las concentraciones de contaminantes atmosféricos.

2.1. Introducción

COVID-19, pandemia causada por SARS-CoV-2 (Morens and Fauci, 2020), se ha propagado rápidamente por todo el mundo desde finales de diciembre de 2019 (Shereen et al., 2020). La Organización Mundial de la Salud (OMS) declaró el brote como una emergencia de salud pública de importancia internacional el 30 de enero (OMS, 2020). El número de personas infectadas y la letalidad del COVID-19 aumentaron exponencialmente entre febrero y marzo de 2020 (Méndez-Espinosa et al., 2020), lo que obligó a las autoridades de todo el mundo a imponer medidas rápidas y estrictas contra el COVID-19, incluido el confinamiento de las ciudades (Goldberg et al., 2020). Se restringió la movilidad de los ciudadanos y se obligó a detener la mayoría de las actividades industriales, comerciales y de entretenimiento. El transporte también fue uno de los sectores más afectados por estos cierres, que redujeron significativamente el tráfico de automóviles en las carreteras (Méndez-Espinosa et al., 2020).

Las medidas de contención afectaron la vida cotidiana de los ciudadanos, cambiando la calidad del aire en las ciudades (Dantas et al., 2020; Saadat et al., 2020; Tobías et al., 2020). En Europa se han reportado variaciones en las concentraciones de contaminantes atmosféricos (Muhammad et al., 2020; Tobías et al., 2020), Asia (Shi and Basseur, 2020; Wang et al., 2020; Xu et al., 2020), África (Otmani et al., 2020), ciudades estadounidenses (Goldberg et al., 2020; Berman and Ebisu, 2020), y a nivel mundial (Tang et al., 2021) debido al cierre drástico de las actividades económicas y sociales. En América Latina, varios estudios han analizado el comportamiento de los contaminantes atmosféricos, por ejemplo, en Brasil (Dantas et al., 2020; Krecl et al., 2020; Nakada and Urban, 2020; Siciliano et al., 2020), Ecuador (Pacheco et al., 2020), Argentina (Bolaño-Ortiz et al., 2020), Colombia (Méndez-Espinosa et al., 2020), Perú (Rojas et al., 2021; Velayarce et al., 2022), Chile (Toro et al., 2021) y México (Hernández-Paniagua et al., 2021; Peralta et al., 2021).

Los estudios han demostrado que el NO₂ es el contaminante atmosférico que registró las mayores disminuciones en las ciudades que han implementado medidas de confinamiento (Bauwens et al., 2020; Goldberg et al., 2020; Vîrghileanu et al., 2020; Islam et al., 2021). Este contaminante atmosférico tiene una influencia sustancial en la salud humana directamente (a través de la inhalación) e indirectamente a través de su papel como precursor de contaminantes secundarios como el O₃ y PM_{2.5} (Grange et al., 2017). Las emisiones de NO₂ de las ciudades están vinculadas principalmente a la combustión de diésel y gasolina en el sector del transporte (Vîrghileanu et al., 2020). El NO₂ tiene una vida fotoquímica corta, que varía de dos a seis horas durante el día en verano (de Foy et al., 2014; Laughner and Cohen, 2019) y de 12 h a 24 h en invierno (Shah et al., 2020). Este corto tiempo de vida permite la correlación entre las concentraciones de NO₂ troposférico y las emisiones antropogénicas locales de NO_x (Pope et al., 2015; Wang et al., 2019).

La disponibilidad reciente de los datos de NO₂ troposférico (tropoNO₂) procedentes de instrumentos a bordo de plataformas de satélites como el Instrumento de Vigilancia del Ozono (OMI) y el Instrumento de Vigilancia de la Troposfera (TROPOMI) han demostrado un alto grado de exactitud en la cuantificación del tropoNO₂ sobre las ciudades, como lo demuestran Prunet et al. (2020). Por lo tanto, los datos satelitales proporcionan una nueva fuente de datos y amplían nuestra comprensión de las consecuencias de las restricciones a la movilidad de la población en ciudades densamente pobladas. Los datos obtenidos por TROPOMI a bordo del satélite Sentinel-5P (Agencia Espacial Europea (ESA)) mostraron una disminución de tropoNO₂ tras las medidas preventivas, centradas en la reducción del desplazamiento de la población (por ejemplo, confinamientos). Estudios previos basados en satélites han indicado que tropoNO₂ han disminuido en China (Liu et al., 2020; Zhang et al., 2020). También se han observado disminuciones similares en el norte de Italia (Vîrghileanu et al., 2020), India (Vadrevu et al., 2020), España (Tobías et al., 2020), Brasil (Nakada and Urban, 2020; Tobías et al., 2020) y Europa Occidental (Bauwens et al., 2020).

Los cambios en la calidad del aire durante el confinamiento de 2020 se han comparado con los periodos anteriores al confinamiento (por ejemplo, Agarwal et al., 2020; Mahato et al., 2020; Rodríguez-Urrego y Rodríguez-Urrego, 2020; Tobías et al., 2020; Shi and Basseur, 2020) o contra un período en el mismo intervalo de tiempo que ocurrió durante años anteriores (por ejemplo, Connerton et al., 2020; Kerimray et al., 2020; Shakoor et al., 2020; Sharma et al., 2020; Sicard et al., 2020). Muchos estudios que compararon los periodos anteriores al confinamiento demostraron una disminución significativa de los contaminantes atmosféricos como el NO₂ y material particulado durante los periodos de cuarentena. Tobías et al. (2020) observaron una reducción significativa de los NO₂ que van del 47.0% al 51.0%, y PM₁₀ que oscila entre el 27,8% y el 31,0% en Barcelona, España. De acuerdo con Shi and Basseur (2020), el PM_{2.5} y el NO₂ superficial en China disminuyeron aproximadamente un 35% y un 60%, respectivamente. El resultado más interesante fue el de Collivignarelli et

al. (2020), quienes compararon la calidad del aire en Milán, Italia, antes y durante el confinamiento en 2020 y mostraron que durante el período de cierre, los contaminantes relacionados con el tráfico, como las PM10, PM2.5 y los NOx se redujeron significativamente. Sin embargo, Jakob et al. (2022) demostraron que esta disminución de la contaminación atmosférica era simplemente un patrón estacional natural, ya que las precipitaciones en Milán aumentaron de febrero a abril. Por lo tanto, en comparación con los períodos inmediatamente anteriores al confinamiento (por ejemplo, enero-febrero frente a marzo-abril), no tiene en cuenta plenamente la influencia cambiante del clima.

La comparación con un período en el mismo intervalo de tiempo ocurrido durante el año anterior ofrece la ventaja de referirse a condiciones climáticas similares. Sin embargo, la variabilidad climática interanual puede dar lugar a cambios significativos en las concentraciones de contaminantes atmosféricos. En consecuencia, las variables meteorológicas juegan un papel importante en la dispersión y concentración de contaminantes atmosféricos en las zonas urbanas (Ravindra et al., 2019). Por lo tanto, sigue siendo difícil demostrar que las concentraciones de este contaminante disminuyan debido a sucesos que no están directa o indirectamente relacionados con fenómenos meteorológicos, sino más bien con medidas de restricción de la movilidad en todos los países de la Tierra. La movilidad dentro y fuera de las zonas urbanas, el tráfico rodado y las emisiones contaminantes asociadas disminuyeron significativamente. Kerimray et al. (2020) señalaron que las medidas severamente restrictivas inducidas por la COVID-19 ofrecen una oportunidad sin precedentes para evaluar cómo una reducción sustancial de la movilidad resulta en cambios significativos en la calidad del aire urbano. Se puede obtener un conjunto de datos de movilidad completo y coherente utilizando big data basado en trazas digitales recopiladas de usuarios de teléfonos inteligentes (Pepe et al., 2020). En particular, varias empresas, en particular Google (2021) y Apple (2021), han publicado informes periódicos de movilidad durante la pandemia COVID-19 basados en datos de ubicación recopilados a través de sus servicios.

Si bien hay evidencia de que las medidas de contención reducen las concentraciones específicas de contaminantes atmosféricos, hasta donde sabemos, ningún estudio anterior ha investigado los cambios en el tropoNO₂ durante las restricciones por COVID a nivel latinoamericano. Además, ningún estudio ha investigado la asociación entre la reducción de la contaminación atmosférica y la movilidad, descartando cambios en las condiciones climáticas de la región. Nuestro estudio se centró en las ciudades más pobladas de América Latina. Los primeros casos confirmados de coronavirus en América Latina se reportaron en Brasil, México y Ecuador en la última semana de febrero (Johns Hopkins University, 2020). La mayoría de los países implementaron diversas medidas para contener la propagación del virus: fomentar el distanciamiento social; la prohibición de eventos públicos; cierre de escuelas; universidades y negocios no esenciales; el cierre de las fronteras exteriores; y reducir los viajes en tren, autobús y avión. Para la segunda y tercera semana de marzo, todos los países latinoamericanos habían implementado medidas restrictivas para detener la propagación del coronavirus, como el cierre de escuelas y universidades, la cancelación de eventos públicos y la recomendación de trabajar desde casa (González-Bustamante, 2021). Debido a la rápida propagación del virus, se implementaron nuevas medidas restrictivas durante las mismas semanas. Entre estas medidas se encuentran el cierre de bares, pubs, restaurantes, playas, centros comerciales y negocios (excepto alimentos y medicinas) y la limitación del transporte público dentro de las ciudades. A finales de marzo, la mayoría de los países latinoamericanos habían implementado duras medidas restrictivas, como toques de queda y cuarentenas totales (González-Bustamante, 2021).

Una pregunta interesante es cómo los contaminantes atmosféricos, como el NO₂, responden a las medidas de confinamiento impuestas por las principales ciudades latinoamericanas. En este estudio se compara el NO₂ troposférico registrado por las imágenes de Sentinel-5P para los meses comprendidos entre marzo y junio de 2019 y 2020. Se examinó la relación entre la reducción de la movilidad poblacional y la disminución de las concentraciones de NO₂ en 17 ciudades latinoamericanas afectadas por la pandemia COVID-19. Además, incluimos un conjunto de datos más completo de tropoNO₂ satelital disponibles de 2011 a 2020 (del satélite de la misión OMI; Lamsal et al., 2021). Su variabilidad se comparó con las variables meteorológicas derivadas de los datos de reanálisis atmosférico durante el mismo período. Esto puede demostrar si el bajo NO₂ observado durante los períodos de restricción se relacionaron con la variabilidad climática regional. Para desentrañar las posibles variaciones conjuntas o disjuntas de estas variables, aplicamos un novedoso procedimiento de reconocimiento de patrones basado en NMF (Non-negative matrix Factorization; una definición formal se encuentra en Lee and Seung, 1999). Este método permite un examen en profundidad de las características comunes del NO₂ los cambios, la movilidad local y la variabilidad meteorológica regional en las ciudades latinoamericanas estudiadas en 2019 y 2020. Este escenario puede ayudarnos a entender la disminución de

las concentraciones de NO₂ como un fenómeno que ocurrió de manera similar y simultánea en varias ciudades importantes de América Latina como respuesta a las medidas de confinamiento impuestas.

2.2. Datos y metodología

2.2.1. Área y período de estudio

Se seleccionaron diecisiete centros urbanos importantes de países latinoamericanos con una gran población y numerosas actividades económicas. El periodo analizado fue marzo-junio de 2020, cuando los gobiernos promulgaron sus principales medidas restrictivas, en comparación con el año anterior marzo-junio de 2019. Estas medidas, segmentadas en tres niveles (verde, amarillo y rojo) según el número y la severidad de las restricciones impuestas a la población, se describen en la Tabla 2.1. Mientras que las fechas en las que se implementaron estas restricciones se presentan en la Fig. 2.1 y la Tabla S1. La comparación se realizó con datos de 2019, y no de inmediatamente antes del confinamiento (enero o febrero de 2020). Así, un período en el mismo intervalo de tiempo que ocurrió durante años anteriores ofrece la ventaja de referirse a condiciones climáticas similares (Jakob et al., 2022; Goldberg et al., 2020). Además, en ciudades ubicadas en latitudes medias y bajas donde las fluctuaciones estacionales de las variables meteorológicas son notables (Garreaud et al., 2009), por lo que las condiciones meteorológicas podrían ser muy diferentes en los meses o semanas previas a la pandemia.

Tabla 2.1. Las escalas de restricción de las actividades y la movilidad de los ciudadanos se basan en las políticas adoptadas por los gobiernos nacionales y subnacionales.

Color	Descripción	Medidas específicas
Verde	Restricciones nulas o muy focalizadas	Aislamiento de personas enfermas o sintomáticas
	Las pólizas se centraron en los viajes de larga distancia o en las personas identificadas como infectadas por el COVID. Restricciones iniciales a la población en general.	Autocuarentena de los viajeros que llegan de los países afectados
Amarillo	Restricciones a la rutina diaria de los ciudadanos o sectores de la población: cuarentenas parciales.	Prohibición de reuniones masivas
		Cierre de determinadas fronteras nacionales y restricciones a los viajes internacionales
	Fases de reapertura	Cierre de todas las fronteras nacionales
		Cierre obligatorio de escuelas, universidades, edificios públicos, religiosos o culturales
		Cierre de restaurantes, bares y otros negocios dentro de la ciudad
		Toque de queda nocturno obligatorio
		Apertura de cines, restaurantes, cafeterías o lugares similares al <75% de su capacidad
		Apertura de pubs, discotecas, gimnasios o lugares similares al <50% de su capacidad
		Se permiten reuniones y eventos con un número restringido de personas

Color	Descripción	Medidas específicas
Rojo	Políticas que restringen sustancialmente la rutina diaria de la población: cuarentena total	Cuarentena obligatoria que requiere el confinamiento domiciliario obligatorio de una parte importante de la población

Nota: Las políticas promulgadas por los gobiernos nacionales y subnacionales en las que se basó la escala de restricción se derivaron de las cuentas oficiales de las secretarías de salud y los ministerios de salud de los respectivos países y ciudades: Secretaría de Salud del Estado de Río Janeiro (Gobierno de R. Janeiro @SaudeGovRJ, s.f.); Secretaría de Estado de Salud de São Paulo (Gobierno de S. Paulo @Governosp, s.f.); Secretaría de Estado de Salud de Bahía (Saúde Bahia @saudegovba, s.f.); Secretaría de Salud del Distrito Federal (Secretaría de Saúde do DF @secsaudedf, s.f.); Secretaría de Salud de México (Secretaría de Salud de México @SSalud_mx, s.f.); Secretaría de Salud del Perú (Ministerio de Salud @Minsa_Peru, s.f.); Secretaría de Salud de Colombia (MinSaludCol @MinSaludCol, s.f.); Secretaría de Salud de Chile (Ministerio de Salud @ministeriosalud, s.f.); Secretaría de Salud del Estado de Buenos Aires (BA Salud @BASalud, s.f.); Secretaría de Desarrollo de la Salud de Córdoba (Córdoba, s.f.); Ministerio de Salud Pública de Ecuador @Salud_Ec, s.f.); Ministerio de Salud y Deportes de Bolivia @SaludDeportesBo, s.f.); Ministerio del Poder Popular para la SaludMPPS @MinSaludVE, s.f.); Ministerio de Salud de la República Oriental del Uruguay (MSP - Uruguay @MSPUruguay, s.f.).

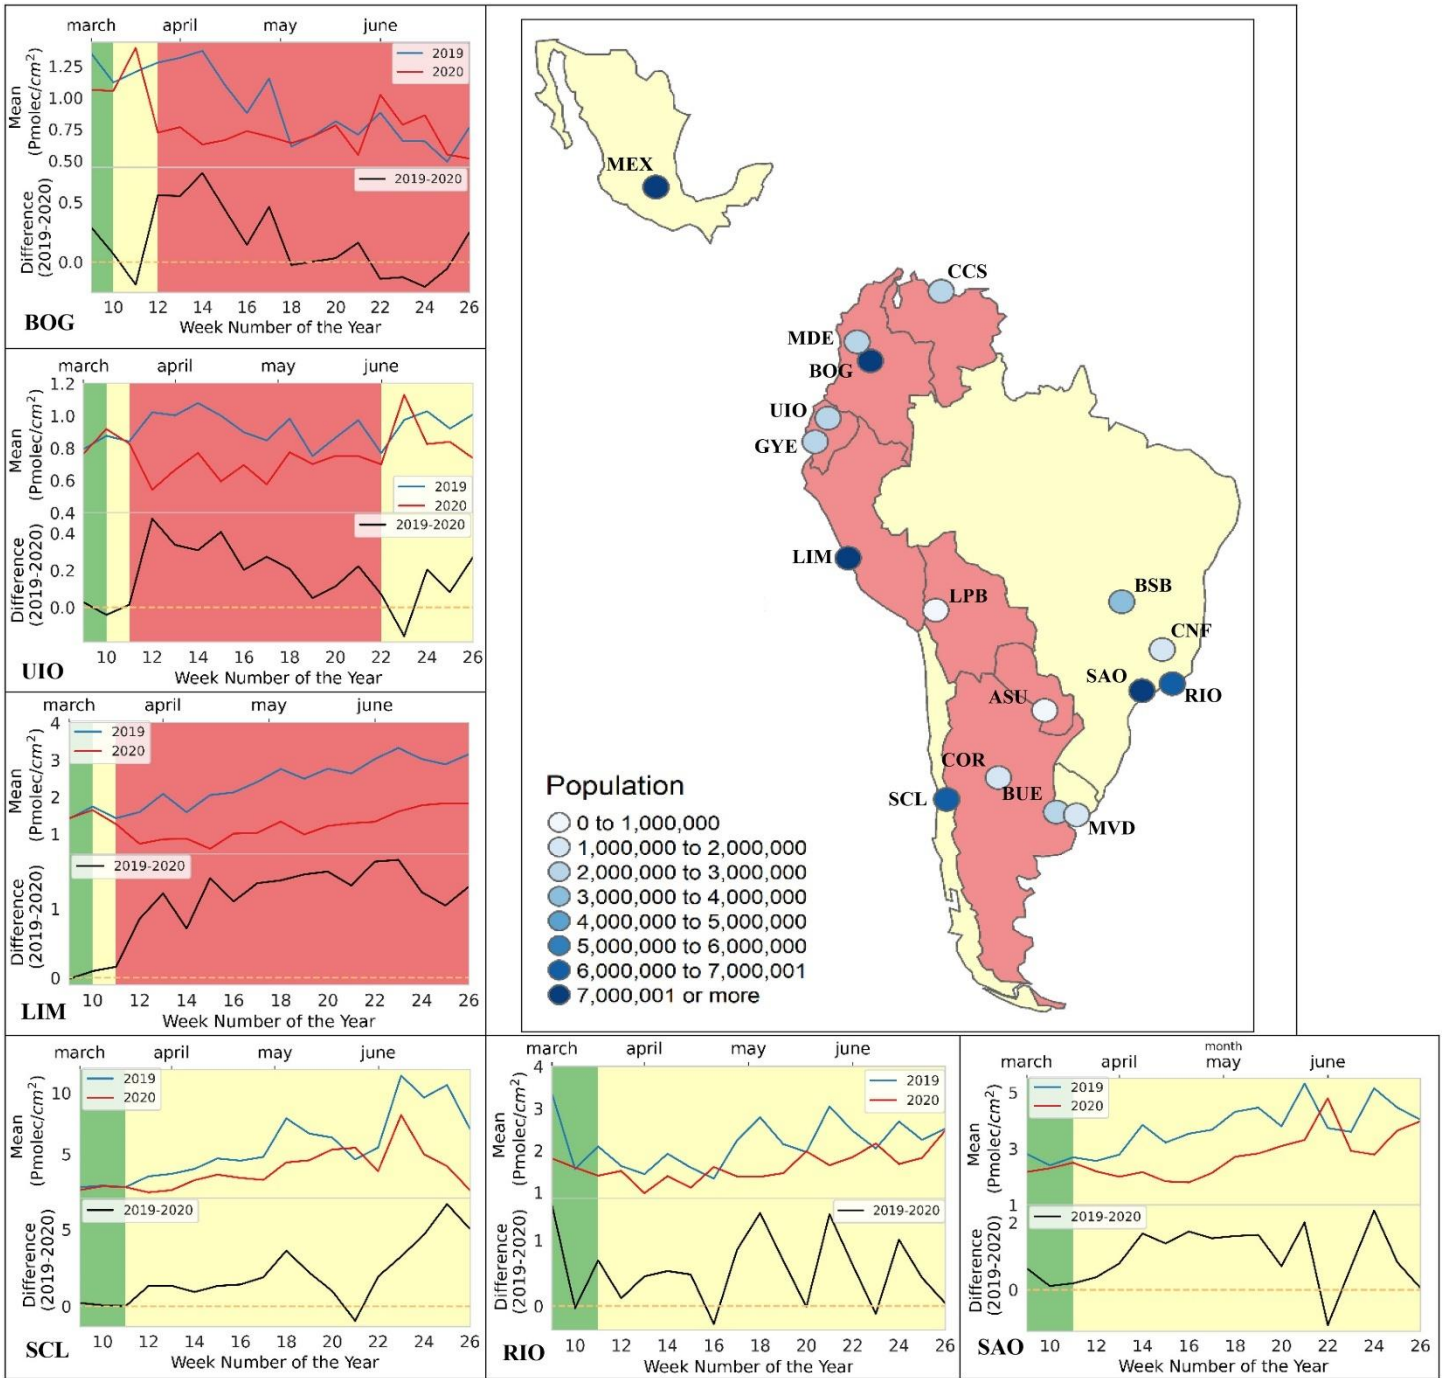


Figura 2.1. Área de estudio. Los círculos de colores corresponden al número de habitantes. Las series temporales de medias y diferencias semanales de tropoNO₂ se muestran para los valores entre los años 2019 y 2020 para las seis ciudades que presentaron las diferencias más significativas. La serie va desde la semana 9, correspondiente a la primera semana de marzo, hasta la semana 26, correspondiente a la última semana de junio. El color de fondo muestra el nivel de confinamiento. Los datos poblacionales: (IBGE, 2020), (INEGI, 2020), (INEI, 2020), (DANE, 2018), (INE, 2017), (INDEC, 2020), (INEC, 2020), (INE, 2012), (INE, 2011a) y (INE, 2011b).

2.2.2. Recopilación de datos

2.2.2.1. Datos del satélite Sentinel-5P (TROPOMI)

Las concentraciones de tropoNO₂ antes y durante los escenarios de cierre del COVID-19 se derivaron utilizando datos del satélite precursor Sentinel-5 (Sentinel-5P) de la Agencia Espacial Europea (ESA), al que se puede acceder a través del Instrumento de Vigilancia Troposférica (TROPOMI) (Sentinel-5P TROPOMI User Guide-Sentinel Online-Sentinel, s.f.).

TROPOMI es un espectrómetro pasivo de imágenes de retrodispersión solar que permite la adquisición de imágenes de 8 bandas, que abarcan desde los dominios espectrales UV y visible hasta el infrarrojo cercano (NIR) y el infrarrojo de onda corta (SWIR) (Lorente et al., 2019). Este instrumento tiene una resolución espacial de 7 × 3,5 km² (a lo largo y a través de la vía) (Vîrghileanu et al., 2020). Sentinel 5P proporciona datos oportunos para muchos gases traza (O₃, SO₂, NO₂, CO y CH₄).

Se utilizaron datos Sentinel-5P con nivel de procesamiento L2 (Sentinel-5P L2-NO₂) y correspondían a productos fuera de línea (OFF-line) disponibles cinco días después de la detección (Vîrghileanu et al., 2020). Se utilizaron todos los días disponibles de Sentinel-5P L2-NO₂ OFF-line para los meses analizados para 2019 y 2020 para las ciudades estudiadas. Se descargaron desde el Centro de Acceso Abierto de Copernicus a través de la API de Python. Los productos Sentinel-5P L2-NO₂ se obtuvieron en el formato netCDF. Estos datos se denominarán en lo sucesivo TROPOMI. La nubosidad, el albedo de la superficie, la nieve, el hielo, la saturación, la geometría y otras variables influyen en la calidad de las observaciones individuales. La capa suministrada en Sentinel-5P describe muchos factores que afectan a la calidad de las mediciones. El "valor de garantía de calidad" ('qa_value') es una estadística agregada que se puede utilizar para filtrar píxeles de baja calidad. Esta variable continua, 'qa_value', oscila entre 0 (sin fecha) y 1 (todas están bien) (Eskes and Knmi, 2020). Las densas mediciones obtenidas cada 24 h permitieron el cálculo de robustos promedios de escala de tiempo semanales y mensuales para examinar el tropoNO₂ variabilidad temporal (Otmani et al., 2020).

2.2.2.2. Datos del satélite Aura (OMI)

El instrumento de vigilancia del ozono estaba a bordo del satélite Aura (OMI, Levelt et al., 2006). OMI es un espectrómetro UV-VIS que mide los valores de columna NO₂ troposférico. El manual de usuario en línea de la NASA para productos OMI (Giovanni, 2014) contiene detalles de filtrado de datos y una definición del análisis y los algoritmos del enfoque de espectroscopia de absorción óptica diferencial (DOAS), y procedimientos de control de calidad de datos para filtrar y etiquetar datos. Se utilizaron los promedios mensuales del NO₂ troposférico L3 diario OMI (OMNO2d) (Lamsal et al., 2021). Los datos de OMNO2d estaban en el nivel L3, con una resolución espacial de 0,25° × 0,25° en una cuadrícula global. Además, considera solo píxeles con una fracción de nube del <30%. La descarga se realizó utilizando la plataforma Giovanni (<https://giovanni.gsfc.nasa.gov/>). Se recuperaron datos de 2011 a 2020 para investigar series de tiempo de NO₂ que describen cada ciudad estudiada a lo largo de un período extendido en el tiempo. Estos datos históricos se denominan OMI.

2.2.2.3. Conjunto de datos meteorológicos ERA5

ERA5 es la quinta generación de datos de reanálisis atmosférico sobre el clima global del Centro Europeo de Previsiones Meteorológicas a Medio Plazo (ECMWF) (Servicio de Cambio Climático de Copernicus (C3S), s.f.). El nuevo análisis combina datos modelados con observaciones asimiladas de muchas fuentes en todo el mundo en un conjunto de datos global completo y consistente. La resolución espacial fue de 0,25° × 0,25°, y la resolución temporal comenzó a partir de los datos horarios. Los promedios diarios, mensuales y anuales están disponibles a través de los servicios de ECMWF.

Nuestro análisis empleó datos de ERA5 (Copernicus Climate Change Service (C3S), s.f.) para temperaturas a dos metros de la superficie, precipitación y velocidad y dirección del viento a diez metros. Se utilizaron datos meteorológicos horarios recogidos entre las 17 y las 20 UTC, correspondientes al paso de tiempo de la misión satelital TROPOMI que sobrevoló las ciudades investigadas. Las descargas se realizaron utilizando el paquete de Python CDSAPI (Ecmwf/Cdsapi: API de Python para acceder al Copernicus Climate Data Store (CDS)).

Balmaceda-Huarte et al. (2021) investigaron la posibilidad de utilizar múltiples conjuntos de datos de reanálisis para reproducir las variabilidades geográficas y temporales de los indicadores de temperatura y precipitación en todo el sur de América del Sur. Según los investigadores, al utilizar datos de reanálisis para llevar a cabo

investigaciones climáticas regionales, es fundamental tener en cuenta las inconsistencias y diferencias con los datos observacionales al utilizar estos datos. Los autores también demostraron que los reanálisis climáticos posteriores, como ERA5, proporcionan una descripción más precisa de la variabilidad geográfica y temporal que los anteriores. Esto se debió probablemente a la resolución espacial mejorada de ERA5 y a las actualizaciones del modelo.

2.2.2.4. Datos de movilidad (MOB)

Se utilizaron los conjuntos de datos de Apple y Google (Google, 2021; Apple, 2021) analizar cómo los cambios en la movilidad se correlacionan con tropoNO₂. Estos datos reflejan los movimientos de las personas rastreadas por las aplicaciones de mapeo en un dispositivo Apple o Android. Sin embargo, estas dos medidas eran diferentes. En el caso de los datos de Apple, la medida de movilidad informa de tres subconjuntos de datos de tipo de movimiento: "conducir", "transporte público" y "caminar". Mientras tanto, la recopilación de datos de Google incluye seis subconjuntos de datos que están más estrechamente relacionados con el tipo de ubicación: "supermercado y farmacia", "parques", "residencial", "comercio minorista y recreación", "estaciones de tránsito" y "lugares de trabajo". Todas las medidas estiman la movilidad diaria relativa de cada país y se cuantifican en relación con la movilidad máxima medida antes de la declaración de la pandemia por parte de la OMS. Los datos de movilidad de Apple y Google estaban disponibles a partir del 13 de enero y el 15 de febrero de 2020 (Cot et al., 2021). Los datos de movilidad se descargaron de informes publicados por Apple y Google en <https://www.apple.com/covid19/mobility> y <https://www.google.com/covid19/mobility>, respectivamente.

Seleccionamos los parámetros de movilidad con el potencial más significativo para afectar la calidad del aire de ambos conjuntos de datos, como se describe en Cot et al. (2021) y Li y Tartarini (2020). Se seleccionaron los datos del conjunto de datos de Google "lugares de trabajo", "residencial" y "estación de tránsito", y los datos del conjunto de datos de Apple "conducción" y "tránsito".

Vale la pena señalar que la información recopilada por los informes de movilidad de la comunidad de Google y Apple proviene de usuarios que han activado la función de historial de ubicaciones en sus dispositivos móviles (Nouvellet et al., 2021). Como resultado, los datos evaluados en este trabajo están, por definición, limitados a un subconjunto específico de cuentas de Google o Apple. Por supuesto, aunque nos hubiera ventajoso tener mucha más información para afinar las estadísticas, como la categoría de personas y la ocupación, entendemos que este tipo de información es privada.

2.2.3. Análisis estadístico

Se empleó el marco metodológico presentado en la Tabla S1. El procedimiento se dividió en cuatro etapas, cada una definida de acuerdo con los datos de entrada requeridos (véanse las columnas 1 a 4 de la Tabla S1).

1^{era} etapa. El enfoque en esta etapa tuvo como objetivo realizar estadística descriptiva y comparar las lecturas de NO₂ de TROPOMI del año en que comenzó la pandemia (2020) con las del mismo período del año anterior (2019). Usamos datos diarios de Sentinel-5P L2-NO₂ OFF-line (véase la sección 2.2.1) de marzo, abril, mayo y junio.

El NO₂ TROPOMI se derivó del L2-NO₂ productos mediante la conversión de los datos procesados de nivel 2 al nivel 3. Esto implica establecer una única cuadrícula de 1° × 1° centrada en cada ciudad, denominada "región de interés" (ROI). En segundo lugar, se filtraron los datos para garantizar que el valor de aseguramiento de la calidad (qa_value) fuera de >0,5, según lo especificado por Eskes and Knmi (2020). Los valores se convirtieron en unidades unitarias internacionales de moléculas/cm². Este procesamiento se implementó utilizando el paquete HARP (interfaz de Python — documentación de HARP 1.13). Los datos temporales diarios vacíos de NO₂ de cada ciudad se llenaron utilizando interpolación temporal lineal, según la definición de Wu et al. (2021). El análisis de datos de la etapa 1 se realizó utilizando este método de recolección de datos.

- Se generaron series de tiempo promedio semanales de TROPOMI (en el área de estudio en cada ciudad) utilizando valores diarios. Las series temporales semanales se presentan en la Fig. 1 y la Fig. S1 para evaluar la contribución de las medidas de confinamiento a la disminución de NO₂ concentraciones entre 2019 y 2020. Se calcularon medias y desviaciones estándar. La diferencia (2020-2019) y el cambio porcentual se informan mensualmente. La significación estadística de las diferencias se determinó mediante la prueba de rangos con signo de Wilcoxon. El nivel de significancia se definió de acuerdo con el intervalo en el que se produjo el valor

de significancia (p): significación baja ($0,01 \leq p < 0,05$), media ($0,001 \leq p < 0,01$) y alta ($p < 0,001$) (ver Fig. 2, Fig. 4). Esto corresponde a la Etapa 1 D2 de la Tabla S1.

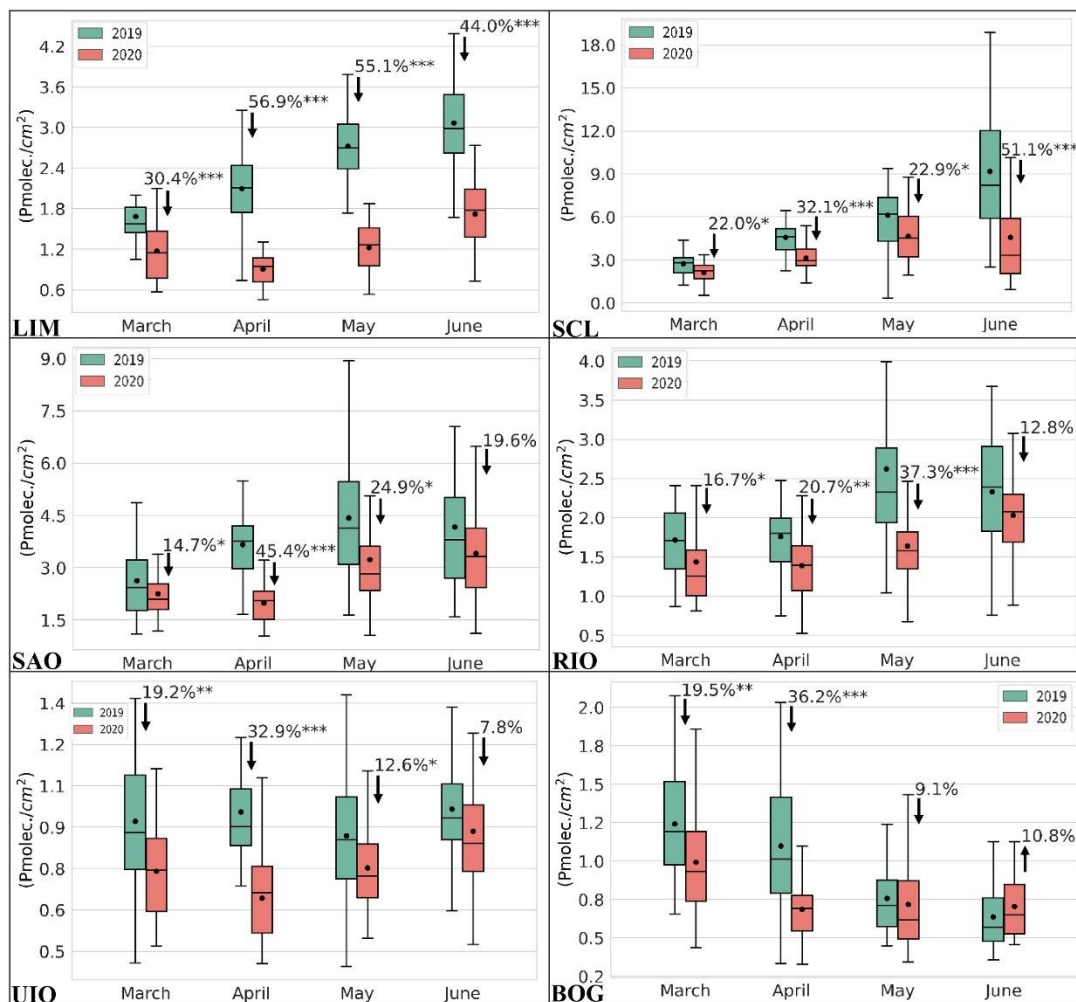


Figura 2.2. Diagrama de caja mensual para NO₂ troposférico Distribuciones para los años 2019 y 2020. El diagrama de caja de 2019 se muestra en verde y el de 2020 en rojo, con el valor medio marcado con un punto negro en el diagrama de caja. Los valores porcentuales por encima de cada diagrama de caja denotan la variación porcentual de NO₂ valores entre los dos años. Allí, *, ** y *** denotan el nivel de significación estadística de la diferencia, correspondiente a significaciones bajas ($0,01 \leq p < 0,05$), medias ($0,001 \leq p < 0,01$) y altas ($p < 0,001$). Las flechas negras denotan un aumento (dirección hacia arriba) o una disminución (dirección hacia abajo) en NO₂ (2020 menos 2019). (Para la interpretación de las referencias al color en esta leyenda de la figura, se remite al lector a la versión web de este artículo).

- En esta etapa, la distribución espacial de las medias mensuales para las ciudades con el NO₂ más significativo (ver Fig. 2.3). Las otras ciudades se muestran en la Fig. S4. Esto corresponde a la etapa 1 D3 de la Tabla S1.

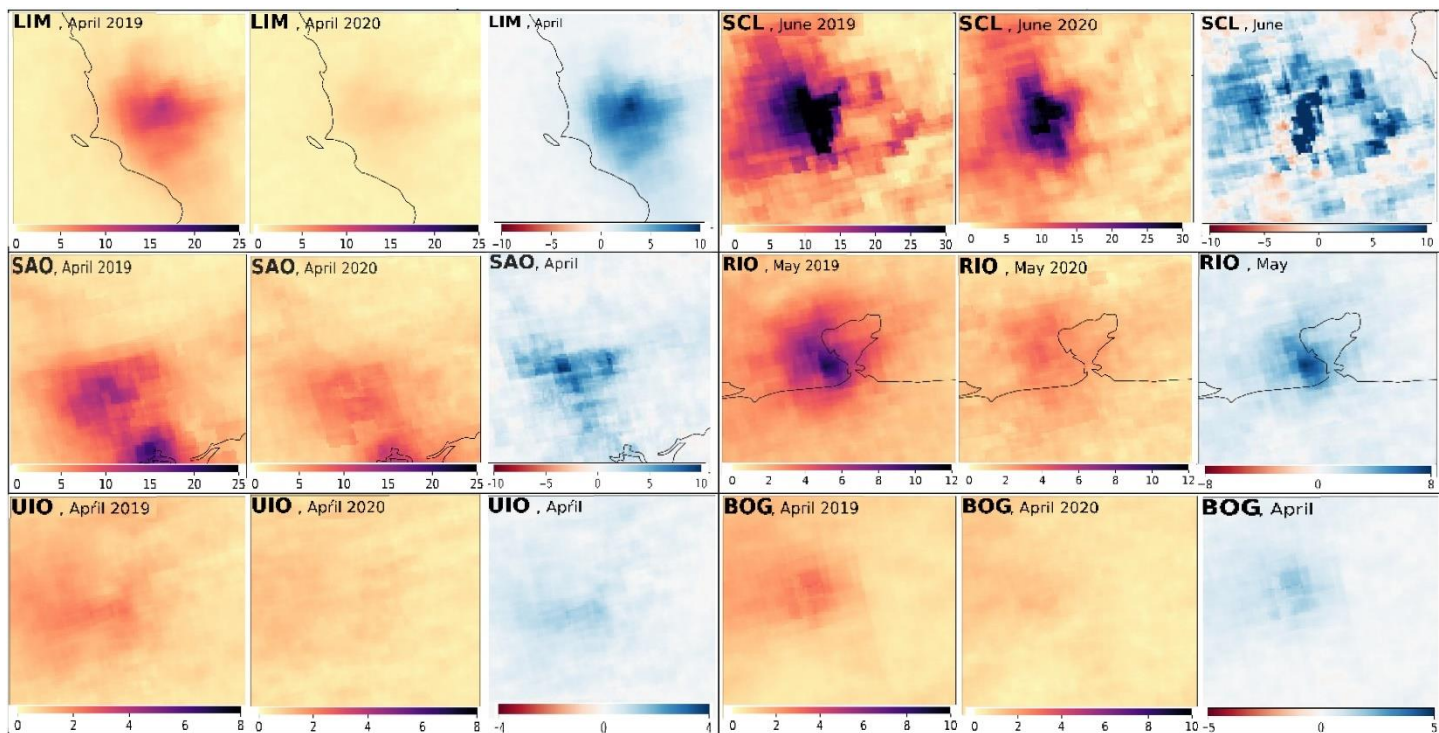


Figura 2.3. Mapas de medias mensuales (2019 y 2020) y la diferencia entre tropoNO₂ valores de ROIs de las seis ciudades que presentaron las diferencias más significativas para el período analizado (LIM, SCL, SAO, RIO, UIO, BOG). Los mapas corresponden al mes que mostró la diferencia más significativa en cada caso (abril – LIM, SAO, UIO y BOG; Mayo – RÍO; Junio – SCL). El valor mensual promedio para 2019 (izquierda), el valor mensual promedio para 2020 (centro) y la diferencia entre 2019 y 2020 (derecha) se indican en cada subdivisión. Los valores representados se expresan en unidades de Moléculas/cm². Nota: LIM: Lima; SCL: Santiago; SAO: São Pablo; RÍO: Río de Janeiro; UIO: Quito; BOG: Bogotá.

2^{da} etapa. El propósito fue determinar si varias ciudades registraron un bajo tropoNO₂ durante un período más largo. Dada la función crítica de la meteorología en la determinación de los niveles de contaminación atmosférica (Goldberg et al., 2020), esta etapa ayudó a determinar si los eventos meteorológicos puntuales sobre las ciudades analizadas explican la disminución observada de tropoNO₂. Se realizaron los siguientes análisis:

- Se investigaron series temporales mensuales que se remontan a 2011, incluidos los promedios mensuales derivados de los datos OMI (2011-2020) y los datos de reanálisis de ERA5 (temperatura, precipitación y velocidad del viento) (2011-2020). Esto corresponde a la Etapa 2 D1 de la Tabla S1.

3^{era} etapa. En esta etapa, intentamos relacionar los valores NO₂ semanal para cada ciudad de la Etapa 1 para 2020 con la reducción de la movilidad poblacional (MOB) provocada por las medidas de confinamiento. Las ciudades de interés y las categorías de movilidad relevantes para este estudio (véase la sección 2.2.4) se seleccionaron utilizando los informes de movilidad de Google y Apple. Finalmente, se generaron series temporales semanales con las categorías de movilidad de cada ciudad.

- Se realizó un análisis de correlación para explicar la correspondencia entre NO₂ y las categorías de Google y Apple. Para asegurar la solidez de nuestros resultados, se utilizaron dos indicadores estadísticos para interpretar los resultados de correlación. El coeficiente de correlación de Pearson mide la correlación lineal entre las dos variables y es útil para identificar si las correlaciones son positivas o negativas o si no hay correlación lineal. El valor p cuantifica la significación estadística. El nivel de significancia se definió de acuerdo con el intervalo en el que se presentó el valor de significancia (p): significación baja ($0,01 \leq p < 0,05$), media ($0,001 \leq p < 0,01$) y alta ($p < 0,001$). Esto corresponde a la Etapa 3 D1 de la Tabla S1.

4^{ta} etapa. Se busco ilustrar las relaciones entre las disminuciones de NO₂ con los datos MOB y las variables meteorológicas. A diferencia de las secciones anteriores, donde el análisis se realizó por separado para cada ciudad, se pretendió realizar un estudio con el conjunto de las ciudades. Para ello, utilizamos la factorización

matricial no negativa (NMF), que es un enfoque de aprendizaje no supervisado que se ha aplicado con éxito en diversas disciplinas. Pocos estudios en el campo de las ciencias atmosféricas han adoptado metodologías NMF para comprender la relación entre las concentraciones de contaminantes, los efectos climáticos y los aspectos sociales (Liang et al., 2020; Liang et al., 2021; Ma et al., 2021). Al igual que el análisis de componentes principales (PCA) y el análisis de componentes independientes (ICA), el objetivo del NMF es describir los datos observados utilizando un número limitado de componentes esenciales, pero con entradas restringidas a ser no negativas (Gaujoux and Seoighe, 2010). Debido a esta no negatividad, los componentes siempre se combinan positivamente, lo que da como resultado una representación completa de los datos originales (ver Brunet et al., 2004 y Wang et al., 2006 para más detalles). Este novedoso método utiliza algunos componentes o factores esenciales para explicar los datos observados. Las variables de la ciudad fueron reorganizadas y categorizadas de manera que estos factores representaran patrones de comportamiento observados en mayor o menor grado (en mayor o menor medida) en cada ciudad estudiada, asumiendo que este enfoque revelaba NO₂ patrones de reducción relacionados con los patrones MOB.

En esta sección se utiliza datos normalizados de NO₂ diario de TROPOMI, categorías de movilidad de los informes de Google y promedios diarios de variables meteorológicas por hora (17:00–20:00 UTC) de ERA5. Se creó un único conjunto de datos de movilidad promediando los flujos de datos de tránsito y lugar de trabajo de Google. Esto permitió calcular una única movilidad relativa media diaria para cada ciudad. Solo estas dos categorías se incluyeron en este estudio. Cada variable se combinó en una matriz $N \times M$ (V), donde N representa las dimensiones de tiempo (120 días) y M representa el número de ciudades consideradas (17). El MOB considera solo las ciudades con datos de movilidad de Google. En la factorización se utilizaron dos matrices: H contenía la contribución de cada factor a cada unidad analizada, y W detallaba la composición de cada factor. Un procedimiento NMF típico ejecuta el algoritmo con muchas inicializaciones aleatorias para las matrices W y H ; Se realizaron 100 iteraciones utilizando el algoritmo NMF de Brunet et al. (2004) para asegurar la solidez de los resultados. La especificación del número de factores NMF es un paso importante para permitir una mejor interpretación de los factores (Gaujoux and Seoighe, 2010). Para garantizar la solidez de nuestros resultados, se aplicaron los valores de los factores 2, 3 y 5 para describir los datos observados utilizando un número limitado de componentes esenciales. En términos de la selección arbitraria de los números de los factores, demasiados factores darían como resultado componentes que agruparían las características de muy pocas ciudades en cada factor. Se buscaron números de factores menores para agregar las características en elementos que incluyeran información amplia.

- En primer lugar, calculamos los valores de rho, o el coeficiente de correlación de rangos de Spearman, (utilizando los factores obtenidos del NMF) para medir la fuerza de los vínculos entre el NO₂ disminuyen con respecto a la variación de la movilidad y las variables de precipitación, temperatura, velocidad del viento y dirección. La mayor correlación absoluta entre las combinaciones de factores variables (movilidad, temperatura, precipitación, velocidad y dirección del viento) y tropoNO₂ se eligió la disminución para cada iteración. A continuación, se calculó la correlación media y se repitió el proceso considerando los factores 2, 3 y 5. Esto corresponde a la Etapa 4 D1 de la Tabla S1.
- Se identificaron patrones derivados de los factores con la asociación más fuerte (mayor correlación). Cada elemento describe el patrón relacionado con las características de las ciudades y se ordena según sus valores de contribución. Esto corresponde a la Etapa 4 D2, como se muestra en la Tabla S1.

3. Resultados

3.1. 1^{era} etapa: Comparación de TROPOMI NO₂ Concentraciones en cada ciudad (2019 vs. 2020)

La Fig. 2.1 muestra las diferencias en el NO₂ semanal (TROPOMI) (línea negra) para 2019-2020 (2019-2020). Las series de tiempo se codificaron por colores para corresponder a varios niveles de confinamiento, como se describe en la Tabla 1. Esto demuestra que la mayoría de las ciudades habían implementado restricciones para la tercera semana de marzo de 2020. Entre los dos años, las series temporales semanales de la diferencia en NO₂ Los valores mostraron un cambio en los patrones de comportamiento asociados a la escala de confinamiento. La escala verde indica que las diferencias en NO₂ (2019-2020) estuvieron más cerca de 0, si no negativos, durante las primeras semanas de marzo. Este comportamiento se vio drásticamente alterado con el paso de las semanas, incrementándose las medidas de confinamiento entre la tercera y cuarta semana de

marzo. Este comportamiento se observó en las series de tiempo para BOG, QUI, LIM, BUE, SAO, CNF, BSB y MEX, como se muestra en la Fig. 2.1 y la Fig. S1. Por otro lado, las diferencias en NO₂ los valores en las transiciones de la escala de verde a amarillo y rojo no están claros en ciudades como MDE, GYE, LPB, SCL y RIO (Fig. 1 y Fig. S1). Sin embargo, se observó una disminución de los niveles de contaminación en la mayoría de los periodos analizados en estas ciudades.

Sin embargo, también es visualmente evidente que las series temporales de 2019 y 2020 presentan similitudes (véanse las series temporales en la Fig. 1). Las ciudades alejadas de las latitudes ecuatoriales como LIM, LPB, SCL, COR, BUE, SAO, RIO, CNF y BSB mostraron tendencias de concentraciones de NO₂ creciente a medida que las semanas avanzaban de marzo a junio para ambos años (ver series de tiempo en la Fig. 1). Por otro lado, se observó una tendencia decreciente en las ciudades más cercanas al Ecuador (véanse las series de MDE, BOG, CCS y MEX en la Fig. 1). El comportamiento de NO₂ en las ciudades QUI, GYE, MVD y ASU fueron relativamente uniformes durante todo el período de estudio (ver serie en la Fig. 1). Los patrones identificados para las ciudades alejadas de las latitudes ecuatoriales fueron probablemente el resultado de numerosos factores. La vida útil de NO₂ fluctúa de dos a seis horas en verano (Laughner and Cohen, 2019) y de 12 a 24 horas en invierno (Shah et al., 2020) debido a la disminución de la radiación solar (Bauwens et al., 2020). Esto es especialmente pronunciado en las ciudades ubicadas en latitudes medias y altas, donde la radiación solar es significativamente más variable que en las latitudes bajas (Corrêa, 2015). Otra razón es que a medida que las temperaturas bajan en los meses de invierno en las latitudes medias y bajas, aumenta la necesidad de calefacción residencial, que es la principal razón del aumento de las emisiones (Zheng, and Wu, and Marinello., 2019; Lok Chan et al., 2020).

En términos porcentuales durante todo el período, las ciudades con mayor reducción de NO₂ fueron: LIM (47,5%), SSA (36,1%), SAO (27%), RIO (23%), UIO (18,6%), BOG (17,5%), BUE (16,6%), GYE (15,3%), MDE (14,2%), MEX (7,6%) y CNF (7,8%). Las disminuciones en NO₂ de LPB (9,5%) y BSB (5,9%) no fueron estadísticamente significativas. Algunas de estas ciudades, como SSA, SAO, BUE, MEX, LIM y RIO, tuvieron concentraciones de NO₂ más alto en 2019 (>2 Pmolecules/cm²). Ciudades como UIO, MDE, BOG, GYE y CNF, que no mostraron concentraciones de NO₂ particularmente elevado (<1.1 Pmolecules/cm²) también experimentaron reducciones. En particular, algunas ciudades experimentaron un aumento en sus concentraciones de NO₂ para 2020, un ligero aumento en COR (+3,6%), un aumento significativo en MVD (+17,3%) y un gran aumento en CCS (+21%) (ver Fig. 4). Esta información se resume en la Fig. 4 (los promedios mensuales y las variaciones porcentuales para 2019-2020 se incluyen en la Tabla S4). Las ciudades más pobladas (LIM, SCL, SAO, MEX, BOG y RIO), que tienen poblaciones superiores a los cinco millones (véase la Fig. 1), experimentaron una disminución promedio del 26,5%. Los valores de NO₂ en ciudades con poblaciones de menos de cinco millones de habitantes, excluyendo aquellas que tuvieron un aumento promedio en su NO₂ (CCS, ASU, MVD, COR), disminuyó en un promedio de 12,6% en comparación con el mismo período del año anterior.

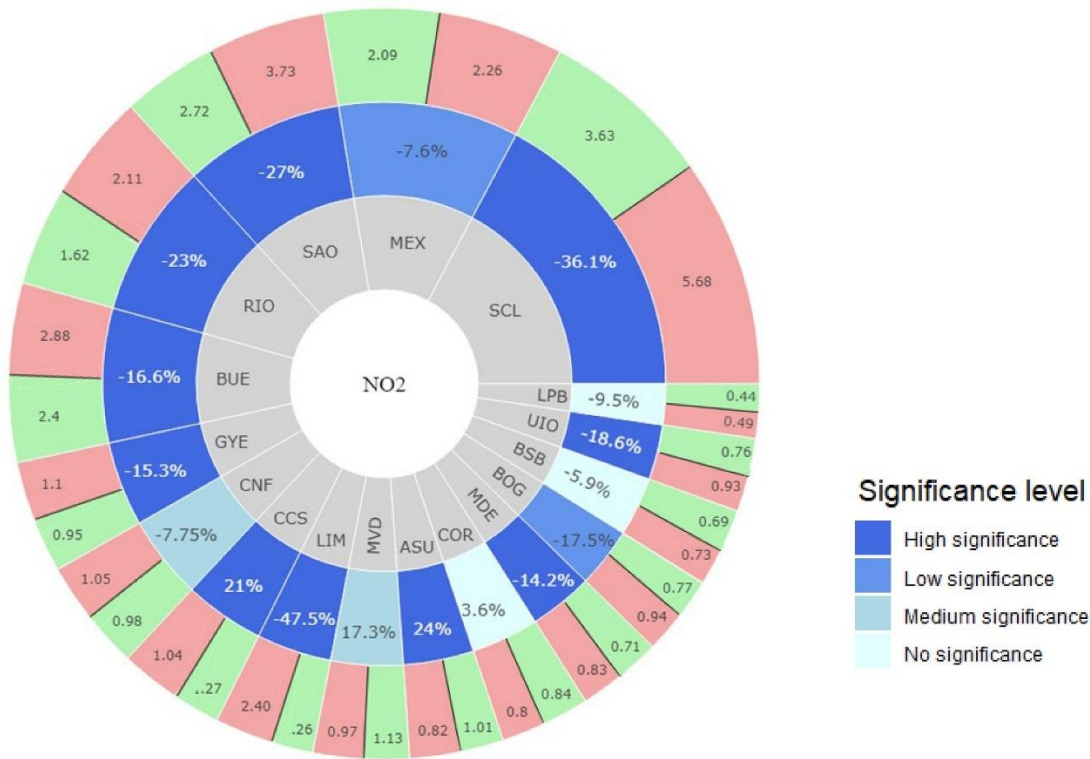


Figura 2.4. Gráfico resumen de los valores medios (círculo exterior) y las diferencias (círculo central) de tropoNO₂ para el período total comprendido entre marzo y junio. Los colores verde y rojo del círculo exterior corresponden a valores medios de 2020 y 2019, respectivamente. (Para la interpretación de las referencias al color en esta leyenda de la figura, se remite al lector a la versión web de este artículo).

El período de estudio mostró una diversidad considerable en los factores que inciden en los valores de NO₂, como diferentes medidas de restricción o características meteorológicas (Goldberg et al., 2020). En consecuencia, se realizó una comparación entre los dos años utilizando marcos temporales mensuales. Los diagramas de caja de la Fig. 2 muestran las ciudades que experimentaron los mayores cambios en el NO₂ mensual (todas las ciudades se muestran en la Fig. S3). Las diferencias mensuales más significativas ocurrieron entre marzo y junio, dependiendo de la ciudad: marzo, MDE y GYE (22,9% y 25%, respectivamente); abril, LIM (56,9%), SAO (45,5%), BUE (40,6%), BOG (36,2%), UIO (32,9%) y BSB (16%); May, LPB (18,9%), MEX (16%) y CNF (16,2%); y junio, SSA (51,1%). Además, para la mayoría de los meses de 2020, la tendencia central y las estadísticas de varianza general son más bajas. La Fig. 3 muestra la distribución espacial de las variaciones de NO₂ para las seis ciudades con los mayores cambios (todas las ciudades se muestran en la Fig. S4). En consecuencia, los niveles de contaminación disminuyeron, al igual que su variabilidad espacial entre las ciudades y las áreas circundantes. Para estas seis ciudades, las caídas medias de 2,05, 1,19, 1,66, 0,98, 0,32 y 0,39 (moléculas/cm²) se observaron en el mes con la disminución más significativa para SCL, LIM, SAO, RIO, UIO y BOG, respectivamente. Para SCL, LIM, SAO, RIO, UIO y BOG, las desviaciones estándar disminuyeron en 1,36, 0,26, 0,55, 0,66, 0,02 y 0,21, respectivamente (Tabla S4).

2.3.2. 2^{da} etapa: TropoNO₂ revisión histórica, TROPOMI respaldado por datos de OMI y meteorología ERA5

Los datos mensuales de OMI (2011-2020) (véase la Fig. S2) no revelaron una asociación general clara entre los descensos de las concentraciones de TropoNO₂ en 2020 y las condiciones climáticas. Así, en la mayoría de las ciudades durante la última década, el NO₂ mensual más bajo ocurrieron en 2020. Sin embargo, esto no equivalía a variaciones similares en la temperatura, la precipitación, la velocidad y la dirección del viento. Las pequeñas disparidades entre el tropoNO₂ mensual de OMI y TROPOMI a lo largo de los tiempos superpuestos fueron consistentes con los de estudios previos que compararon los dos satélites (Bauwens et al., 2020; Huang

and Sun, 2020) y se esperaban dados los diferentes tiempos de sobrepaso locales y las resoluciones de ambos sensores.

2.3.3. 3^{era} etapa: Relación entre las concentraciones de NO₂ y categorías de movilidad de Google y Apple

Este enfoque evaluó la correlación entre la disminución del NO₂ y datos de movilidad de Google y Apple (Tabla 2). En la Tabla 2.2 se muestra una correlación significativa entre las concentraciones de NO₂ y una o más categorías de informes de movilidad en las ciudades. Este fue el caso del lugar de trabajo, las estaciones de tránsito, el área residencial, la conducción y el transporte público. A modo de ilustración, entre otras ciudades, MEX, BUE, RIO y CNF mostraron correlaciones significativas en todas las categorías que reportaron datos: lugar de trabajo (0.53, 0.55, 0.52 y 0.71, respectivamente), estaciones de tránsito (0.47, 0.49, 0.51 y 0.76, respectivamente), área residencial (-0.48, -0.54, -0.51 y -0.79, respectivamente), conducción (0.49, 0.68, 0.68 y 0.73, respectivamente), tránsito (0.48 para MEX y RIO). Las ciudades de UIO, GYE, BOG y LIM mostraron lo siguiente: lugar de trabajo (0,76, 0,54, 0,46 y 0,72, respectivamente), estaciones de tránsito (0,75, 0,51, 0,44 y 0,74, respectivamente), área residencial (-0,75, -0,48, -0,44 y -0,8, respectivamente). SAO tuvo un valor en el lugar de trabajo de 0,31 y la conducción de 0,38, mientras que COR tuvo un valor en el lugar de trabajo ligeramente significativo (0,52) y el MVD solo mostró un valor de conducción significativo (0,82).

Tabla 2.2. Valores de correlación entre tropoNO₂ y datos de movilidad de Google y Apple.

Correlación de rangos de Spearman (rho)						
	Ciudad	Lugar de trabajo	Estaciones de tránsito	Residencial	Conducción	Tránsito
Promedio semanal para NO ₂	Lima	0.72***	0.74***	-0,8**	N.C.	N.C.
	Santiago	-0,22	-0,01	0.02	-0,21	N.C.
	São Pablo	0.31*	0.26	-0,29	0.38*	0.24
	México	0.53*	0.47*	-0,48*	0.49*	0.48*
	Bogotá	0.46*	0.44*	-0,44	0.24	N.C.
	Quito	0.76***	0.75***	-0,75***	N.C.	N.C.
	Buenos Aires	0.55*	0.49*	-0,54*	0.68*	N.C.
	Caracas	N.C.	N.C.	N.C.	N.C.	N.C.
	Asunción	-0,1	0,02	0.1	N.C.	N.C.
	Montevideo	N.C.	N.C.	N.C.	0.82**	N.C.
	Río de Janeiro	0.52*	0.51*	-0,51*	0.68**	0.48*
	Brasilia	0,3	0.34	-0,29	0.48*	N.C.
	Belo Horizonte	0.71**	0.76***	-0,79***	0.73**	N.C.
	Medellín	0.33	0.35	-0,27	0,23	N.C.
	Guayaquil	0.54*	0.51*	-0,48*	N.C.	N.C.
	Córdoba	0.52*	0.44*	-0,46*	N.C.	N.C.
	La Paz	0.41*	0.4*	-0,41	N.C.	N.C.

Nota: el valor p denota el nivel de significación de la correlación. * Significaciones bajas ($0,01 \leq p < 0,05$), ** medias ($0,001 \leq p < 0,01$) y *** altas ($p < 0,001$), respectivamente. N.C.: No aplicable.

2.3.4. 4^{ta} etapa: Factorización de matrices no negativas (NMF)

Correlaciones entre diferentes factores (MOB, temperatura, precipitación, velocidad y dirección del viento) y la variabilidad de NO₂ fue calculada. Usando el promedio de las correlaciones más significativas para las 100 iteraciones, los valores rho entre los factores de disminución de NO₂ y movilidad fueron 0,37, 0,49 y 0,41 para el NMF aplicado con los factores 2, 3 y 5, respectivamente. La aplicación de NMF con el mayor valor de rho fue el factor 3 NMF (0,49). Como resultado, se demostró el papel más significativo de la reducción de la movilidad en la definición de la disminución de la contaminación en las principales ciudades de América Latina. Por el contrario, los cambios en las concentraciones de NO₂ no mostró una correlación significativa con las variables meteorológicas (precipitación, temperatura, velocidad y dirección del viento). Si bien la temperatura tuvo la mayor correlación, lo hizo con valores de rho de solo 0,18, 0,34 y 0,36 para los factores 2, 3 y 5, respectivamente. La velocidad del viento tuvo valores rho de 0,16, 0,30 y 0,35, y la dirección del viento tuvo valores de 0,09, 0,25 y 0,35 para los factores 2, 3 y 5, respectivamente. La precipitación, en particular, fue la menos correlacionada en todos los casos, con valores de rho de 0,07, 0,13 y 0,24 para los factores 2, 3 y 5, respectivamente (para más detalles, ver Fig. S6).

Los factores de correlación más altos incluyeron los patrones de comportamiento de movilidad y las diferencias en los niveles de NO₂ observados en la mayoría de las ciudades durante el período de estudio. Para el factor movilidad, se presentaron valores altos durante los primeros 20 d, los cuales luego descendieron abruptamente, continuando a concentraciones más bajas hasta aproximadamente el día 80, cuando comenzó una tendencia ascendente más pronunciada. Los factores de las diferencias de NO₂ mostraron un patrón de valores bajos durante las primeras dos y tres semanas de marzo. En el día 80, el crecimiento se desaceleró y el patrón se invirtió. LIM, LPB, SCL, SAO, MEX, BUE, BSB y CNF mostraron tendencias similares. Fig. S7 ilustra este comportamiento.

2.4. Discusión

Nuestro estudio proporciona evidencia de la significancia estadística de la reducción de la contaminación atmosférica en 2020, y es consistente con los estudios satelitales sobre la calidad del aire local (Bolaño-Ortiz et al., 2020; Méndez-Espinosa et al., 2020; Pacheco et al., 2020; Zalakeviciute et al., 2020; Zambrano-Monserrate and Ruano, 2020). En la mayoría de las ciudades de América Latina, hubo una diferencia sustancial en las concentraciones de NO₂ entre 2019 y 2020 (ver series temporales de NO₂ en la Fig. 1 y la Fig. S1), que crecieron con la introducción de medidas de confinamiento en la segunda parte de marzo. La dependencia de los sensores satelitales para determinar las concentraciones de NO₂ tiene ciertas incertidumbres. En las zonas urbanas, el algoritmo TROPOMI NO₂ subestimó las concentraciones de NO₂ en la columna vertical troposférica. Esto se debe a que los perfiles de forma del factor de masa de aire generador (AMF) se basan en un modelo global. No obstante, los resultados aquí presentados son consistentes con los obtenidos de investigaciones realizadas con monitores terrestres en regiones de América Latina (Bolaño-Ortiz et al., 2020; Dantas et al., 2020; Krecl et al., 2020). Sin embargo, nuestro estudio no incluyó datos in situ terrestres en su análisis. Esto se debe a que inicialmente nos concentramos en una metodología a escala de ciudad que abarcaba todo el perímetro urbano de las ciudades investigadas. Además, no existe una estandarización latinoamericana para capturar y validar los datos de calidad del aire registrados por los sistemas de calidad del aire y, por lo tanto, existen variaciones en los datos en función de las normas y regulaciones de cada país. Además, existen restricciones en el acceso a las bases de datos para algunas ciudades de la región. No obstante, se podría compilar una base de datos validados in situ basados en el terreno para futuras investigaciones que adopten un enfoque más localizado de la planificación urbana.

Considerando la importancia del papel de las variables climatológicas en la dispersión y concentración de contaminantes en la atmósfera, las mediciones de tropoNO₂ (del satélite OMI) y los datos meteorológicos (del ERA5) mostraron que su influencia no explicaba la drástica disminución de la contaminación. Los enfoques NMF, adoptados por Thiem et al. (2012) y Malley et al. (2014), verificaron hallazgos similares. El NMF se correlaciona las disparidades de NO₂ entre ciudades latinoamericanas con factores de movilidad en lugar de variables climáticas. Esto confirma un fenómeno que reduce el NO₂ en las ciudades latinoamericanas sin depender del clima. Esto es consistente con investigaciones previas sobre la influencia de las variables meteorológicas en el satélite Sentinel-5P NO₂ durante el periodo de confinamiento (Bauwens et al., 2020; Goldberg et al., 2020) y datos de monitoreo in situ (Wang et al., 2020). Estudios anteriores han demostrado que el control de la población mejora la calidad del aire de una ciudad, como los realizados por Potts et al. (2021)

para ciudades del Reino Unido o Vadrevu et al. (2020) para 41 ciudades de la India. Sin embargo, es necesario descartar la existencia de patrones en las variables meteorológicas asociados a una disminución del NO₂. En este estudio se utilizaron los datos meteorológicos de la ERA5. Aunque este último es el producto atmosférico más actualizado y pulido disponible en la actualidad, es posible que no capture con precisión la variabilidad climática real (Cucchi et al., 2020), lo que agrega incertidumbre al análisis sobre el papel de la meteorología en la drástica disminución obtenida para el NO₂. Se necesitan modelos de resolución mucho más alta para describir mejor el papel de la meteorología en los niveles de contaminación en entornos urbanos más allá del alcance de este esfuerzo.

A medida que aumentan las concentraciones de NO₂ para el año 2020, las variables meteorológicas pueden haber influido en el aumento de las concentraciones en ciudades como CCS, MVD y COR. La cuarentena parcial y las lluvias por debajo del promedio de marzo a mayo en el MVD habrían aumentado la probabilidad de concentraciones de NO₂ altas. A su vez, las situaciones de CAC y CDR fueron similares. En CCS, se registraron precipitaciones limitadas de marzo a junio de 2020. Sin embargo, las temperaturas de abril y mayo han sido las más altas desde 2011 (ver Fig. S2 y Fig. S5). Estas ciudades eran más pequeñas que la mayoría de las que tenían una caída de tropoNO₂ Niveles. En contraste, LIM, SCL, SAO, MEX, BOG y RIO exhibieron una mejor reducción promedio en NO₂ que las ciudades menos pobladas, a pesar de que cuatro de estas seis ciudades solo tenían cuarentenas limitadas. Así, la reducción de la contaminación fue mayor en los lugares con más residentes y menos restricciones.

El sistema Koppen-Geiger clasifica el clima de cada ciudad (Kottek et al., 2006). Sin embargo, el cambio climático ha generado importantes incertidumbres en torno a esta categorización (Beck et al., 2018). A pesar de pertenecer a la misma zona climática (Aw), la dispersión geográfica de CCS, RIO y BSB hace que sea poco probable que estas ciudades experimenten cambios climáticos interanuales similares. De hecho, cada ciudad tiene un microclima único, que se ve afectado por el cambio climático (Masson et al., 2020) y afectará la calidad del aire local (Henríquez y Romero, 2019; Kumar, 2021). Patrones macroclimáticos como la Oscilación del Sur de El Niño, la oscilación decenal del Pacífico, la oscilación del Atlántico Norte, la oscilación climática multidecadal del Atlántico y el papel de varios anticiclones del Pacífico y del Atlántico también afectan el clima de América del Sur, que se ve aún más afectado por el cambio climático (Reboita et al., 2021; Marengo et al., 2021). La escala y la duración de nuestro estudio impidieron un examen completo de cómo las influencias globales, regionales, oceánicas-continenciales, microclimáticas o urbanas pueden haber afectado las reducciones de la contaminación de un año a otro o de un mes a otro. Para establecer si los cambios climáticos de un año a otro contribuían a la disminución de la contaminación del aire en las ciudades investigadas, utilizamos un enfoque estadístico sofisticado, que rechazó esta suposición.

Para entender mejor la contaminación del aire en América Latina, es necesario aclarar ciertos factores. La mayoría de las ciudades estudiadas no emplean simultáneamente las medidas de contención más estrictas. La evolución de la pandemia en América Latina ha sido relativamente consistente. Los primeros casos de COVID-19 se registraron a finales de febrero y principios de marzo (González-Bustamante, 2021). Las ciudades examinadas en este estudio tenían limitaciones poblacionales comparables. Perú adoptó medidas de cuarentena el 15 de marzo, seguido por Ecuador, Venezuela, Argentina, Paraguay, Bolivia y Colombia (el 24 de marzo). Sin embargo, las bases de datos consideradas en este estudio tienen algunas limitaciones: Sentinel-5P mide la columna troposférica total, no a nivel del suelo; Los datos de movilidad de Google y Apple solo muestran la información de movilidad de los usuarios que activan el historial de ubicaciones de su dispositivo móvil, y no la movilidad de toda la población de cada ciudad considerada; y, por último, la resolución espacial de los datos meteorológicos de ERA5 no siempre refleja las situaciones urbanas.

Otros autores, como de Oliveira et al. (2021), han estudiado previamente el impacto de las políticas de distanciamiento social en la movilidad latinoamericana. Los autores demostraron que estas características están relacionadas con la movilidad reducida. Sin embargo, hasta donde sabemos, no se ha realizado ningún estudio a nivel latinoamericano sobre la asociación entre el confinamiento, la reducción de la movilidad y la reducción de la contaminación del aire. Nuestros datos muestran que la información proporcionada por las categorías de los informes de movilidad puede explicar la disminución de tropoNO₂ (ver Tabla 2.2). Google informó de una caída en los desplazamientos de los ciudadanos, un aumento en la movilidad en el hogar y una disminución en la movilidad a los lugares de trabajo y terminales de transporte. La disminución en el uso de la conducción y el transporte registrada por Apple apoyó esta hipótesis. Así, las zonas con una alta reducción de NO₂ mostraron una relación significativa con una menor actividad y movilidad relacionada con el transporte, el principal generador de NO₂ primario. Esto está en línea con los estudios de Connerton et al. (2020), Li and Tartarini

(2020) y Wang et al. (2020) que relacionaron la calidad del aire, el tráfico y la movilidad urbana. Sin embargo, incluso después de fusionar los datos de movilidad de Google y Apple, carecíamos de datos suficientes para determinar una disminución específica en el tráfico de automóviles.

Además, los contaminantes en los entornos urbanos se originan en diferentes fuentes, incluido el tráfico de vehículos (por ejemplo, sectores residenciales e industriales), que son difíciles de recolectar (Tomassetti et al., 2020). En la tabla S3 se compara el consumo de diésel de 2020 y 2019 por ciudad, mostrando que el consumo de diésel disminuye a nivel mundial para 2020. A excepción de las crisis económicas graves, el consumo de energía ha aumentado normalmente de forma constante (AIE, 2021). Así, los descensos observados en las ciudades sudamericanas pueden haberse debido a procesos locales o al azar. Sin embargo, fueron contemporáneos y confirmados por las estadísticas de movilidad de Apple y Google (véase la Tabla 2). De hecho, el consumo de energía y las emisiones disminuyeron en todas las ciudades. La mayoría de las ciudades con grandes cambios en el consumo de diésel (es decir, $> \pm 10\%$), en particular BUE (-12,1%), LPB (-18,7%), RIO (-13,4%), SCL (-13%), GYI (-13,5%) y UIO (-13,5%), también experimentaron cambios significativos en las concentraciones de contaminantes atmosféricos (-16,6%, -9,5%, -23%, -36,1%, -15,6% y -18,6%, respectivamente). Sin embargo, algunas ciudades con altas reducciones en el consumo de diésel, como COR (-11,9%) y MEX (-15%), reportaron reducciones moderadas de la contaminación de 3,6% y 7,6%, respectivamente. Por el contrario, algunas ciudades con ligeros descensos en el consumo de diésel, como MDE (-2,5%) y BOG (-2,5%) en Colombia, y SAO (-2,7%) en Brasil, mostraron disminuciones considerables en la contaminación (-14,2%, -17,5% y -25%). No se verificaron ciertos cambios, como en el MVD, donde el consumo bajó un 9% pero la contaminación aumentó un +17,3%. El consumo anual de la ciudad fue el más bajo encuestado (179×10^3 m³). Nótese de nuevo que los cambios en el consumo de diésel fueron solo uno de los factores que podrían alterar las concentraciones de contaminantes en los entornos urbanos. Además, el uso de diésel es anual. Se trata de un periodo más amplio que el analizado; Por lo tanto, los valores de consumo de diésel pueden responder a otros fenómenos que ocurrieron antes o después del periodo de estudio. Teniendo en cuenta que los datos de consumo de diésel son anuales, estas similitudes son ilustrativas y no irrefutables. Por ejemplo, las ciudades con restricciones más severas y duraderas (véase la Fig. 1), como BUE, COR, LPB, GYE y UIO, experimentaron las mayores reducciones en el consumo de diésel de -12,1%, -11,9%, -18,7%, -13,50% y -13,50%, respectivamente (véase la Tabla 2). Sin embargo, BOG y MDE también se enfrentaron a duras restricciones a pesar de experimentar una pequeña reducción en el consumo de diésel (-2,5%), mientras que SCL, MEX, RIO y MVD (-13%, -15%, -13,5%, -9%) tuvieron restricciones menos rigurosas.

Numerosos estudios socioeconómicos han analizado la epidemia de COVID-19 (por ejemplo, Bontempi, 2022). La densidad de población desempeña un papel en la transmisión del virus (Diao et al., 2021; Coccia, 2021), pero se sabe poco sobre su impacto en la calidad del aire debido a las limitaciones de movilidad (Vadrevu et al., 2020). Nuestro análisis mostró que las ciudades con poblaciones de más de cinco millones de habitantes vieron una mayor reducción en las concentraciones de NO₂ atmosférico. Cuando la movilidad de más personas se ve afectada, la calidad del aire se resiente. El intercambio comercial es otro factor socioeconómico que puede afectar a la calidad del aire, como avalan numerosos estudios (Bontempi, 2020), pero este componente está fuera del alcance de este estudio. Sin embargo, esto debería incluirse en futuras investigaciones porque afecta a los límites de movilidad promulgados por el gobierno.

2.5. Conclusión

TROPOMI nos permitió evaluar y comparar el NO₂ en 17 ciudades latinoamericanas entre 2019 y 2020 (entre marzo y junio), lo que nos permite examinar el impacto de las cuarentenas, las políticas de distanciamiento social y la variabilidad climática en la contaminación del aire. Ciudades latinoamericanas que presentaron una disminución significativa en las concentraciones de NO₂ fueron las siguientes: Lima (47,5%), Santiago (36,1%), São Paulo (27%), Río de Janeiro (23%), Quito (18,6%), Bogotá (17,5%), Buenos Aires (16,6%), Guayaquil (15,3%), Medellín (14,2%), La Paz (9,5%), Belo Horizonte (7,8%), México (7,6%) y Brasilia (5,9%). Esta disminución refleja una mejora considerable en la calidad del aire en ciudades muy contaminadas como Santiago, Sao Paulo, Buenos Aires, México, Lima y Río de Janeiro. En la mayoría de las ciudades, hubo una diferencia notable entre 2019 y 2020, que creció con la implementación de medidas de confinamiento durante la segunda quincena de marzo de 2020. Nuestro estudio encontró que las ciudades más pobladas (Lima, Santiago, Sao Pablo, Ciudad de México, Bogotá y Río de Janeiro) experimentaron una reducción de NO₂ significativamente mayor (en promedio 26,5%) que las ciudades menos pobladas (en promedio 12,6%). Utilizando datos de los informes de Google y Apple, demostramos una correlación sustancial y estadísticamente

significativa entre la reducción de NO₂ en 2020 y varias categorías de movilidad. Del mismo modo, el método NMF organizó los cambios drásticos de NO₂ en un patrón que se correlaciona con los patrones de movilidad de las ciudades latinoamericanas. El enfoque no logró establecer una asociación a escala regional entre la disminución del NO₂ y variables meteorológicas locales, como la temperatura, la precipitación y la velocidad del viento. Como resultado, ningún patrón de variables meteorológicas se correlacionó con la disminución del NO₂ entre 2019 y 2020. Este resultado fue confirmado por un análisis temporal de una década de duración que comparó las concentraciones de NO₂ y variables meteorológicas, utilizando las mediciones satelitales de NO₂ (del satélite OMI) y datos meteorológicos (de ERA5) desde 2011.

Estos hallazgos proporcionan la primera medición directa de los efectos del distanciamiento social en la calidad del aire en las ciudades más grandes de América Latina. Estos resultados también demuestran la promesa de utilizar mediciones basadas en la teledetección para monitorear la respuesta de la contaminación del aire a las políticas de regulación de emisiones de las ciudades presentes y futuras. La investigación futura debería centrarse en aumentar la resolución espacial de las imágenes satelitales para integrar las características espaciales, como las carreteras, la densidad de población y la cobertura del suelo. Además, se podrían incorporar datos in situ terrestres para obtener una imagen más detallada de lo ocurrido en las ciudades investigadas. El confinamiento por COVID-19 demostró cómo se podían reducir y controlar eficazmente las concentraciones de contaminantes atmosféricos. Los gobiernos y los responsables de la adopción de decisiones deberían realizar investigaciones adicionales en esta esfera. Cuando nos enfrentamos a un entorno pospandémico, debemos aprender lecciones sobre nuestra contribución a la calidad del aire y considerar las medidas más eficientes para ayudar a mantener los niveles relativamente bajos de concentración de contaminantes atmosféricos observados durante la pandemia.

Referencias

- Agarwal, A., Kaushik, A., Kumar, S., & Mishra, R. K. (2020). Comparative study on air quality status in Indian and Chinese cities before and during the COVID-19 lockdown period. *Air Quality, Atmosphere and Health*, 13(10), 1167–1178. <https://doi.org/10.1007/s11869-020-00881-z>
- Apple (2021). COVID-19 - Informes de tendencias de movilidad - Apple.. Retrieved June 2, 2021, from <https://covid19.apple.com/mobility>
- BA Salud (@BASalud) / Twitter. (n.d.). Retrieved June 14, 2021, from <https://twitter.com/BASalud>.
- Ban-Weiss, G.A., McLaughlin, J.P., Harley, R.A., Kean, A.J., Grosjean, E. and Grosjean, D. (2008). Carbonyl and nitrogen dioxide emissions from gasoline- and diesel-powered motor vehicles. *Environ. Sci. Technol.* 42: 3944–3950. <https://doi.org/10.1021/es8002487>
- Balmaceda-Huarte, R., Olmo, M. E., Bettolli, M. L., & Poggi, M. M. (2021). Evaluation of multiple reanalyses in reproducing the spatio-temporal variability of temperature and precipitation indices over southern South America. *International Journal of Climatology*, 41(12), 5572–5595. <https://doi.org/10.1002/JOC.7142>
- Bauwens, M., Compennolle, S., Stavrou, T., Müller, J. -F., Gent, J., Eskes, H., Levelt, P. F., A, R., Veeffkind, J. P., Vlietinck, J., Yu, H., & Zehner, C. (2020). Impact of Coronavirus Outbreak on NO₂ Pollution Assessed Using TROPOMI and OMI Observations. *Geophysical Research Letters*, 47(11), e2020GL087978. <https://doi.org/10.1029/2020GL087978>
- Beck, H. E. et al. Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Sci. Data*. 5:180214 doi: 10.1038/sdata.2018.214 (2018).
- Berman, J. D., & Ebi, K. (2020). Changes in U.S. air pollution during the COVID-19 pandemic. *Science of the Total Environment*, 739, 139864. <https://doi.org/10.1016/j.scitotenv.2020.139864>
- Bolaño-Ortiz, T. R., Pascual-Flores, R. M., Puliafito, S. E., Camargo-Cacedo, Y., Berná-Peña, L. L., Ruggeri, M. F., Lopez-Noreña, A. I., Tames, M. F., & Cereceda-Balic, F. (2020). Spread of COVID-19, Meteorological Conditions and Air Quality in the City of Buenos Aires, Argentina: Two Facets Observed during Its Pandemic Lockdown. *Atmosphere*, 11(10), 1045. <https://doi.org/10.3390/atmos11101045>
- Bontempi, E. (2020). Commercial exchanges instead of air pollution as possible origin of COVID-19 initial diffusion phase in Italy: More efforts are necessary to address interdisciplinary research. *Environmental Research*, 188, 109775. <https://doi.org/10.1016/J.ENVRES.2020.109775>
- Bontempi, E. (2022). A global assessment of COVID-19 diffusion based on a single indicator: Some considerations about air pollution and COVID-19 spread. *Environmental Research*, 204, 112098. <https://doi.org/10.1016/J.ENVRES.2021.112098>
- Brunet, J. P., Tamayo, P., Golub, T. R., & Mesirov, J. P. (2004). Metagenes and molecular pattern discovery using matrix factorization. *Proceedings of the National Academy of Sciences of the United States of America*, 101(12), 4164–4169. <https://doi.org/10.1073/pnas.0308531101>
- Cai, W., McPhaden, M. J., Grimm, A. M., Rodrigues, R. R., Taschetto, A. S., Garreaud, R. D., Dewitte, B., Poveda, G., Ham, Y.-G., Santoso, A., Ng, B., Anderson, W., Wang, G., Geng, T., Jo, H.-S., Marengo, J. A., Alves, L. M., Osman, M., Li, S., ... Vera, C. (2020). Climate impacts of the El Niño–Southern Oscillation on South America. *Nature Reviews Earth & Environment*, 1(4), 215–231. <https://doi.org/10.1038/s43017-020-0040-3>
- Cocchia, M. (2021). How do low wind speeds and high levels of air pollution support the spread of COVID-19? *Atmospheric Pollution Research*, 12(1), 437–445. <https://doi.org/10.1016/J.APR.2020.10.002>
- Collivignarelli, M. C., Abbà, A., Bertanza, G., Pedrazzani, R., Ricciardi, P., & Carnevale Miino, M. (2020). Lockdown for CoViD-2019 in Milan: What are the effects on air quality? *Science of the Total Environment*, 732, 139280. <https://doi.org/10.1016/j.scitotenv.2020.139280>
- Connerton, P., Vicente de Assunção, J., Maura de Miranda, R., Dorothée Slovic, A., José Pérez-Martínez, P., & Ribeiro, H. (2020). Air Quality during COVID-19 in Four Megacities: Lessons and Challenges for Public Health. *International Journal of Environmental Research and Public Health*, 17(14), 5067. <https://doi.org/10.3390/ijerph17145067>
- Corrêa, M. D. P. (2015). Solar ultraviolet radiation: Properties, characteristics and amounts observed in Brazil and south America. *Anais Brasileiros de Dermatologia*, 90(3), 297–313. <https://doi.org/10.1590/abd1806-4841.20154089>
- Cot, C., Cacciapaglia, G., & Sannino, F. (2021). Mining Google and Apple mobility data: temporal anatomy for COVID-19 social distancing. *Scientific Reports*, 11(1), 4150. <https://doi.org/10.1038/s41598-021-83441-4>
- Cucchi, M., P. Weedon, G., Amici, A., Bellouin, N., Lange, S., Müller Schmied, H., Hersbach, H., & Buontempo, C. (2020). WFDE5: Bias-adjusted ERA5 reanalysis data for impact studies. *Earth System Science Data*, 12(3), 2097–2120. <https://doi.org/10.5194/essd-12-2097-2020>

- Dantas, G., Siciliano, B., França, B. B., da Silva, C. M., & Arbilla, G. (2020). The impact of COVID-19 partial lockdown on the air quality of the city of Rio de Janeiro, Brazil. *Science of the Total Environment*, 729, 139085. <https://doi.org/10.1016/j.scitotenv.2020.139085>
- de Foy, B., Wilkins, J. L., Lu, Z., Streets, D. G., & Duncan, B. N. (2014). Model evaluation of methods for estimating surface emissions and chemical lifetimes from satellite data. *Atmospheric Environment*, 98, 66–77. <https://doi.org/10.1016/j.atmosenv.2014.08.051>
- Diao, Y., Kodera, S., Anzai, D., Gomez-Tames, J., Rashed, E. A., & Hirata, A. (2021). Influence of population density, temperature, and absolute humidity on spread and decay durations of COVID-19: A comparative study of scenarios in China, England, Germany, and Japan. *One Health*, 12, 100203. <https://doi.org/10.1016/J.ONEHLT.2020.100203>
- Ecmwf/Cdsapi: Python API to Access the Copernicus Climate Data Store (CDS). Retrieved April 25, 2021, from <https://github.com/ecmwf/cdsapi>
- Eskes, H. J., & Knmi, (. (2020). S5P Mission Performance Centre Nitrogen Dioxide [L2_NO2_] Readme document number Prepared by. <https://earth.esa.int/web/guest/pi->
- Garreaud, R. D., Vuille, M., Compagnucci, R., & Marengo, J. (2009). Present-day South American climate. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 281(3–4), 180–195. <https://doi.org/10.1016/j.palaeo.2007.10.032>
- Gaujoux, R., & Seoighe, C. (2010). A flexible R package for nonnegative matrix factorization. *BMC Bioinformatics*, 11(1), 367. <https://doi.org/10.1186/1471-2105-11-367>
- Google (2021). Informes de Movilidad Local sobre el COVID-19. (n.d.). Retrieved June 2, 2021, from <https://www.google.com/covid19/mobility/>
- Goldberg, D. L., Anenberg, S. C., Griffin, D., McLinden, C. A., Lu, Z., & Streets, D. G. (2020). Disentangling the Impact of the COVID-19 Lockdowns on Urban NO₂ From Natural Variability. *Geophysical Research Letters*, 47(17), e2020GL089269. <https://doi.org/10.1029/2020GL089269>
- González-Bustamante, B. (2021). Evolution and early government responses to COVID-19 in South America. *World Development*, 137, 105180. <https://doi.org/10.1016/j.worlddev.2020.105180>
- Governo de R. Janeiro (@SaudeGovRJ) / Twitter. (n.d.). Retrieved June 14, 2021, from <https://twitter.com/SaudeGovRJ>
- Governo de S. Paulo (@governosp) / Twitter. (n.d.). Retrieved June 11, 2021, from <https://twitter.com/governosp>
- Grange, S. K., Lewis, A. C., Moller, S. J., & Carslaw, D. C. (2017). Lower vehicular primary emissions of NO₂ in Europe than assumed in policy projections. *Nature Geoscience* 2017 10:12, 10(12), 914–918. <https://doi.org/10.1038/s41561-017-0009-0>
- Hernández-Paniagua, I. Y., Valdez, S. I., Almanza, V., Rivera-Cárdenas, C., Grutter, M., Stremme, W., García-Reynoso, A., & Ruiz-Suárez, L. G. (2021). Impact of the COVID-19 Lockdown on Air Quality and Resulting Public Health Benefits in the Mexico City Metropolitan Area. *Frontiers in Public Health*, 9, 642630. <https://doi.org/10.3389/fpubh.2021.642630>
- Huang, G., & Sun, K. (2020). Non-negligible impacts of clean air regulations on the reduction of tropospheric NO₂ over East China during the COVID-19 pandemic observed by OMI and TROPOMI. *Science of the Total Environment*, 745, 141023. <https://doi.org/10.1016/j.scitotenv.2020.141023>
- IBGE (2020). Portal do IBGE. Retrieved January 27, 2021, from <https://www.ibge.gov.br/>
- IEA (2021): IEA (2021), World Energy Outlook 2021, IEA, Paris <https://www.iea.org/reports/world-energy-outlook-2021>
- INE (2017). Censos de Población y Vivienda, Chile. Retrieved January 28, 2021, from <https://www.ine.cl/estadisticas/sociales/censos-de-poblacion-y-vivienda>
- INE (2012). Censo de poblacion y vivienda, Bolivia. Retrieved January 28, 2021, from <https://www.ine.gob.bo/index.php/la-paz-3/>
- INE (2011a). Censos 2011 - Instituto Nacional de Estadística, Uruguay. Retrieved January 28, 2021, from <https://web.archive.org/web/20170712024858/http://www.ine.gub.uy/web/guest/censos2011>
- INE (2011b). XIV Censo Nacional de Poblacion y Vivienda, Venezuela. Retrieved January 28, 2021, from https://web.archive.org/web/20150510173447/http://www.ine.gov.ve/index.php?option=com_content&id=56&Itemid=8;tmpl=component
- INEC (2020). Población / Proyecciones y estimaciones, Ecuador. Retrieved January 28, 2021, from <https://www.ecuadorencifras.gob.ec/proyecciones-poblacionales/>
- INEI (2020). Instituto Nacional de Estadística e Informática, Peru. Retrieved January 28, 2021, from <https://www.inei.gob.pe/>
- INEGI (2020). Instituto Nacional de Estadística y Geografía (INEGI). Retrieved January 28, 2021, from <https://www.inegi.org.mx/>
- Islam, M. S., Tusher, T. R., Roy, S., & Rahman, M. (2021). Impacts of nationwide lockdown due to COVID-19 outbreak on air quality in Bangladesh: a spatiotemporal analysis. *Air Quality, Atmosphere and Health*, 14(3), 351–363. <https://doi.org/10.1007/s11869-020-00940-5>
- Jakob, A., Hasibuan, S., & Fiantis, D. (2022). Empirical evidence shows that air quality changes during COVID-19 pandemic lockdown in Jakarta, Indonesia are due to seasonal variation, not restricted movements. *Environmental Research*, 208, 112391. <https://doi.org/10.1016/J.ENVRES.2021.112391>
- Kerimray, A., Baimatova, N., Ibragimova, O. P., Bukenov, B., Kenessov, B., Plotitsyn, P., & Karaca, F. (2020). Assessing air quality changes in large cities during COVID-19 lockdowns: The impacts of traffic-free urban conditions in Almaty, Kazakhstan. *Science of the Total Environment*, 730, 139179. <https://doi.org/10.1016/j.scitotenv.2020.139179>
- Kottek, M., J. Grieser, C. Beck, B. Rudolf, and F. Rubel, 2006: World Map of the Köppen-Geiger climate classification updated. *Meteorol. Z.*, 15, 259-263. DOI: 10.1127/0941-2948/2006/0130.
- Krecl, P., Targino, A. C., Oukawa, G. Y., & Cassino Junior, R. P. (2020). Drop in urban air pollution from COVID-19 pandemic: Policy implications for the megacity of São Paulo. In *Environmental Pollution* (Vol. 265, p. 114883). Elsevier Ltd. <https://doi.org/10.1016/j.envpol.2020.114883>
- Kumar P (2021) Climate Change and Cities: Challenges Ahead. *Front. Sustain. Cities* 3:645613. doi: 10.3389/frsc.2021.645613
- Lamsal, L., A. Krotkov, N., Vasilkov, A., Marchenko, S., Qin, W., Fasnacht, Z., Joiner, J., Choi, S., Haffner, D., H. Swartz, W., Fisher, B., & Bucsela, E. (2021). Ozone Monitoring Instrument (OMI) Aura nitrogen dioxide standard product version 4.0 with improved surface and cloud treatments. *Atmospheric Measurement Techniques*, 14(1), 455–479. <https://doi.org/10.5194/amt-14-455-2021>
- Laughner, J. L., & Cohen, R. C. (2019a). Direct observation of changing NO_x lifetime in North American cities. *Science*, 366(6466), 723–727. <https://doi.org/10.1126/science.aax6832>
- Laughner, J. L., & Cohen, R. C. (2019b). Direct observation of changing NO_x lifetime in North American cities. *Science*, 366(6466), 723–727. <https://doi.org/10.1126/science.aax6832>
- Lee, D. D., & Seung, H. S. (1999). Learning the parts of objects by non-negative matrix factorization. *Nature*, 401(6755), 788–791. <https://doi.org/10.1038/44565>
- Levelt, P. F., Van Den Oord, G. H. J., Dobber, M. R., Mälkki, A., Visser, H., De Vries, J., Stammes, P., Lundell, J. O. V., & Saari, H. (2006). The ozone monitoring instrument. *IEEE Transactions on Geoscience and Remote Sensing*, 44(5), 1093–1100. <https://doi.org/10.1109/TGRS.2006.872333>
- Li, J., & Tartarini, F. (2020). Changes in Air Quality during the COVID-19 Lockdown in Singapore and Associations with Human Mobility Trends. *Aerosol and Air Quality Research*, 20(8), 1748–1758. <https://doi.org/10.4209/aaqr.2020.06.0303>
- Liang, C. S., Wu, H., Li, H. Y., Zhang, Q., Li, Z., & He, K. Bin. (2020). Efficient data preprocessing, episode classification, and source apportionment of particle number concentrations. *Science of The Total Environment*, 744, 140923. <https://doi.org/10.1016/J.SCITOTENV.2020.140923>
- Liang, C. S., Yue, D., Wu, H., Shi, J. Sen, & He, K. Bin. (2021). Source apportionment of atmospheric particle number concentrations with wide size range by nonnegative matrix factorization (NMF). *Environmental Pollution*, 289, 117846. <https://doi.org/10.1016/J.ENVPOL.2021.117846>
- Lin, J., Huang, W., Wen, M., Li, D., Ma, S., Hua, J., Hu, H., Yin, S., Qian, Y., Chen, P., Zhang, Q., Yuan, N., & Sun, S. (2020). Containing the spread of coronavirus disease 2019 (COVID-19): Meteorological factors and control strategies. *Science of The Total Environment*, 744, 140935. <https://doi.org/10.1016/J.SCITOTENV.2020.140935>

- Liu, F., Page, A., Strode, S. A., Yoshida, Y., Choi, S., Zheng, B., Lamsal, L. N., Li, C., Krotkov, N. A., Eskes, H., Ronald van der, A., Veeffkind, P., Levelt, P. F., Hauser, O. P., & Joiner, J. (2020). Abrupt decline in tropospheric nitrogen dioxide over China after the outbreak of COVID-19. *Science Advances*, 6(28), eabc2992. <https://doi.org/10.1126/sciadv.abc2992>
- Lok Chan, K., Wiegner, M., Van Geffen, J., De Smedt, I., Alberti, C., Cheng, Z., Ye, S., & Wenig, M. (2020). MAX-DOAS measurements of tropospheric NO₂ and HCHO in Munich and the comparison to OMI and TROPOMI satellite observations. *Atmospheric Measurement Techniques*, 13(8), 4499–4520. <https://doi.org/10.5194/amt-13-4499-2020>
- Ma, Q., Zhang, Q., Wang, Q., Yuan, X., Yuan, R., & Luo, C. (2021). A comparative study of EOF and NMF analysis on downward trend of AOD over China from 2011 to 2019. *Environmental Pollution*, 288, 117713. <https://doi.org/10.1016/j.envpol.2021.117713>
- Mahato, S., Pal, S., & Ghosh, K. G. (2020). Effect of lockdown amid COVID-19 pandemic on air quality of the megacity Delhi, India. *Science of the Total Environment*, 730, 139086. <https://doi.org/10.1016/j.scitotenv.2020.139086>
- Malley, C. S., Braban, C. F., & Heal, M. R. (2014). The application of hierarchical cluster analysis and non-negative matrix factorization to European atmospheric monitoring site classification. *Atmospheric Research*, 138, 30–40. <https://doi.org/10.1016/j.atmosres.2013.10.019>
- Marengo, J. et al. (2021). State of the Climate in Latin America and the Caribbean 2020 WMO- No. 1272. isbn = {978-92-63-11272-9}
- Masson, V., Lemonsu, A., Hidalgo, J., & Voogt, J. (2020). Urban climates and climate change. *Annual Review of Environment and Resources*, 45, 411–444. doi: 10.1146/annurev-environ-012320-083623
- Mendez-Espinosa, J. F., Rojas, N. Y., Vargas, J., Pachón, J. E., Belalcázar, L. C., & Ramírez, O. (2020). Air quality variations in Northern South America during the COVID-19 lockdown. *Science of the Total Environment*, 749, 141621. <https://doi.org/10.1016/j.scitotenv.2020.141621>
- Ministerio de Salud (@ministeriosalud) / Twitter. (n.d.). Retrieved June 14, 2021, from <https://twitter.com/ministeriosalud>
- Ministerio de Salud (@Minsa_Peru) / Twitter. (n.d.). Retrieved June 14, 2021, from https://twitter.com/Minsa_Peru
- Ministerio de Salud Pública (@Salud_Ec) / Twitter. (n.d.). Retrieved June 14, 2021, from https://twitter.com/Salud_Ec
- Ministerio de Salud y Deportes Bolivia (@SaludDeportesBo) / Twitter. (n.d.). Retrieved June 14, 2021, from <https://twitter.com/SaludDeportesBo>
- MinSaludCol (@MinSaludCol) / Twitter. (n.d.). Retrieved June 14, 2021, from <https://twitter.com/MinSaludCol>
- Morens, D. M., & Fauci, A. S. (2020). Emerging Pandemic Diseases: How We Got to COVID-19. *Cell*, 182(5), 1077–1092. <https://doi.org/10.1016/J.CELL.2020.08.021>
- MPPS (@MinSaludVE) / Twitter. (n.d.). Retrieved June 14, 2021, from <https://twitter.com/MinSaludVE>
- MSP - Uruguay (@MSPUruguay) / Twitter. (n.d.). Retrieved June 14, 2021, from <https://twitter.com/MSPUruguay>
- Muhammad, S., Long, X., & Salman, M. (2020). COVID-19 pandemic and environmental pollution: A blessing in disguise? *Science of the Total Environment*, 728, 138820. <https://doi.org/10.1016/j.scitotenv.2020.138820>
- Nakada, L. Y. K., & Urban, R. C. (2020). COVID-19 pandemic: Impacts on the air quality during the partial lockdown in São Paulo state, Brazil. *Science of the Total Environment*, 730, 139087. <https://doi.org/10.1016/j.scitotenv.2020.139087>
- Oke TR, Mills G, Christen A, Voogt J. 2017. *Urban Climate*. Cambridge, UK: Cambridge Univ. Press
- Oliveira, G. L. A. de, Lima, L., Silva, I., Ribeiro-Dantas, M. da C., Monteiro, K. H., & Endo, P. T. (2021). Evaluating Social Distancing Measures and Their Association with the Covid-19 Pandemic in South America. *ISPRS International Journal of Geo-Information*, 10(3), 121. <https://doi.org/10.3390/ijgi10030121>
- Otmani, A., Benchrif, A., Tahri, M., Bounakhla, M., Chakir, E. M., El Bouch, M., & Krombi, M. (2020). Impact of Covid-19 lockdown on PM₁₀, SO₂ and NO₂ concentrations in Salé City (Morocco). *Science of the Total Environment*, 735, 139541. <https://doi.org/10.1016/j.scitotenv.2020.139541>
- Pacheco, H., Díaz-López, S., Jarre, E., Pacheco, H., Méndez, W., & Zamora-Ledezma, E. (2020). NO₂ levels after the COVID-19 lockdown in Ecuador: A trade-off between environment and human health. *Urban Climate*, 34, 100674. <https://doi.org/10.1016/j.uclim.2020.100674>
- Park, G., Mun, S., Hong, H., Chung, T., Jung, S., Kim, S., Seo, S., Kim, J., Lee, J., Kim, K., Park, T., Kang, S., Ban, J., Yu, D.G., Woo, J.H. and Lee, T. (2019). Characterization of emission factors concerning gasoline, LPG, and diesel vehicles via transient chassis-dynamometer tests. *Appl. Sci.* <https://doi.org/10.3390/app9081573>.
- Pepe, E., Bajardi, P., Gauvin, L., Privitera, F., Lake, B., Cattuto, C., & Tizzoni, M. (2020). COVID-19 outbreak response, a dataset to assess mobility changes in Italy following national lockdown. *Scientific Data*, 7(1), 1–7. <https://doi.org/10.1038/s41597-020-00575-2>
- Peralta, O., Ortíz-Alvarez, A., Torres-Jardón, R., Suárez-Lastra, M., Castro, T., & Ruíz-Suárez, L. G. (2021). Ozone over Mexico City during the COVID-19 pandemic. *Science of the Total Environment*, 761, 143183. <https://doi.org/10.1016/j.scitotenv.2020.143183>
- Pope, R. J., Savage, N. H., Chipperfield, M. P., Ordóñez, C., & Neal, L. S. (2015). The influence of synoptic weather regimes on UK air quality: Regional model studies of tropospheric column NO₂. *Atmospheric Chemistry and Physics*, 15(19), 11201–11215. <https://doi.org/10.5194/acp-15-11201-2015>
- Prunet, P., Lezeaux, O., Camy-Peyret, C., & Thevenon, H. (2020). Analysis of the NO₂ tropospheric product from S5P TROPOMI for monitoring pollution at city scale. *City and Environment Interactions*, 8, 100051. <https://doi.org/10.1016/J.CACINT.2020.100051>
- Python interface — HARP 1.13 documentation. Retrieved April 25, 2021, from <https://stcorp.github.io/harp/doc/html/python.html#api-reference>
- Ravindra, K., Rattan, P., Mor, S., & Aggarwal, A. N. (2019). Generalized additive models: Building evidence of air pollution, climate change and human health. *Environment International*, 132, 104987. <https://doi.org/10.1016/J.ENVINT.2019.104987>
- Reboita, M.S., Kuki, C.A.C., Marrafon, V.H. et al. South America climate change revealed through climate indices projected by GCMs and Eta-RCM ensembles. *Clim Dyn* (2021). <https://doi.org/10.1007/s00382-021-05918-2>
- Rodríguez-Urrego, D., & Rodríguez-Urrego, L. (2020). Air quality during the COVID-19: PM_{2.5} analysis in the 50 most polluted capital cities in the world. In *Environmental Pollution* (Vol. 266, p. 115042). Elsevier Ltd. <https://doi.org/10.1016/j.envpol.2020.115042>
- Rojas, J. P., Urdanivia, F. R., Garay, R. A., García, A. J., Enciso, C., Medina, E. A., Toro, R. A., Manzano, C., & Leiva-Guzmán, M. A. (2021). Effects of COVID-19 pandemic control measures on air pollution in Lima metropolitan area, Peru in South America. *Air Quality, Atmosphere and Health*, 1–9. <https://doi.org/10.1007/s11869-021-00990-3>
- Saadat, S., Rawtani, D., & Hussain, C. M. (2020). Environmental perspective of COVID-19. In *Science of the Total Environment* (Vol. 728, p. 138870). Elsevier B.V. <https://doi.org/10.1016/j.scitotenv.2020.138870>
- SALUD México (@SSalud_mx) / Twitter. (n.d.). Retrieved June 14, 2021, from https://twitter.com/SSalud_mx
- Saúde Bahia (@saudegovba) / Twitter. (n.d.). Retrieved June 13, 2021, from <https://twitter.com/saudegovba>
- Secretaría de Saude do DF (@secsaudedf) / Twitter. (n.d.). Retrieved June 13, 2021, from <https://twitter.com/secsaudedf>
- Secretaría de Desarrollo de la Salud - Córdoba. (@CordobaSalud) / Twitter. (n.d.). Retrieved June 14, 2021, from <https://twitter.com/CordobaSalud>
- Shah, V., J. Jacob, D., Li, K., Silvern, R., Zhai, S., Liu, M., Lin, J., & Zhang, Q. (2020). Effect of changing NO_x lifetime on the seasonality and long-term trends of satellite-observed tropospheric NO₂ columns over China. *Atmospheric Chemistry and Physics*, 20(3), 1483–1495. <https://doi.org/10.5194/acp-20-1483-2020>
- Shakoor, A., Chen, X., Farooq, T. H., Shahzad, U., Ashraf, F., Rehman, A., Sahar, N. e., & Yan, W. (2020). Fluctuations in environmental pollutants and air quality during the lockdown in the USA and China: two sides of COVID-19 pandemic. *Air Quality, Atmosphere and Health*, 13(11), 1335–1342. <https://doi.org/10.1007/s11869-020-00888-6>
- Sharma, S., Zhang, M., Anshika, Gao, J., Zhang, H., & Kota, S. H. (2020). Effect of restricted emissions during COVID-19 on air quality in India. *Science of the Total Environment*, 728, 138878. <https://doi.org/10.1016/j.scitotenv.2020.138878>
- Shereen, M. A., Khan, S., Kazmi, A., Bashir, N., & Siddique, R. (2020). COVID-19 infection: Origin, transmission, and characteristics of human coronaviruses. In *Journal of Advanced Research* (Vol. 24, pp. 91–98). Elsevier B.V. <https://doi.org/10.1016/j.jare.2020.03.005>

- Shi, X., & Brasseur, G. P. (2020). The Response in Air Quality to the Reduction of Chinese Economic Activities During the COVID-19 Outbreak. *Geophysical Research Letters*, 47(11), e2020GL088070. <https://doi.org/10.1029/2020GL088070>
- Sicard, P., De Marco, A., Agathokleous, E., Feng, Z., Xu, X., Paoletti, E., Rodriguez, J. J. D., & Calatayud, V. (2020). Amplified ozone pollution in cities during the COVID-19 lockdown. *Science of the Total Environment*, 735, 139542. <https://doi.org/10.1016/j.scitotenv.2020.139542>
- Siciliano, B., Carvalho, G., da Silva, C. M., & Arbilla, G. (2020). The Impact of COVID-19 Partial Lockdown on Primary Pollutant Concentrations in the Atmosphere of Rio de Janeiro and São Paulo Megacities (Brazil). *Bulletin of Environmental Contamination and Toxicology*, 105(1), 2–8. <https://doi.org/10.1007/s00128-020-02907-9>
- Tang, R., Huang, X., Zhou, D., Wang, H., Xu, J., & Ding, A. (2021). Global air quality change during the COVID-19 pandemic: Regionally different ozone pollution responses COVID-19. *Atmospheric and Oceanic Science Letters*, 100015. <https://doi.org/10.1016/j.aosl.2020.100015>
- Thiem, A., Schlink, U., Pan, X.-C., Hu, M., Peters, A., Wiedensohler, A., Breitner, S., Cyrys, J., Wehner, B., Rösch, C., and Franck, U (2012).: Using non-negative matrix factorization for the identification of daily patterns of particulate air pollution in Beijing during 2004–2008, *Atmos. Chem. Phys. Discuss.*, 12, 13015–13052, <https://doi.org/10.5194/acpd-12-13015-2012>,
- Tobías, A., Carnerero, C., Reche, C., Massagué, J., Via, M., Minguillón, M. C., Alastuey, A., & Querol, X. (2020). Changes in air quality during the lockdown in Barcelona (Spain) one month into the SARS-CoV-2 epidemic. *Science of the Total Environment*, 726, 138540. <https://doi.org/10.1016/j.scitotenv.2020.138540>
- Tomassetti, L.; Torre, M.; Tratzi, P.; Paolini, V.; Rizza, V.; Segreto, M.; Petracchini, F.; Tomassetti, L.; Torre, M.; Tratzi, P. (2020). Evaluation of air quality and mobility policies in 14 large Italian cities from 2006 to 2016. *J. Environ. Sci. Health Part A* 2020, 55, 886–902. <https://doi.org/10.1080/10934529.2020.1752070>.
- Toro A., R., Catalán, F., Urdanivia, F. R., Rojas, J. P., Manzano, C. A., Seguel, R., Gallardo, L., Osses, M., Pantoja, N., & Leiva-Guzman, M. A. (2021). Air pollution and COVID-19 lockdown in a large South American city: Santiago Metropolitan Area, Chile. *Urban Climate*, 36, 100803. <https://doi.org/10.1016/j.uclim.2021.100803>
- Vadrevu, K. P., Eaturu, A., Biswas, S., Lasko, K., Sahu, S., Garg, J. K., & Justice, C. (2020). Spatial and temporal variations of air pollution over 41 cities of India during the COVID-19 lockdown period. *Scientific Reports*, 10(1), 1–15. <https://doi.org/10.1038/s41598-020-72271-5>
- Velayarce, D., Bustos, Levels during the COVID-19 Pandemic Lockdown. *Atmosphere* 2022, Vol. 13, Page 373, 13(3), 373. <https://doi.org/10.3390/ATMOS13030373>
- Vîrghileanu, M., Săvulescu, I., Mihai, B. A., Nistor, C., & Dobre, R. (2020). Nitrogen dioxide (NO₂) pollution monitoring with sentinel-5p satellite imagery over europe during the coronavirus pandemic outbreak. *Remote Sensing*, 12(21), 1–29. <https://doi.org/10.3390/rs12213575>
- Wang, Yichen, Yuan, Y., Wang, Q., Liu, C. G., Zhi, Q., & Cao, J. (2020). Changes in air quality related to the control of coronavirus in China: Implications for traffic and industrial emissions. *The Science of the Total Environment*, 731, 139133. <https://doi.org/10.1016/j.scitotenv.2020.139133>
- Wang, Yujue, Hu, M., Wang, Y., Zheng, J., Shang, D., Yang, Y., Liu, Y., Li, X., Tang, R., Zhu, W., Du, Z., Wu, Y., Guo, S., Wu, Z., Lou, S., Hallquist, M., & Yu, J. Z. (2019). The formation of nitro-aromatic compounds under high NO_x and anthropogenic VOC conditions in urban Beijing, China. *Atmospheric Chemistry and Physics*, 19(11), 7649–7665. <https://doi.org/10.5194/acp-19-7649-2019>
- WHO (2020a). Retrieved April 9, 2021, from <https://www.who.int/emergencies/diseases/novel-coronavirus-2019>
- Wu, S., Huang, B., Wang, J., He, L., Wang, Z., Yan, Z., Lao, X., Zhang, F., Liu, R., & Du, Z. (2021). Spatiotemporal mapping and assessment of daily ground NO₂ concentrations in China using high-resolution TROPOMI retrievals. *Environmental Pollution*, 273, 116456. <https://doi.org/10.1016/j.envpol.2021.116456>
- Xu, K., Cui, K., Young, L.-H., Hsieh, Y.-K., Wang, Y.-F., Zhang, J., & Wan, S. (2020). Impact of the COVID-19 Event on Air Quality in Central China. *Aerosol and Air Quality Research*, 20(5), 915–929. <https://doi.org/10.4209/aaqr.2020.04.0150>
- Zalakeviciute, R., Vasquez, R., Bayas, D., Buenano, A., Mejia, D., Zegarra, R., Diaz, V., & Lamb, B. (2020). Drastic Improvements in Air Quality in Ecuador during the COVID-19 Outbreak. *Aerosol and Air Quality Research*, 20(8), 1783–1792. <https://doi.org/10.4209/aaqr.2020.05.0254>
- Zambrano-Monserrate, M. A., & Ruano, M. A. (2020). Has air quality improved in Ecuador during the COVID-19 pandemic? A parametric analysis. *Air Quality, Atmosphere and Health*, 13(8), 929–938. <https://doi.org/10.1007/s11869-020-00866-y>
- Zhang, R., Zhang, Y., Lin, H., Feng, X., Fu, T. M., & Wang, Y. (2020). NO_x emission reduction and recovery during COVID-19 in East China. *Atmosphere*, 11(4), 433. <https://doi.org/10.3390/ATMOS11040433>
- Zheng, Yang, Wu, & Marinello. (2019). Spatial Variation of NO₂ and Its Impact Factors in China: An Application of Sentinel-5P Products. *Remote Sensing*, 11(16), 1939. <https://doi.org/10.3390/rs11161939>

Capítulo 3:

Assessing the Influence of Energy Consumption on Tropospheric NO₂ in Santiago, Chile: A Multi-Method Approach Using Satellite Data

Capítulo basado en: Publicación enviada

Assessing the Influence of Energy Consumption on Tropospheric NO₂ in Santiago, Chile: A Multi-Method Approach Using Satellite Data

Matias I. Volke^a, Lisdelys González-Rodríguez^b

^a Energy Doctoral Program, Faculty of Engineering, Universidad de Concepción, Concepción 4030000, Chile.

^bFacultad de Ingeniería y Negocios, Universidad de Las Américas, Sede Concepción, Chile.

Abstract

Changes in energy consumption patterns are closely linked to variations in air quality. Nitrogen dioxide (NO₂), a key atmospheric pollutant, poses significant risks to both environmental and human health. This study analyzed tropospheric NO₂ (tropoNO₂) time series over Santiago, Chile, from 2006 to 2020 using satellite data from the Ozone Monitoring Instrument (OMI). Significant positive correlations ($r > 0.8$) were found between annual tropoNO₂ levels and energy-related indicators, including crude oil price, fossil fuel primary energy consumption, and per capita energy use. Although monthly VIIRS DNB nighttime lights data, which was also used as a proxy for energy consumption, showed no significant linear correlation, empirical dynamic modeling revealed a positive causal relationship with tropoNO₂.

The analysis focused further on two major energy-related global crises: the 2008–2009 financial crisis and the COVID-19 pandemic. Machine learning models incorporating ERA5 reanalysis meteorological data were used to estimate expected tropoNO₂ concentrations under non-crisis scenarios. In 2009 and 2020, average annual tropoNO₂ concentrations decreased by 3% and 27%, respectively, compared to preceding years. In both cases, model predictions exceeded observed values, indicating reduced emissions.

These findings confirm the strong link between energy use and air quality, and underscore the utility of machine learning in disentangling the complex drivers of air pollution. This study highlights the importance of integrating meteorological and energy data to better understand spatiotemporal dynamics of NO₂ concentrations, with implications for evidence-based policy design and sustainable urban planning in cities like Santiago.

Resumen

Los cambios en los patrones de consumo energético están estrechamente vinculados a las variaciones en la calidad del aire. El dióxido de nitrógeno (NO₂), un contaminante atmosférico clave, representa riesgos significativos tanto para la salud humana como para el medioambiente. Este estudio analizó series temporales de NO₂ troposférico (tropoNO₂) sobre Santiago de Chile, desde 2006 hasta 2020, utilizando datos satelitales del Ozone Monitoring Instrument (OMI). Se encontraron correlaciones positivas significativas ($r > 0,8$) entre los niveles anuales de tropoNO₂ y diversos indicadores energéticos, incluidos el precio del petróleo crudo, el consumo primario de energía fósil y el uso de energía per cápita. Aunque los datos mensuales de luces nocturnas VIIRS DNB, también empleados como un proxy del consumo energético, no mostraron una correlación lineal significativa, el modelado dinámico empírico reveló una relación causal positiva con el tropoNO₂.

El análisis se centró además en dos grandes crisis globales relacionadas con la energía: la crisis financiera de 2008–2009 y la pandemia de COVID-19. Se aplicaron modelos de machine learning que incorporaron datos meteorológicos de reanálisis ERA5 para estimar las concentraciones esperadas de tropoNO₂ en escenarios sin crisis. En 2009 y 2020, las concentraciones anuales promedio de tropoNO₂ disminuyeron un 3% y un 27%, respectivamente, en comparación con los años anteriores. En ambos casos, las predicciones del modelo superaron los valores observados, lo que indicó una reducción en las emisiones.

Estos hallazgos confirman el fuerte vínculo entre el uso de energía y la calidad del aire, y destacan la utilidad del machine learning para desentrañar los complejos factores que impulsan la contaminación atmosférica. Este estudio resalta la importancia de integrar datos meteorológicos y energéticos para comprender mejor las dinámicas espacio-temporales de las concentraciones de NO₂, con implicancias para el diseño de políticas basadas en evidencia y la planificación urbana sostenible en ciudades como Santiago.

3.1. Introducción

A lo largo de la historia, la humanidad ha enfrentado múltiples crisis, cada una de las cuales ha puesto en evidencia las vulnerabilidades de los distintos sistemas que operan en la sociedad moderna y ha puesto a prueba su resiliencia (Notteboom et al., 2021). La crisis económica mundial de 2008/2009 redujo de manera significativa las actividades económicas (Squizzato et al., 2018), provocando una desaceleración de la economía global y contracciones en diversos sectores económicos (Arruti et al., 2011). En 2020, la pandemia de COVID-19 introdujo impactos sin precedentes en todas las esferas de la actividad humana (Notteboom et al., 2021). El virus se propagó globalmente, lo que llevó a muchos países a implementar severas restricciones para frenar su expansión. Estas incluyeron limitaciones estrictas a la movilidad de las personas, cierre de la mayoría de los espacios públicos y restricción de los viajes únicamente a desplazamientos laborales esenciales (Barre et al., 2021). No obstante, también se observaron efectos positivos: mejoras significativas en la calidad del aire, reducciones en el ruido y disminución de las emisiones de gases de efecto invernadero (Zambrano-Monserrate et al., 2020).

Por ejemplo, Squizzato et al. (2018) y Seo et al. (2018) demostraron que durante la crisis financiera/económica de 2009 hubo una influencia potencial de la recesión global en la reducción de material particulado (PM) y otros contaminantes gaseosos primarios en Nueva York (Estados Unidos) y Seúl (Corea del Sur), respectivamente. De forma similar, las medidas de confinamiento para controlar la pandemia en 2020 alteraron la vida cotidiana de los ciudadanos, modificando la calidad del aire en distintas ciudades (Dantas et al., 2020; Tobías et al., 2020). Durante ese año, se reportaron variaciones en las concentraciones de contaminantes atmosféricos en Europa (Muhammad et al., 2020; Tobías et al., 2020), Asia (Wang et al., 2020; Xu et al., 2020), África (Otmani et al., 2020), ciudades de Estados Unidos (Goldberg et al., 2020) y a escala global (Tang et al., 2021) como consecuencia de la drástica paralización de las actividades económicas y sociales. En América Latina, se han desarrollado estudios en Brasil (Dantas et al., 2020), Ecuador (Pacheco et al., 2020), Argentina (Bolaño-Ortiz et al., 2020), Colombia (Méndez-Espinosa et al., 2020), Perú (Velayarce et al., 2022) y Chile (Toro et al., 2021). Estos trabajos han mostrado que el NO_2 es el contaminante atmosférico que registra las mayores disminuciones en las ciudades que atravesaron periodos de recesión y/o restricción (Goldberg et al., 2020; Vîrghileanu et al., 2020). Este contaminante tiene una influencia sustancial sobre la salud humana (Grange et al., 2017). Las emisiones urbanas de NO_2 se asocian principalmente a la combustión de diésel y gasolina en el sector transporte (Vîrghileanu et al., 2020). El NO_2 presenta una vida fotoquímica corta, que varía entre dos y seis horas durante el día en verano y entre 12 y 24 horas en invierno (Volke et al., 2023). Esta corta vida, modulada en parte por factores atmosféricos como la temperatura y la radiación, junto con la naturaleza localizada de sus fuentes de emisión, hacen del NO_2 un excelente proxy para detectar reducciones en emisiones, tanto mediante mediciones de superficie como satelitales (Barre et al., 2020).

Son muchos los factores que influyen en la calidad del aire, incluyendo elementos naturales, económicos y energéticos (Li et al., 2019). En este sentido, la relación entre consumo energético y calidad del aire ha sido ampliamente explorada, vinculando el uso de energía con las concentraciones de las principales emisiones (Chen et al., 2018). Investigaciones en distintas regiones del mundo, como las de Zhu et al. (2014) en Beijing, Khan et al. (2016) en Pakistán y Alam et al. (2016) en Brasil, China, India e Indonesia, han mostrado que el consumo energético tiene un impacto significativo en la calidad del aire. Asimismo, la contaminación atmosférica está fuertemente influenciada por las condiciones meteorológicas, las cuales han sido señaladas en numerosos estudios como un factor que incidió en la reducción de los niveles de contaminación en diversas ciudades (Schiermeier, 2020; Jakob et al., 2022). Por ello, resulta fundamental separar el efecto meteorológico de los datos de calidad del aire para comprender los impactos reales de distintas acciones. Esto hace difícil entender si las crisis económicas resultan indirectamente en mejoras de las condiciones ambientales.

En este contexto, recientemente se han aplicado técnicas de normalización meteorológica para atribuir los cambios en las concentraciones de contaminantes a variaciones en las emisiones (Goldberg et al., 2020; Petetin et al., 2020; Barre et al., 2021). Estas técnicas se basan en algoritmos de machine learning (ML), los cuales aprenden las relaciones no lineales entre las variables de entrada y salida de los modelos (Grange y Carslaw, 2019). Dichos modelos formulan concentraciones de contaminantes en función de todos los parámetros de entrada, como variables meteorológicas y otras de carácter temporal, permitiendo construir modelos capaces de aprender la influencia de la meteorología en las concentraciones bajo un forzamiento promedio de emisiones que abarca el período de estudio (Lovric et al., 2022). De este modo, es posible estimar las concentraciones

que se habrían registrado sin los cambios de emisiones provocados por periodos de crisis (Petetin et al., 2020). Sin embargo, comprender la estructura causal de las variables ambientales sigue siendo un desafío, especialmente en sistemas dinámicos no lineales, donde los métodos tradicionales basados en correlaciones pueden resultar insuficientes. A ello se suma la limitada disponibilidad de datos históricos de monitoreo terrestre, lo que dificulta el análisis de escenarios generados durante estos periodos (Vu et al., 2019).

En este marco, el Empirical Dynamic Modeling (EDM) ofrece una alternativa poderosa para detectar causalidad a partir de series temporales, sin necesidad de relaciones funcionales predefinidas (Sugihara et al., 2012; Ushio et al., 2018). Técnicas como Convergent Cross Mapping (CCM) permiten inferir vínculos causales evaluando si la evolución temporal de una variable contiene información sobre otra. Asimismo, el enfoque S-map posibilita cuantificar la magnitud y dirección de las interacciones a lo largo del tiempo, revelando dinámicas dependientes del contexto (Sugihara, 1994; Wasserman et al., 2022). La integración de marcos de ML y EDM entrega una comprensión más amplia de cómo interactúan el consumo energético, la variabilidad meteorológica y las concentraciones de NO₂.

Dada la disponibilidad limitada de datos terrestres de calidad del aire a largo plazo en Chile, la Red de Monitoreo Automático de Contaminantes Atmosféricos (MACAM) se ha convertido en un recurso clave para el seguimiento de diversos contaminantes, incluido el NO₂. Esta red forma parte del Sistema Nacional de Calidad del Aire (SINCA, <https://sinca.mma.gob.cl/>), dependiente del Ministerio del Medio Ambiente de Chile. Diversos estudios se han basado en esta base de datos para examinar la dinámica de los contaminantes y su interacción con las condiciones ambientales locales (Parra et al., 2021; Toro et al., 2024). Sin embargo, solo 11 estaciones de monitoreo miden NO₂ y los registros de largo plazo son incompletos o carecen de cobertura espacial suficiente. Estas limitaciones suponen desafíos importantes para la gestión de la calidad del aire, generando vacíos críticos de información y restringiendo evaluaciones ambientales robustas.

En este contexto, las observaciones satelitales ofrecen alternativas valiosas para estudiar tendencias de largo plazo en las concentraciones de NO₂ a escalas tanto globales como locales. Numerosos estudios han demostrado el potencial de la teledetección para detectar patrones espacio-temporales de contaminación atmosférica (Miyazaki et al., 2017; Krotkov et al., 2016). Por ejemplo, investigaciones recientes han aprovechado el Tropospheric Monitoring Instrument (TROPOMI; Veeffkind et al., 2012), a bordo del satélite Sentinel-5 Precursor lanzado en octubre de 2017, para identificar reducciones de NO₂ durante los confinamientos por COVID-19 (e.g., Bauwens et al., 2020; Nakada y Urban, 2020). No obstante, su cobertura temporal relativamente corta limita su utilidad para establecer líneas base climatológicas robustas. Por el contrario, el Ozone Monitoring Instrument (OMI), operativo desde 2004, proporciona mediciones consistentes y de largo plazo de gases traza atmosféricos, incluido el NO₂ (Lamsal et al., 2021). Los datos OMI han sido ampliamente utilizados para analizar tendencias de contaminación, evaluar los efectos de factores meteorológicos y examinar los impactos de políticas de control de emisiones y de la actividad industrial (Krotkov et al., 2016; Bauwens et al., 2020; Singh et al., 2023). Por ejemplo, Krotkov et al. (2016) reportaron descensos en las concentraciones de NO₂ en América del Norte y Europa debido a regulaciones ambientales, mientras que se observaron aumentos en China e India, atribuidos a la rápida urbanización e industrialización. De forma similar, Jamali et al. (2020) utilizaron OMI para examinar patrones y tendencias globales de NO₂ troposférico entre 2005 y 2018, demostrando su efectividad para el monitoreo ambiental a largo plazo.

En este trabajo, utilizando datos OMI de NO₂ troposférico e indicadores de consumo energético, analizamos la correlación y causalidad entre estas variables para Santiago de Chile. Asimismo, aplicamos estimaciones normalizadas meteorológicamente mediante cinco métodos de machine learning, evaluando las diferencias en las concentraciones de NO₂ a lo largo del período de estudio. Los modelos se aplicaron para predecir los años 2009 y 2020, comparando los resultados con los años 2013, 2014 y 2018, con el fin de contrastar los efectos entre años de “crisis” y años “normales”.

3.2. Metodología

3.2.1 Área de estudio

La ciudad metropolitana de Santiago (33.5° S, 70.6° O), representada en la Figura 3.1, que abarca la capital de Chile, concentra el 40% de la población del país (7,4 millones de habitantes) (Toro et al., 2021). Asimismo, concentra una parte importante de la actividad económica, representando hasta un 45% del producto interno bruto nacional (OL, 2020). Santiago se ubica en un valle relativamente amplio y plano, a 500 m sobre el nivel

del mar. Está rodeada por cadenas montañosas, con la cordillera de los Andes al este y la cordillera de la Costa al oeste. La localización geográfica de Santiago, rodeada de montañas, genera un “efecto cuenco” que atrapa los contaminantes, exacerbando los problemas de calidad del aire, especialmente en invierno.

Durante los meses cálidos y secos de verano, la ciudad está expuesta a concentraciones relativamente altas de oxidantes secundarios, mientras que en invierno se enfrenta a elevadas concentraciones de material particulado y óxidos de nitrógeno. Representa además un polo económico con alta actividad industrial en la zona central de Chile. Como resultado, Santiago ha sido designada desde 1996 como zona de incumplimiento para PM10, CO, O₃ y como zona de incumplimiento “latente” para NO₂ (Toro et al., 2021).

El clima de Santiago es semiárido, con una precipitación media anual de 350 mm, concentrada en los meses de invierno (González-Rodríguez et al., 2021).




Figure 3.1. Área de estudio: Santiago Metropolitano (33,5°S, 70,6°O). El recuadro rojo está centrado sobre Santiago y delimita el área a partir de la cual se extrajeron los datos satelitales y de reanálisis utilizados en este estudio.

3.2.2 Marco metodológico

El procedimiento metodológico empleado para evaluar las fluctuaciones en las concentraciones de tropoNO₂ durante episodios críticos y su asociación con los índices de consumo energético se ilustra en el esquema presentado en la Figura 3.2 y se detalla exhaustivamente en la Sección 2.5. Este enfoque se basa principalmente en el análisis de extensas series temporales obtenidas a partir de observaciones satelitales, lo que permite evaluar el tropoNO₂ y compararlo con predicciones basadas en condiciones meteorológicas. De manera paralela, se investiga su correlación con los indicadores de consumo energético. Finalmente, se realiza un análisis causal entre las luces nocturnas (NL) y el tropoNO₂ mediante técnicas de Empirical Dynamic Modeling (EDM).

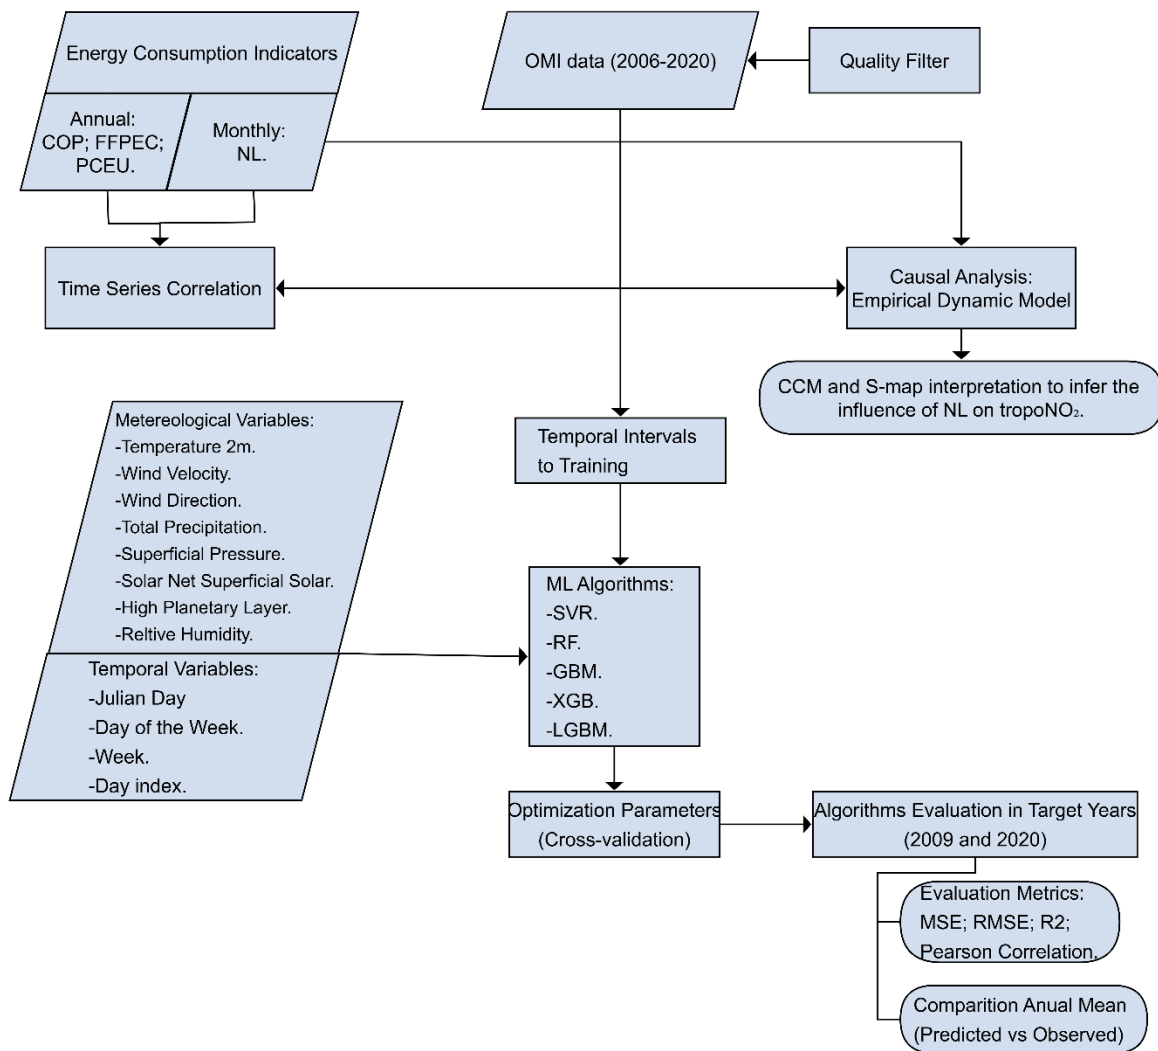


Fig. 3.2 Diagrama de flujo que muestra las principales etapas del método. Abreviaturas: Precio del Petróleo Crudo (COP), Consumo Primario de Energía Fósil (FFPEC), Consumo de Energía Per Cápita (PCEU), Luces Nocturnas (NL), Support Vector Regressor (SVR), Random Forest (RF), Gradient Boosting Machine (GBM), Extreme Gradient Boosting (XGB), Light Gradient Boosting Machine (LGBM).

3.2.3 Bases de datos satelitales y de reanálisis

OMI
 El Ozone Monitoring Instrument (OMI) está a bordo del satélite Aura (Levelt et al., 2006). OMI es un espectrómetro UV-VIS que mide los valores de la columna troposférica de NO₂. El manual de usuario en línea de la NASA para los productos de OMI (Giovanni, 2014) proporciona detalles sobre el filtrado de datos, la definición del análisis y los algoritmos del enfoque Differential Optical Absorption Spectroscopy (DOAS), así como los procedimientos de control de calidad para el filtrado y etiquetado de datos. Para este estudio, se utilizaron los promedios mensuales de los datos diarios del L3 tropospheric NO₂ OMI (OMNO2d) (Lamsal et al., 2021). Los datos de OMNO₂ se encuentran en el nivel L3, con una resolución espacial de 0.25° × 0.25° en una cuadrícula global. Además, se consideraron solo los píxeles con una fracción de nubosidad menor al 30%. La descarga de los datos se realizó a través de la plataforma Giovanni (<https://giovanni.gsfc.nasa.gov/>). Se recuperaron datos desde 2011 hasta 2020 para investigar una serie temporal extendida de NO₂ en el tiempo. Estos datos históricos se referencian como OMI en este estudio.

ERA5

Las variables meteorológicas utilizadas incluyen la altura de la capa límite, la temperatura del aire a 2 m sobre la superficie, la temperatura del punto de rocío a 2 m sobre la superficie, el componente del viento este a 10 m, el componente del viento norte a 10 m y la presión en superficie, que son comúnmente utilizadas en estudios cartográficos (Vitolo et al., 2020; Li et al., 2024).

Las covariables fueron obtenidas de los conjuntos de datos de reanálisis ERA5, con una resolución de $0.25^\circ \times 0.25^\circ$, y de los conjuntos de datos ERA5-Land (Pelosi et al., 2020), con una resolución de $0.1^\circ \times 0.1^\circ$. Todos los datos de ERA5 y ERA5-Land fueron descargados del Climate Data Store del Copernicus Climate Change Service (ERA5, 2019).

3.2.4 Indicadores de consumo energético

Los indicadores de consumo energético permiten analizar los sistemas energéticos a escalas tanto globales como regionales (Martins et al., 2019). En este estudio, se consideraron las siguientes variables: Precio del petróleo crudo (Crude Oil Price, COP), Consumo primario de energía fósil (Fossil Fuel Primary Energy Consumption, FFPEC), Consumo de energía per cápita (Per Capita Energy Use, PCEU). La relación entre las concentraciones de tropoNO₂ y estos indicadores energéticos fue evaluada mediante el coeficiente de correlación de Pearson (r), con el objetivo de determinar la asociación lineal entre el consumo de energía y la contaminación atmosférica.

Tabla 3.1. Lista de variables e indicadores de consumo energético.

Variable	Abreviatura	Unidad	Fuente
Precio del petróleo crudo	COP	Dólares estadounidenses por metro cúbico (\$)	<i>Statistical Review of World Energy (2024)</i>
Consumo primario de energía fósil	FFPEC	Teravatios-hora (TWh)	<i>Statistical Review of World Energy (2024)</i>
Consumo de energía per cápita	PCEU	Kilovatios-hora por persona (kWh)	<i>Statistical Review of World Energy (2024)</i>

3.2.5 Análisis de datos y validación

Para los datos OMI de Nivel 3, los píxeles dentro de las cuadrículas de $1^\circ \times 1^\circ$ fueron promediados para generar medias diarias que reflejan el promedio espacial de los píxeles válidos en la región de estudio. Solo se retuvieron los promedios diarios con un mínimo de cinco píxeles válidos por cuadrícula. Este umbral aseguró la calidad de los datos al excluir observaciones afectadas por anomalías de fila, contaminación excesiva por nubes o valores de Radiative Cloud Fraction (RCF) superiores a 0,3. Posteriormente, se calcularon promedios anuales de NO₂ troposférico (tropoNO₂) y se compararon con indicadores anuales de consumo energético utilizando el coeficiente de correlación de Pearson.

Mediante algoritmos de machine learning (ML) y a través de una metodología denominada normalización meteorológica, investigamos la reducción de NO₂ en Santiago de Chile, asociada a fenómenos socioeconómicos significativos como los ocurridos en 2009 y 2020. En este estudio se aplicaron cinco técnicas de aprendizaje automático: Support Vector Regression (SVR), Random Forest (RF), Gradient Boosting Machine (GBM), Extreme Gradient Boost (XGB) y Light Gradient Boosting Machine (LGBM). Siguiendo la recomendación de Kang et al. (2021), se probaron diversos algoritmos de ML y luego se describieron los datos predichos por los modelos con mejor desempeño. Además, se buscó demostrar que, independientemente del modelo utilizado, la metodología de normalización meteorológica permite evidenciar que las crisis afectaron los niveles de contaminación en Santiago de Chile. Cada técnica fue implementada mediante el paquete de Python “scikit-learn” (Pedregosa et al., 2011). Estos modelos de ML describen las relaciones entre los valores diarios de tropoNO₂ y sus variables predictoras (incluyendo variables temporales: mes (1–12), día del año (1–365), hora del día (0–23), y parámetros meteorológicos: temperatura a 2 m, velocidad y dirección del viento a 10 m, presión superficial, radiación solar neta en superficie, radiación solar descendente, humedad relativa y altura de la capa límite planetaria (PBL)) (véase Fig. 2). Siguiendo los postulados de Grange et al. (2018), Grange y Carslaw

(2019) y Petetin et al. (2020), se generó la variable de índice temporal (desde 0 para el 1 de enero de 2013 hasta 2669 para el 23 de abril de 2020). Este índice permitió limitar posibles problemas relacionados con la presencia de tendencias en la serie temporal de NO₂.

Para estimar la incertidumbre y robustez del modelo, se realizaron cinco evaluaciones en subperíodos: 2009 y 2020 (Test1 y Test2, años de crisis), y 2013, 2014 y 2018 (Test3–5, años de referencia). Cada modelo fue entrenado con los cuatro años previos, asegurando una ventana de entrenamiento consistente en todas las pruebas. Cabe destacar que investigaciones previas, como Petetin et al. (2020), no encontraron mejoras al extender los períodos de entrenamiento más allá de 4 años en metodologías de normalización meteorológica. Para el entrenamiento de 2013 no se usaron datos de 2009, y para el entrenamiento de 2009 fue necesario incluir datos de 2010, dado que nuestra serie temporal comienza en 2006. En todos los entrenamientos se establecieron umbrales de disponibilidad mínima de datos en el área de estudio para cada captura diaria, exigiendo que al menos el 50% de los píxeles fueran válidos para el promedio. El desempeño de los modelos se evaluó mediante Error Cuadrático Medio (MSE), Raíz del Error Cuadrático Medio (RMSE), correlación de Pearson (r) y R^2 . Los modelos de ML incluyen diversos hiperparámetros que deben ajustarse; para ello, se aplicó validación cruzada con cinco particiones. Más detalles sobre los modelos y el proceso de optimización se incluyen en el material suplementario.

Se replicó el procedimiento anterior utilizando promedios semanales de los datos OMI. Dado que las mediciones satelitales pueden presentar alta incertidumbre debido a factores meteorológicos (Barre et al., 2021), se espera que las predicciones de NO₂ promediadas en períodos mayores a un día presenten menores incertidumbres gracias a compensaciones de error (Petetin et al., 2020). Se estableció un umbral de al menos 5 días de datos disponibles para calcular el promedio semanal.

Para explorar más a fondo los impulsores de la variabilidad del tropoNO₂, se llevó a cabo un análisis de causalidad mediante técnicas de Empirical Dynamic Modeling (EDM), centrándose en la influencia de las luces nocturnas (NL) como proxy del consumo energético (Letu et al., 2014; Elvidge et al., 2022). Debido a su resolución temporal mensual, los datos de NL cumplieron con la longitud mínima de serie temporal requerida para EDM, mientras que otros indicadores anuales no presentaban resolución suficiente para este análisis. Las limitaciones de la capacidad de EDM al trabajar con pocos datos ya habían sido planteadas en investigaciones como Tian et al. (2024).

En particular, se utilizó el método Convergent Cross Mapping (CCM) (Sugihara et al., 2012) para inferir vínculos causales direccionales entre NL y tropoNO₂, evaluando si la dinámica del NO₂ podía ser reconstruida a partir de las series de NL. Adicionalmente, se aplicó el método S-map (Sugihara, 1994; Ushio et al., 2018) para examinar cómo la fuerza y dirección de esta relación variaban en el tiempo, capturando interacciones no lineales y dependientes del contexto. Este enfoque permitió investigar si las fluctuaciones en las luces nocturnas podían anticipar de manera confiable cambios en los niveles de NO₂ troposférico. Dadas las limitaciones de los métodos tradicionales basados en correlaciones, la inclusión de técnicas EDM refuerza la robustez de las inferencias causales y proporciona una visión complementaria sobre la relación dinámica entre la actividad humana y la calidad del aire. Más detalles sobre EDM se presentan en el material suplementario.

3.3. Resultados

3.3.1 Concentración anual de NO₂ troposférico durante las crisis de 2009 y 2020

Las concentraciones promedio anuales basadas en observaciones satelitales durante el período 2006–2020 se presentan en la Fig. 3.3A. Las concentraciones más altas y más bajas de NO₂ se observaron en 2019 y 2020, correspondientes a 3,95 Pmolec/cm² y 2,74 Pmolec/cm², respectivamente. La concentración anual promedio de NO₂ para todo el período fue de 3,36 Pmolec/cm².

Las concentraciones promedio de tropoNO₂ para los años 2009 y 2020 se muestran en la Fig. 3.3B, con valores de 2,89 Pmolec/cm² y 2,74 Pmolec/cm², respectivamente. En 2009, se registró una reducción del 3% en las concentraciones de tropoNO₂ en el área de estudio en comparación con el año anterior, y una reducción del 17% en comparación con el año siguiente. En 2020, se produjo una reducción significativa del 27% en las concentraciones de tropoNO₂ en comparación con el año anterior. Al comparar las concentraciones de estos años con el promedio de todo el período de estudio (véase Fig. 3.3), se observa que ambos años presentaron un valor anual promedio inferior al promedio del período en un 14% y un 19%, para 2009 y 2020, respectivamente.

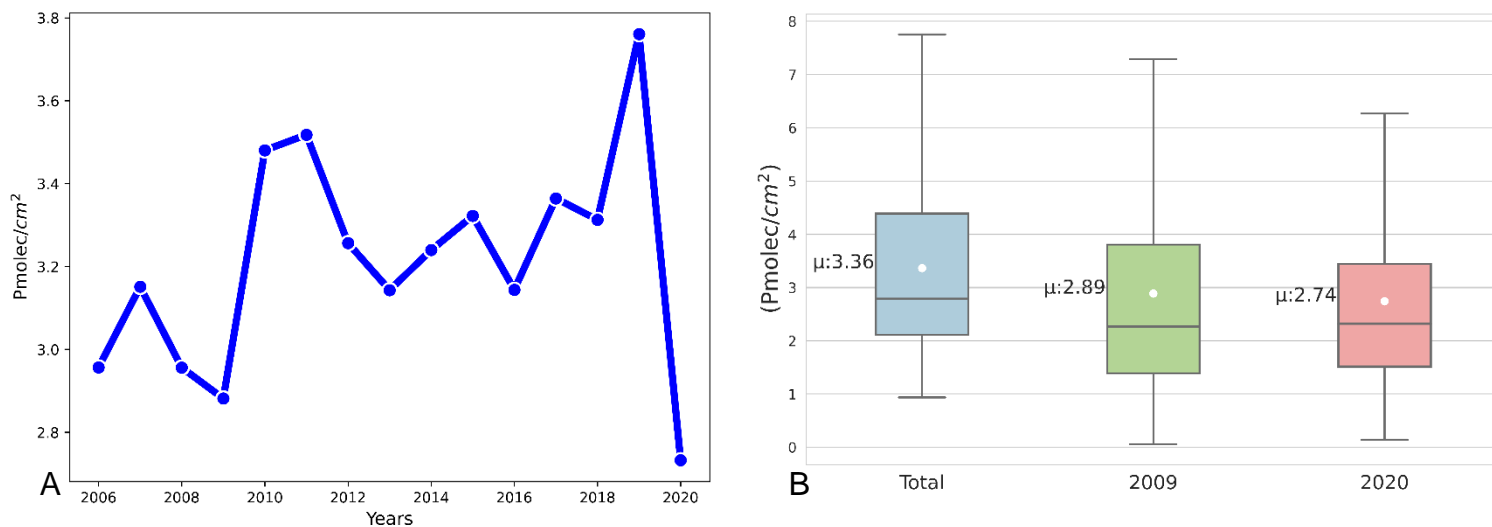


Fig. 3.3 A - Serie temporal de las concentraciones anuales promedio de NO₂ troposférico (2006–2020); B – Diagrama de cajas que muestra la distribución de las concentraciones diarias de NO₂ para toda la serie (2006–2020) y para los años de crisis globales que impactaron en la energía (2009 y 2020).

3.3.2. Modelos de normalización meteorológica

La Tabla 3.2 muestra los promedios de los datos observados y pronosticados para los años de crisis y años normales, utilizando datos diarios y semanales. Además, la Tabla S1 detalla los indicadores de desempeño de los algoritmos de aprendizaje automático (ML) en relación con las observaciones de OMI (diarias y semanales), incluyendo métricas como el Error Cuadrático Medio (MSE), la Raíz del Error Cuadrático Medio (RMSE), el coeficiente de correlación de Pearson (r) y el Coeficiente de Determinación (R^2).

Los resultados se presentan tanto para los conjuntos de datos de entrenamiento (los 4 años previos al año objetivo, donde los modelos fueron ajustados) como para los conjuntos de prueba (año objetivo). Las estadísticas para los conjuntos de entrenamiento y prueba muestran resultados similares, con valores significativos de MSE y RMSE y correlaciones entre 0.4 y 0.5 en la mayoría de los casos.

Tabla 3.2: Comparación de las concentraciones promedio anuales de NO₂ (Pmolec/cm²) observadas y obtenidas mediante la técnica de normalización meteorológica.

Year	Observado	SVR	RF	GBM	XGB	LGBM
2009	2.88	3.11	3.24	3.06	3.07	3.23
2013	3.15	2.78	3.08	3.09	3.36	3.18
2014	3.25	2.66	3.21	3.20	3.10	3.18
2018	3.32	3.82	3.88	3.57	3.57	3.46
2020	2.75	3.41	3.93	3.60	3.45	3.53

Al considerar los modelos entrenados con datos diarios, en los años de crisis, los promedios de los datos predichos fueron mayores que los observados por OMI en todos los modelos. Para 2009, las diferencias fueron de 7.4%, 11%, 5.9%, 6.2% y 10.8% para SVR, RF, GBM, XGB y LGBM, respectivamente. En 2020, los valores obtenidos por los modelos fueron significativamente superiores a los observados, con diferencias del 19.4%, 30%, 23.6%, 20.3% y 22.1%, respectivamente.

Por otro lado, en los años normales, los promedios de los datos predichos por los modelos fueron a veces

inferiores y otras veces superiores a los valores observados. En 2013, los promedios de los datos predichos fueron inferiores en 13%, 2.3% y 11.9% para SVR, RF y GBM, respectivamente, y superiores en 6.2% y 1% para XGB y LGBM, respectivamente. En 2014, los valores predichos fueron menores que los observados por OMI en 22.2%, 1.2%, 1.6%, 4.8% y 2.2% para SVR, RF, GBM, XGB y LGBM, respectivamente. Finalmente, en 2018, los valores predichos fueron mayores que los observados en 13%, 14.4%, 7%, 7% y 4% para SVR, RF, GBM, XGB y LGBM, respectivamente.

En los años normales, el modelo que mostró mejor desempeño fue SVR, con las siguientes métricas: 4.36 (MSE), 2.09 (RMSE), 0.25 (R^2), y 0.53 (r) para 2013; 5.42 (MSE), 2.32 (RMSE), 0.25 (R^2), y 0.55 (r) para 2014; 3.93 (MSE), 1.98 (RMSE), 0.32 (R^2), y 0.58 (r) para 2018. Excepto en 2018, el promedio de los datos predichos mostró valores inferiores a los observados por OMI.

En los años de crisis, el modelo con mejor desempeño en 2009 fue GBM, con valores de 4.1 (MSE), 2.03 (RMSE), 0.23 (R^2), y 0.49 (r), mientras que en 2020, el mejor modelo fue SVR, con valores de 3.46 (MSE), 1.86 (RMSE), 0.02 (R^2), y 0.48 (r).

Para los algoritmos entrenados y evaluados con datos de OMI promediados semanalmente, en los años de crisis, los algoritmos mostraron un peor desempeño en comparación con los años normales. Las estadísticas para el modelo con mejor desempeño (SVR) en los años de crisis fueron: 1.67 (MSE), 1.3 (RMSE), 0.53 (R^2), y 0.73 (r) para 2009; 2.71 (MSE), 1.65 (RMSE), 0.21 (R^2), y 0.6 (r) para 2020. Mientras que, en los años normales, los algoritmos con mejor desempeño presentaron las siguientes estadísticas: 0.76 (MSE), 0.87 (RMSE), 0.67 (R^2), y 0.84 (r) para 2013; 1.36 (MSE), 1.17 (RMSE), 0.55 (R^2), y 0.76 (r) para 2014; 0.75 (MSE), 0.86 (RMSE), 0.71 (R^2), y 0.84 (r) para 2018. Los promedios de los valores predichos fueron muy similares a los observados por OMI, con diferencias entre 1% y 2%, excepto en 2020, donde se registró una diferencia del 25%.

La Figura 3.4 proporciona una visualización del comportamiento de los datos observados y predichos para los años analizados, considerando el algoritmo con mejor desempeño en cada caso. En los años normales, los datos predichos siguen la variabilidad observada en los datos de OMI, aunque con ciertas diferencias, presentando valores tanto superiores como inferiores a las observaciones. Los valores promedio de los datos predichos fueron menores que los observados.

En 2009 y 2020, las predicciones muestran valores más altos que las observaciones, siendo particularmente significativo en 2020. No obstante, en términos generales, el modelo logra seguir el comportamiento de las variaciones de NO_2 durante estos años.

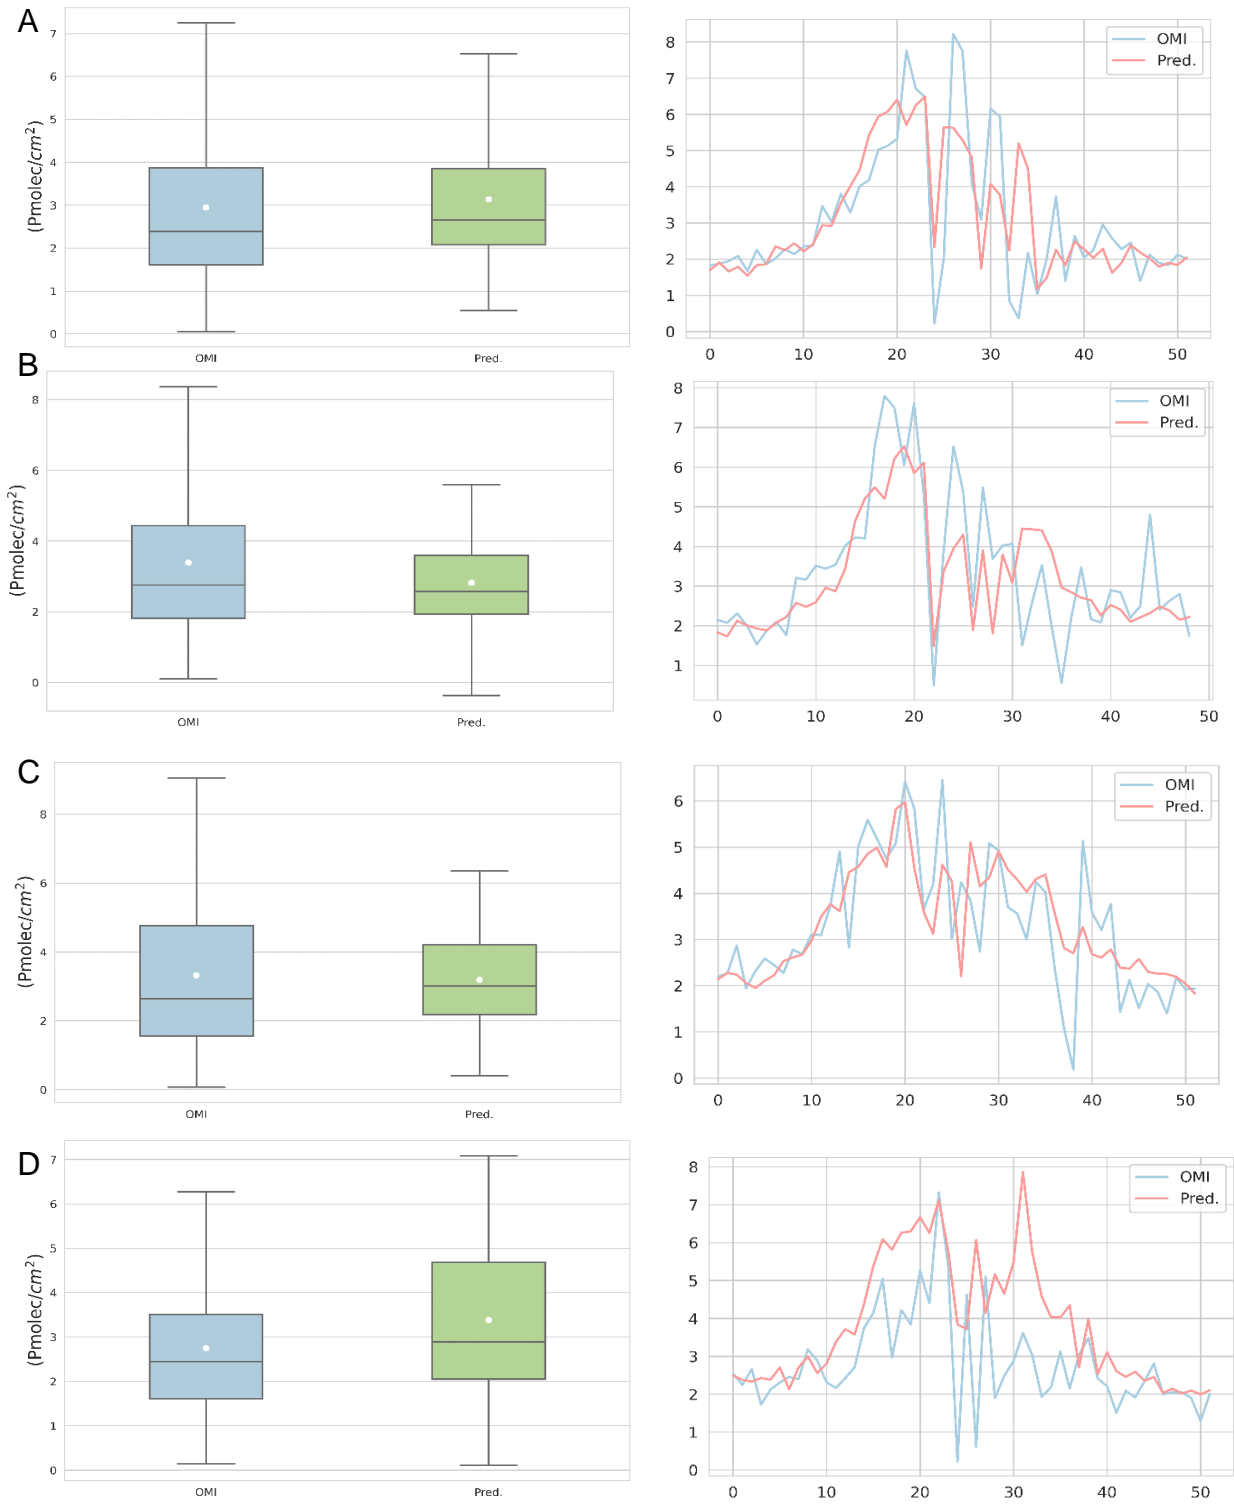


Fig. 3.4. Datos OMI frente a datos previstos. A- 2009; B- 2014; C- 2018; D- 2020.

3.3.3 Correlación con los Indicadores de Consumo Energético

En la Figura 3.5, se comparan los promedios anuales de los distintos indicadores energéticos utilizados con los promedios anuales de tropoNO_2 .




Figura 3.5. Comparación de series temporales de promedios anuales de tropoNO_2 (2006–2020) vs A – Precio del Petróleo Crudo; B – Consumo Primario de Energía Fósil; C – Consumo de Energía Per Cápita, y promedios mensuales de tropoNO_2 (2014–2020) vs D – Luces Nocturnas.

Para las series temporales anuales (Fig. 3.5A, 3.5B y 3.5C), se observan trayectorias similares entre tropoNO_2 y los indicadores energéticos, particularmente con FFPEC y PCEU. Estos dos indicadores muestran una tendencia ascendente constante a lo largo de los años, a diferencia del COP, que presenta una mayor variabilidad en comparación con tropoNO_2 . Las tres series exhiben descensos notables durante los años de crisis de 2009 y 2020, en relación con sus años precedentes.

En el caso del gráfico tropoNO_2 vs. NL (Fig. 3.5D), esta comparación se basa en una resolución temporal más alta (mensual), lo que permite identificar patrones estacionales. tropoNO_2 muestra un ciclo estacional claro, con picos pronunciados durante ciertos meses del año (invierno en el hemisferio sur) y mínimos recurrentes (verano en el hemisferio sur). En contraste, NL exhibe una tendencia más estable y con un incremento sostenido en el tiempo, con una variabilidad estacional menos marcada.

La Tabla 3 presenta la matriz de correlación convencional, que destaca la fuerza y magnitud de las asociaciones entre las variables. Los resultados revelan una correlación fuerte y positiva entre los indicadores energéticos anuales y tropoNO_2 , con coeficientes de correlación que van de 0.67 a 0.78. En contraste, no se observa una correlación significativa o directa mes a mes entre NL y tropoNO_2 , lo que sugiere una relación más compleja entre estas dos variables. Esta complejidad probablemente está influenciada por factores adicionales que

afectan los niveles de tropoNO₂, como las condiciones meteorológicas. Para comprender mejor esta relación, incorporamos un análisis de causalidad utilizando los métodos CCM y S-map, proporcionando una interpretación más integral de las interacciones dinámicas entre NL y tropoNO₂ en Santiago.

Tabla 3.3.: Matriz de correlación de los promedios anuales de tropoNO₂ (2006-2020) vs: Precio del petróleo crudo (Crude Oil Price, COP), Consumo primario de energía fósil (Fossil Fuel Primary Energy Consumption, FFPEC), Consumo de energía per cápita (Per Capita Energy Use, PCEU), Luz Nocturna (NL).

	tropoNO2
COP	0.73
FFPEC	0.78
PCEU	0.67
NL	-0.21

3.3.4 Análisis de causalidad entre NL y tropoNO₂

Para explorar más a fondo la relación entre las luces nocturnas (NL) y el dióxido de nitrógeno troposférico (tropoNO₂), realizamos un análisis de causalidad no lineal utilizando las técnicas de Convergent Cross Mapping (CCM) y S-Map. Si bien los enfoques tradicionales de correlación entregaron una visión limitada de las interacciones mes a mes entre estas variables, en particular debido a la influencia de factores externos como las condiciones meteorológicas, el uso del modelado dinámico empírico (EDM) permite detectar dependencias direccionales y potencialmente asimétricas. Esta sección presenta los resultados del análisis de causalidad, con el objetivo de determinar si las variaciones en la intensidad de las luces nocturnas pueden predecir o ser predichas por los cambios en las concentraciones de tropoNO₂ en el área metropolitana de Santiago.




Figura 3.6. Análisis de causalidad y fuerza de interacción entre la radiación promedio de luces nocturnas (NL) y las concentraciones de dióxido de nitrógeno troposférico (tropoNO₂) en Santiago. (Izquierda) Resultados de Convergent Cross Mapping (CCM) que muestran una habilidad de mapeo cruzado positiva y creciente (ρ) desde NL hacia tropoNO₂ a medida que aumenta el tamaño de la librería. (Derecha) Análisis S-Map que muestra la variación temporal en la fuerza de interacción de NL sobre tropoNO₂ (línea roja), con la fuerza de interacción promedio representada por la línea discontinua.

El panel izquierdo de la Figura 3.6 presenta los resultados del análisis de Convergent Cross Mapping (CCM), realizado utilizando una dimensión de incrustación óptima (E) de 7 y un rezago de predicción (T_p) de 0, lo que indica que la causalidad se evalúa sin un retraso temporal (es decir, con un efecto inmediato). La curva muestra una clara tendencia ascendente a medida que aumenta el tamaño de la librería, alcanzando un valor de correlación de aproximadamente $\rho \approx 0.5$ para librerías más grandes (es decir, con más puntos de datos).

muestreados aleatoriamente). Este patrón creciente y convergente proporciona una fuerte evidencia de una influencia causal de las luces nocturnas (NL) sobre las concentraciones de NO₂ troposférico.

En concordancia con esto, el panel derecho de la Figura 6 muestra el análisis S-Map. A diferencia del CCM, que captura la causalidad promedio en el tiempo, el enfoque S-Map revela cómo la fuerza de la influencia de NL sobre tropoNO₂ varía dinámicamente. La fuerza de interacción fluctúa entre ~0.3 y ~0.7, con picos pronunciados en momentos específicos. La línea azul discontinua representa la fuerza de interacción promedio (~0.42), que se alinea estrechamente con el resultado del CCM ($\rho \approx 0.5$). En conjunto, estos hallazgos respaldan la presencia de una señal causal significativa, aunque temporalmente variable, de NL hacia tropoNO₂.

3.4. Discusión

3.4.1. Correlaciones y análisis de causalidad entre los indicadores energéticos y el tropoNO₂

Como se muestra en la **Figura 3**, las observaciones satelitales de tropoNO₂ indican descensos en las concentraciones de este contaminante durante años emblemáticos como 2009 y 2020, cuando ocurrieron crisis económicas y sociales significativas. La reducción en los niveles de tropoNO₂ obtenida a partir de OMI se alinea con la disminución de varios contaminantes atmosféricos registrados mediante monitoreo in situ en diversas regiones del mundo durante la crisis económica de 2009 (Monteiro et al., 2018; Seo et al., 2018), y más evidentemente durante la crisis provocada por la pandemia de COVID-19 (Collivignarelli et al., 2020; Liu et al., 2022; Toro et al., 2021). Cabe destacar que este resultado contribuye a establecer la utilidad de las estimaciones satelitales para la calidad del aire urbano, tal como ha sido propuesto en múltiples estudios basados en datos satelitales (Ma et al., 2019; Barré et al., 2021; Bauwens et al., 2020). Asimismo, disponer de fuentes satelitales para las estimaciones de calidad del aire ayuda a entregar mayor certeza a la evidencia encontrada con mediciones terrestres.

Las correlaciones obtenidas entre las variables energéticas analizadas y los valores de NO₂ troposférico complementan los hallazgos de estudios como los de Khan et al. (2016) y Wang et al. (2005), que han propuesto una correlación positiva significativa entre el consumo de energía y la contaminación del aire. En línea con Ali et al. (2023), nuestros resultados refuerzan que mayores niveles de consumo energético, especialmente desde fuentes no renovables, tienden a intensificar la contaminación atmosférica, mientras que las transiciones hacia energías renovables pueden contribuir a mitigar las emisiones. Aunque nuestro estudio se centra en el tropoNO₂ y Ali et al. (2023) analizaron el CO₂ como principal contaminante, ambos trabajos convergen en destacar el fuerte vínculo entre los sistemas energéticos y la contaminación atmosférica en Sudamérica, tomando a Santiago, la capital de Chile, como área de estudio. Además, nuestros hallazgos sugieren que la implementación de medidas orientadas a reducir la movilidad poblacional o el consumo energético total —como fomentar el teletrabajo, mejorar la eficiencia del transporte público e incentivar prácticas de ahorro energético— podría tener un impacto tangible en la reducción de los niveles de contaminantes, particularmente en contextos urbanos donde las actividades antropogénicas son los principales impulsores de la degradación de la calidad del aire.

Además de los análisis de correlación lineal, incorporamos un análisis de causalidad no lineal mediante técnicas de Empirical Dynamic Modeling (EDM), específicamente con los métodos CCM y S-Map, para profundizar en la relación entre NL y tropoNO₂. Este enfoque fue motivado por la ausencia de correlaciones lineales significativas mes a mes entre estas variables, lo que sugiere que las métricas tradicionales no capturan plenamente sus interacciones dinámicas y potencialmente no lineales. El EDM es particularmente adecuado para analizar sistemas complejos con variables interdependientes y relaciones que varían en el tiempo, ya que no depende de supuestos de estacionariedad ni linealidad (Sugihara et al., 2012). Los resultados del CCM indican una habilidad de mapeo cruzado convergente y positiva, sugiriendo una influencia causal desde NL hacia tropoNO₂. Este hallazgo fue reforzado por el análisis S-Map, que reveló una interacción de fuerza moderada y variable en el tiempo entre ambas variables. En conjunto, estos resultados sugieren que las NL, usadas como un proxy de consumo energético, ejercen una influencia medible y dinámica sobre las concentraciones locales de tropoNO₂, consistente con las relaciones causales bidireccionales entre consumo energético y contaminación reportadas por Ali et al. (2023).

Los métodos EDM requieren series temporales relativamente densas y continuas para garantizar robustez en la estimación de atractores dinámicos, lo cual no fue factible con datos anuales o series con grandes vacíos temporales (Deyle et al., 2016; Ye et al., 2015). A pesar de estas limitaciones, el uso de EDM en este estudio ofreció un complemento valioso a los enfoques basados en correlaciones y regresiones, proporcionando una

comprensión más profunda de las relaciones dinámicas entre la actividad humana y la contaminación atmosférica. Esto resalta la necesidad de enfoques multimétodo en estudios de calidad del aire urbano, especialmente en regiones con limitaciones de datos, donde los mecanismos causales pueden no ser captados por análisis convencionales.

3.4.2. Normalización meteorológica y su papel en la explicación de la variabilidad del tropoNO₂

Los modelos utilizados para calcular estimaciones diarias normalizadas por condiciones meteorológicas identificaron de manera consistente valores más altos que los observados durante los años de crisis y valores más bajos o similares durante los años normales, en particular en los modelos con las mejores métricas de evaluación para cada período. Un patrón similar emergió en los modelos entrenados con datos semanales, donde el desempeño fue notablemente mejor en años normales, lo que indica que las variaciones en las concentraciones de tropoNO₂ están en gran medida impulsadas por condiciones meteorológicas bajo circunstancias típicas. Este patrón coincide con lo señalado por Petetin et al. (2020) y Barré et al. (2021), quienes demostraron que la normalización meteorológica puede aislar efectivamente la porción de variabilidad de NO₂ explicada por la dinámica atmosférica, permitiendo una atribución más clara a los impulsores antropogénicos. Sin embargo, este fenómeno fue menos evidente durante los años de crisis, especialmente en 2020, cuando los modelos tuvieron dificultades para reproducir los valores observados por OMI. Caídas similares en el rendimiento de los modelos durante eventos excepcionales también han sido reportadas por Grange et al. (2021) y Chang et al. (2022), quienes encontraron que reducciones abruptas en las emisiones (por ejemplo, durante los confinamientos por COVID-19) pueden interrumpir las relaciones típicas entre meteorología y contaminación que se encuentran implícitas en los modelos estadísticos. Estos resultados confirman que nuestros modelos de normalización meteorológica capturan de manera realista la variabilidad bajo escenarios dominados por el clima, y proporcionan un marco robusto para cuantificar cambios en los niveles de contaminación durante períodos excepcionales como la crisis económica de 2009 y la pandemia de COVID-19. Tal como se describió en la sección metodológica, diseñamos nuestro procedimiento de entrenamiento y ajuste de los modelos de normalización meteorológica para lograr el mejor rendimiento, probando varios de los modelos de machine learning más utilizados en estudios de contaminación atmosférica (Kang et al., 2021), además de implementar un paso de validación cruzada y búsqueda aleatoria en el espacio de hiperparámetros. En general, los resultados son satisfactorios, pero las métricas de evaluación de los modelos que usaron datos diarios de OMI indican que estos no describen adecuadamente las variaciones en esta escala temporal. Como señalan Petetin et al. (2020), esto puede deberse a que los datos satelitales están condicionados por la cobertura nubosa, la frecuencia de revisita y la calidad de las observaciones. Por lo tanto, fijar umbrales de calidad demasiado permisivos introduciría datos de baja calidad en el modelo, mientras que umbrales demasiado estrictos reducirían el volumen de datos disponibles para entrenar los algoritmos. Se sugiere que futuros trabajos optimicen dichos umbrales.

Si bien las mediciones de NO₂ en superficie no se traducen directamente en las columnas de NO₂ troposférico derivadas de satélites, ya que estas últimas representan el contenido integrado de NO₂ en toda la columna troposférica (Barré et al., 2021), se espera, como lo muestran estudios como el de Barré et al. (2021), que las reducciones observadas en columnas troposféricas derivadas de satélite difieran de las registradas en superficie. Otro factor relevante que pudo haber contribuido al menor desempeño de los modelos es la incertidumbre en los datos meteorológicos de ERA5. Como señala el estudio de Tang et al. (2021), la resolución espacial relativamente gruesa (31 km) de ERA5 puede capturar solo una parte de la variabilidad meteorológica presente en áreas urbanas. La integración de productos meteorológicos de mayor resolución, junto con variables socioeconómicas y energéticas, podría mejorar aún más el rendimiento predictivo y la relevancia para la formulación de políticas en investigaciones futuras.

3.5. Conclusión

Este estudio resalta el valor de las observaciones satelitales de NO₂ troposférico (tropoNO₂) para evaluar los impactos de las interrupciones económicas y sociales sobre la calidad del aire urbano. Las disminuciones observadas en NO₂ durante los años 2009 y 2020 se alinean con hallazgos globales en el contexto de la crisis económica y la pandemia de COVID-19, respectivamente, confirmando la sensibilidad del NO₂ derivado de satélite frente a cambios drásticos en la actividad antropogénica. Estos resultados refuerzan la utilidad de productos de teledetección, como OMI, para el monitoreo de tendencias de contaminación atmosférica a escala urbana.

El análisis de las variables energéticas reveló correlaciones positivas significativas entre los indicadores de consumo energético y los niveles anuales de tropoNO₂. Para el caso de las luces nocturnas (NL), que ofrecen mayor resolución temporal, las correlaciones lineales no lograron detectar relaciones consistentes. Para superar esta limitación, incorporamos un análisis mediante Empirical Dynamic Modeling (EDM)—específicamente Convergent Cross Mapping (CCM) y S-Map—lo que permitió detectar influencias causales no lineales y variables en el tiempo de NL sobre el tropoNO₂ en Santiago. El CCM reveló una habilidad de mapeo cruzado positiva y convergente, mientras que el S-Map identificó una variabilidad temporal moderada pero significativa en la fuerza de esta relación. Esto demostró que las NL, utilizadas como un proxy del consumo energético y la actividad económica, ejercen una influencia dinámica y medible sobre los niveles locales de contaminación, entregando información que no es captada por los métodos de correlación tradicionales.

Los modelos de normalización meteorológica, por su parte, permitieron separar las tendencias de contaminación asociadas a la variabilidad meteorológica de aquellas impulsadas por la actividad humana. Nuestros resultados muestran que, bajo condiciones normales, estos modelos representan de manera confiable la variabilidad del tropoNO₂. Sin embargo, durante períodos de crisis como 2020, el desempeño del modelo disminuyó, lo que sugiere que los cambios en los niveles de NO₂ en eventos excepcionales no pueden explicarse únicamente por factores meteorológicos. Esto respalda la hipótesis de que las reducciones significativas en los niveles de contaminantes durante esos años se debieron principalmente a la disminución de la actividad humana más que a anomalías meteorológicas.

En conjunto, este estudio demuestra que la combinación de observaciones satelitales, normalización meteorológica y herramientas analíticas avanzadas como EDM ofrece una comprensión más integral del nexo entre energía y contaminación del aire. Más allá de confirmar la sensibilidad del NO₂ urbano frente a los patrones de consumo energético, los resultados subrayan la importancia de considerar dinámicas no lineales y variables en el tiempo en las evaluaciones de calidad del aire. Asimismo, indican que medidas dirigidas a reducir la movilidad poblacional o el consumo energético total —como promover el teletrabajo, mejorar la eficiencia del transporte público e incentivar prácticas de ahorro energético— pueden contribuir significativamente a mitigar la contaminación, especialmente en áreas urbanas donde las actividades antropogénicas son las principales fuentes. Este enfoque integrador puede orientar a los responsables de políticas en el desarrollo de estrategias de transición energética que maximicen las mejoras en la calidad del aire, así como en el diseño de sistemas de monitoreo adaptativos capaces de responder eficazmente ante interrupciones sociales o económicas abruptas.

Referencias

- Akadiri, S. Saint, Bekun, F. V., & Sarkodie, S. A. (2019). Contemporaneous interaction between energy consumption, economic growth and environmental sustainability in South Africa: What drives what? *Science of The Total Environment*, 686, 468–475. <https://doi.org/10.1016/J.SCITOTENV.2019.05.421>
- Alam, M. M., Murad, M. W., Noman, A. H. M., & Ozturk, I. (2016). Relationships among carbon emissions, economic growth, energy consumption and population growth: Testing Environmental Kuznets Curve hypothesis for Brazil, China, India and Indonesia. *Ecological Indicators*, 70, 466–479. <https://doi.org/10.1016/J.ECOLIND.2016.06.043>
- Barré, J., Petetin, H., Colette, A., Guevara, M., Peuch, V. H., Rouil, L., Engelen, R., Inness, A., Flemming, J., Pérez García-Pando, C., Bowdalo, D., Meleux, F., Geels, C., Christensen, J. H., Gauss, M., Benedictow, A., Tsyro, S., Friese, E., Struzewska, J., ... Kouznetsov, R. (2021). Estimating lockdown-induced European NO₂ changes using satellite and surface

observations and air quality models. *Atmospheric Chemistry and Physics*, 21(9), 7373–7394. <https://doi.org/10.5194/ACP-21-7373-2021>

Bauwens, M., Compernelle, S., Stavrakou, T., Müller, J. F., van Gent, J., Eskes, H., Levelt, P. F., van der A, R., Veefkind, J. P., Vlietink, J., Yu, H., & Zehner, C. (2020). Impact of Coronavirus Outbreak on NO₂ Pollution Assessed Using TROPOMI and OMI Observations. *Geophysical Research Letters*, 47(11), e2020GL087978. <https://doi.org/10.1029/2020GL087978>

Bolaño-Ortiz, T. R., Pascual-Flores, R. M., Puliafito, S. E., Camargo-Caicedo, Y., Berná-Peña, L. L., Ruggeri, M. F., Lopez-Noreña, A. I., Tames, M. F., & Cereceda-Balic, F. (2020). Spread of COVID-19, Meteorological Conditions and Air Quality in the City of Buenos Aires, Argentina: Two Facets Observed during Its Pandemic Lockdown. *Atmosphere* 2020, Vol. 11, Page 1045, 11(10), 1045. <https://doi.org/10.3390/ATMOS11101045>

Chen, H., Hao, Y., Li, J., & Song, X. (2018). The impact of environmental regulation, shadow economy, and corruption on environmental quality: Theory and empirical evidence from China. *Journal of Cleaner Production*, 195, 200–214. <https://doi.org/10.1016/J.JCLEPRO.2018.05.206>

Collivignarelli, M. C., Abbà, A., Bertanza, G., Pedrazzani, R., Ricciardi, P., & Carnevale Miino, M. (2020). Lockdown for CoViD-2019 in Milan: What are the effects on air quality? *Science of The Total Environment*, 732, 139280. <https://doi.org/10.1016/J.SCITOTENV.2020.139280>

Dantas, G., Siciliano, B., França, B. B., da Silva, C. M., & Arbilla, G. (2020). The impact of COVID-19 partial lockdown on the air quality of the city of Rio de Janeiro, Brazil. *Science of The Total Environment*, 729, 139085. <https://doi.org/10.1016/J.SCITOTENV.2020.139085>

Goldberg, D. L., Anenberg, S. C., Griffin, D., McLinden, C. A., Lu, Z., & Streets, D. G. (2020). Disentangling the Impact of the COVID-19 Lockdowns on Urban NO₂ From Natural Variability. *Geophysical Research Letters*, 47(17), e2020GL089269. <https://doi.org/10.1029/2020GL089269>

González-Rodríguez, L., de Oliveira, A. P., Rodríguez-López, L., Rosas, J., Contreras, D., & Baeza, A. C. (2021). A Study of UVER in Santiago, Chile Based on Long-Term In Situ Measurements (Five Years) and Empirical Modelling. *Energies* 2021, Vol. 14, Page 368, 14(2), 368. <https://doi.org/10.3390/EN14020368>

Grange, S. K., & Carslaw, D. C. (2019). Using meteorological normalisation to detect interventions in air quality time series. *Science of The Total Environment*, 653, 578–588. <https://doi.org/10.1016/J.SCITOTENV.2018.10.344>

Grange, S. K., Lewis, A. C., Moller, S. J., & Carslaw, D. C. (2017). Lower vehicular primary emissions of NO₂ in Europe than assumed in policy projections. *Nature Geoscience* 2017 10:12, 10(12), 914–918. <https://doi.org/10.1038/s41561-017-0009-0>

He, L., Zhong, Z., Yin, F., & Wang, D. (2018). Impact of Energy Consumption on Air Quality in Jiangsu Province of China. *Sustainability* 2018, Vol. 10, Page 94, 10(1), 94. <https://doi.org/10.3390/SU10010094>

Jakob, A., Hasibuan, S., & Fiantis, D. (2022). Empirical evidence shows that air quality changes during COVID-19 pandemic lockdown in Jakarta, Indonesia are due to seasonal variation, not restricted movements. *Environmental Research*, 208, 112391. <https://doi.org/10.1016/J.ENVRES.2021.112391>

Jamali, S., Klingmyr, D., & Tagesson, T. (2020). Global-Scale Patterns and Trends in Tropospheric NO₂ Concentrations, 2005–2018. *Remote Sensing* 2020, Vol. 12, Page 3526, 12(21), 3526. <https://doi.org/10.3390/RS12213526>

Khan, M. M., Zaman, K., Irfan, D., Awan, U., Ali, G., Kyophilavong, P., Shahbaz, M., & Naseem, I. (2016). Triangular relationship among energy consumption, air pollution and water resources in Pakistan. *Journal of Cleaner Production*, 112, 1375–1385. <https://doi.org/10.1016/J.JCLEPRO.2015.01.094>

Krotkov, N. A., McLinden, C. A., Li, C., Lamsal, L. N., Celarier, E. A., Marchenko, S. V., Swartz, W. H., Bucseles, E. J., Joiner, J., Duncan, B. N., Folkert Boersma, K., Pepijn Veefkind, J., Levelt, P. F., Fioletov, V. E., Dickerson, R. R., He, H., Lu, Z., & Streets, D. G. (2016). Aura OMI observations of regional SO₂ and NO₂ pollution changes from 2005 to 2015. *Atmospheric Chemistry and Physics*, 16(7), 4605–4629. <https://doi.org/10.5194/ACP-16-4605-2016>

Li, R., Wang, Z., Cui, L., Fu, H., Zhang, L., Kong, L., Chen, W., & Chen, J. (2019). Air pollution characteristics in China during 2015–2016: Spatiotemporal variations and key meteorological factors. *Science of The Total Environment*, 648, 902–915. <https://doi.org/10.1016/J.SCITOTENV.2018.08.181>

- Li, Z., Mu, Z., & Gao, R. (2024). Applicability of ERA5 Reanalysis Precipitation Data in Runoff Modeling in China's Ili River Basin. *Journal of Hydrologic Engineering*, 29(5), 04024036. <https://doi.org/10.1061/JHYEFF.HEENG-6161>
- Lovrić, M., Antunović, M., Šunić, I., Vuković, M., Kecorius, S., Kröll, M., Bešlić, I., Godec, R., Pehnec, G., Geiger, B. C., Grange, S. K., & Šimić, I. (2022). Machine Learning and Meteorological Normalization for Assessment of Particulate Matter Changes during the COVID-19 Lockdown in Zagreb, Croatia. *International Journal of Environmental Research and Public Health* 2022, Vol. 19, Page 6937, 19(11), 6937. <https://doi.org/10.3390/IJERPH19116937>
- Martins, F., Felgueiras, C., Smitkova, M., & Caetano, N. (2019). Analysis of Fossil Fuel Energy Consumption and Environmental Impacts in European Countries. *Energies* 2019, Vol. 12, Page 964, 12(6), 964. <https://doi.org/10.3390/EN12060964>
- Martins, F., Felgueiras, C., Smitkova, M., & Caetano, N. (2019). Analysis of Fossil Fuel Energy Consumption and Environmental Impacts in European Countries. *Energies* 2019, Vol. 12, Page 964, 12(6), 964. <https://doi.org/10.3390/EN12060964>
- Mendez-Espinosa, J. F., Rojas, N. Y., Vargas, J., Pachón, J. E., Belalcazar, L. C., & Ramírez, O. (2020). Air quality variations in Northern South America during the COVID-19 lockdown. *Science of The Total Environment*, 749, 141621. <https://doi.org/10.1016/J.SCITOTENV.2020.141621>
- Mendez-Espinosa, J. F., Rojas, N. Y., Vargas, J., Pachón, J. E., Belalcazar, L. C., & Ramírez, O. (2020). Air quality variations in Northern South America during the COVID-19 lockdown. *Science of The Total Environment*, 749, 141621. <https://doi.org/10.1016/J.SCITOTENV.2020.141621>
- Miyazaki, K., Eskes, H., Sudo, K., Folkert Boersma, K., Bowman, K., & Kanaya, Y. (2017). Decadal changes in global surface NO_x emissions from multi-constituent satellite data assimilation. *Atmospheric Chemistry and Physics*, 17(2), 807–837. <https://doi.org/10.5194/ACP-17-807-2017>
- Monteiro, A., Russo, M., Gama, C., Lopes, M., & Borrego, C. (2018). How economic crisis influence air quality over Portugal (Lisbon and Porto)? *Atmospheric Pollution Research*, 9(3), 439–445. <https://doi.org/10.1016/J.APR.2017.11.009>
- Muhammad, S., Long, X., & Salman, M. (2020). COVID-19 pandemic and environmental pollution: A blessing in disguise? *Science of The Total Environment*, 728, 138820. <https://doi.org/10.1016/J.SCITOTENV.2020.138820>
- N. Lamsal, L., A. Krotkov, N., Vasilkov, A., Marchenko, S., Qin, W., Fasnacht, Z., Joiner, J., Choi, S., Haffner, D., H. Swartz, W., Fisher, B., & Bucsela, E. (2021). Ozone Monitoring Instrument (OMI) Aura nitrogen dioxide standard product version 4.0 with improved surface and cloud treatments. *Atmospheric Measurement Techniques*, 14(1), 455–479. <https://doi.org/10.5194/AMT-14-455-2021>
- Nakada, L. Y. K., & Urban, R. C. (2020). COVID-19 pandemic: Impacts on the air quality during the partial lockdown in São Paulo state, Brazil. *Science of The Total Environment*, 730, 139087. <https://doi.org/10.1016/J.SCITOTENV.2020.139087>
- Notteboom, T., Pallis, T., & Rodrigue, J. P. (2021). Disruptions and resilience in global container shipping and ports: the COVID-19 pandemic versus the 2008–2009 financial crisis. *Maritime Economics & Logistics*, 23(2), 179. <https://doi.org/10.1057/S41278-020-00180-5>
- Otmani, A., Benchrif, A., Tahri, M., Bounakhla, M., Chakir, E. M., El Bouch, M., & Krombi, M. (2020). Impact of Covid-19 lockdown on PM₁₀, SO₂ and NO₂ concentrations in Salé City (Morocco). *Science of The Total Environment*, 735, 139541. <https://doi.org/10.1016/J.SCITOTENV.2020.139541>
- Pacheco, H., Díaz-López, S., Jarre, E., Pacheco, H., Méndez, W., & Zamora-Ledezma, E. (2020). NO₂ levels after the COVID-19 lockdown in Ecuador: A trade-off between environment and human health. *Urban Climate*, 34, 100674. <https://doi.org/10.1016/J.UCLIM.2020.100674>
- Parra, S., Bravo, M. A., Parra, S., & Bravo, M. A. (2021). IMPACT OF COVID-19 LOCKDOWN ON NO₂, NO_x, O₃ AND PM_{2.5} CONCENTRATIONS IN SANTIAGO DE CHILE. *Journal of the Chilean Chemical Society*, 66(3), 5259–5261. <https://doi.org/10.4067/S0717-97072021000305259>
- Pedregosa FABIANPEDREGOSA, F., Michel, V., Grisel OLIVIERGRISEL, O., Blondel, M., Prettenhofer, P., Weiss, R., Vanderplas, J., Cournapeau, D., Pedregosa, F., Varoquaux, G., Gramfort, A., Thirion, B., Grisel, O., Dubourg, V., Passos, A., Brucher, M., Perrot and Édouardand, M., Duchesnay, and Édouard, & Duchesnay EDOUARD DUCHESNAY, Fré. (2011).

- Scikit-learn: Machine Learning in Python Gaël Varoquaux Bertrand Thirion Vincent Dubourg Alexandre Passos PEDREGOSA, VAROQUAUX, GRAMFORT ET AL. Matthieu Perrot. *Journal of Machine Learning Research*, 12, 2825–2830. <http://scikit-learn.sourceforge.net>.
- Pelosi, A., Terribile, F., D'Urso, G., & Chirico, G. B. (2020). Comparison of ERA5-Land and UERRA MESCAN-SURFEX Reanalysis Data with Spatially Interpolated Weather Observations for the Regional Assessment of Reference Evapotranspiration. *Water* 2020, Vol. 12, Page 1669, 12(6), 1669. <https://doi.org/10.3390/W12061669>
- Petetin, H., Bowdalo, D., Soret, A., Guevara, M., Jorba, O., Serradell, K., & Pérez García-Pando, C. (2020). Meteorology-normalized impact of the COVID-19 lockdown upon NO₂ pollution in Spain. *Atmospheric Chemistry and Physics*, 20(18), 11119–11141. <https://doi.org/10.5194/ACP-20-11119-2020>
- Richard Toro, A., Tomás Claramunt, A., Fiorella González, V., Sebastián Ávila, G., & Manuel, A. L. G. (2024). Long-term assessment and acute air pollution events in a mega-industrial area in Central Chile. *Urban Climate*, 55, 101880. <https://doi.org/10.1016/J.UCLIM.2024.101880>
- Schiermeier, Q. (2020). Why pollution is plummeting in some cities - but not others. *Nature*, 580(7803), 313. <https://doi.org/10.1038/D41586-020-01049-6>
- Singh, N., Dey, S., & Knibbs, L. D. (2023). Spatio-temporal patterns of tropospheric NO₂ over India during 2005–2019. *Atmospheric Pollution Research*, 14(3), 101692. <https://doi.org/10.1016/J.APR.2023.101692>
- Squizzato, S., Masiol, M., Rich, D. Q., & Hopke, P. K. (2018). PM_{2.5} and gaseous pollutants in New York State during 2005–2016: Spatial variability, temporal trends, and economic influences. *Atmospheric Environment*, 183, 209–224. <https://doi.org/10.1016/J.ATMOENV.2018.03.045>
- Tang, R., Huang, X., Zhou, D., Wang, H., Xu, J., & Ding, A. (2021). Global air quality change during the COVID-19 pandemic: Regionally different ozone pollution responses COVID-19. *Atmospheric and Oceanic Science Letters*, 14(4), 100015. <https://doi.org/10.1016/J.AOSL.2020.100015>
- Tang, Y., Sun, T., Luo, Z., Omidvar, H., Theeuwes, N., Xie, X., Xiong, J., Yao, R., & Grimmond, S. (2021). Urban meteorological forcing data for building energy simulations. *Building and Environment*, 204, 108088. <https://doi.org/10.1016/J.BUILDENV.2021.108088>
- Tobías, A., Carnerero, C., Reche, C., Massagué, J., Via, M., Minguillón, M. C., Alastuey, A., & Querol, X. (2020). Changes in air quality during the lockdown in Barcelona (Spain) one month into the SARS-CoV-2 epidemic. *Science of The Total Environment*, 726, 138540. <https://doi.org/10.1016/J.SCITOTENV.2020.138540>
- Toro A., R., Catalán, F., Urdanivia, F. R., Rojas, J. P., Manzano, C. A., Seguel, R., Gallardo, L., Osses, M., Pantoja, N., & Leiva-Guzman, M. A. (2021). Air pollution and COVID-19 lockdown in a large South American city: Santiago Metropolitan Area, Chile. *Urban Climate*, 36, 100803. <https://doi.org/10.1016/J.UCLIM.2021.100803>
- Veefkind, J. P., Aben, I., McMullan, K., Förster, H., de Vries, J., Otter, G., Claas, J., Eskes, H. J., de Haan, J. F., Kleipool, Q., van Weele, M., Hasekamp, O., Hoogeveen, R., Landgraf, J., Snel, R., Tol, P., Ingmann, P., Voors, R., Kruizinga, B., ... Levelt, P. F. (2012). TROPOMI on the ESA Sentinel-5 Precursor: A GMES mission for global observations of the atmospheric composition for climate, air quality and ozone layer applications. *Remote Sensing of Environment*, 120, 70–83. <https://doi.org/10.1016/J.RSE.2011.09.027>
- Vîrghileanu, M., Săvulescu, I., Mihai, B. A., Nistor, C., & Dobre, R. (2020). Nitrogen Dioxide (NO₂) Pollution Monitoring with Sentinel-5P Satellite Imagery over Europe during the Coronavirus Pandemic Outbreak. *Remote Sensing* 2020, Vol. 12, Page 3575, 12(21), 3575. <https://doi.org/10.3390/RS12213575>
- Vitolo, C., Di Giuseppe, F., Barnard, C., Coughlan, R., San-Miguel-Ayanz, J., Libertá, G., & Krzeminski, B. (2020). ERA5-based global meteorological wildfire danger maps. *Scientific Data* 2020 7:1, 7(1), 1–11. <https://doi.org/10.1038/s41597-020-0554-z>
- Volke, M. I., Abarca-del-Rio, R., & Ulloa-Tesser, C. (2023). Impact of mobility restrictions on NO₂ concentrations in key Latin American cities during the first wave of the COVID-19 pandemic. *Urban Climate*, 48, 101412. <https://doi.org/10.1016/J.UCLIM.2023.101412>

Vu, B. N., Sánchez, O., Bi, J., Xiao, Q., Hansel, N. N., Checkley, W., Gonzales, G. F., Steenland, K., & Liu, Y. (2019). Developing an Advanced PM_{2.5} Exposure Model in Lima, Peru. *Remote Sensing* 2019, Vol. 11, Page 641, 11(6), 641. <https://doi.org/10.3390/RS11060641>

Wang, Y., Yuan, Y., Wang, Q., Liu, C. G., Zhi, Q., & Cao, J. (2020). Changes in air quality related to the control of coronavirus in China: Implications for traffic and industrial emissions. *Science of The Total Environment*, 731, 139133. <https://doi.org/10.1016/J.SCITOTENV.2020.139133>

Xu, K., Cui, K., Young, L. H., Hsieh, Y. K., Wang, Y. F., Zhang, J., & Wan, S. (2020). Impact of the COVID-19 Event on Air Quality in Central China. *Aerosol and Air Quality Research*, 20(5), 915–929. <https://doi.org/10.4209/AAQR.2020.04.0150>

Zhu, S., He, C., & Liu, Y. (2014). Going green or going away: Environmental regulation, economic geography and firms' strategies in China's pollution-intensive industries. *Geoforum*, 55, 53–65. <https://doi.org/10.1016/J.GEOFORUM.2014.05.004>

Capitulo 4:

Clustering Time Series Analysis of Tropospheric NO₂ and AOD Satellite Data in Global Megacities: Exploring Patterns Linked to Energy-Related Variables.

Capitulo basado en: Publicacion enviada

Clustering Time Series Analysis of Tropospheric NO₂ and AOD Satellite Data in Global Megacities: Exploring Patterns Linked to Energy-Related Variables.

Matias I. Volke^{a,*}, Lisdelys González-Rodríguez^{b,c}

^a Energy Doctoral Program, Faculty of Engineering, Universidad de Concepción, Concepción 4030000, Chile.

^b Facultad de Ingeniería y Negocios, Universidad de Las Américas, Sede Concepción, Concepción, Chile.

^c Centro de Modelación Ambiental y Dinámica de Sistemas (CEMADIS), Universidad de Las Américas, Santiago, Chile.

* Corresponding author. E-mail address: matiasvolke@udec.cl.

Abstract

Megacities, characterized by high population density and extensive industrial activities, are major contributors to global air pollution. To examine annual trends in tropospheric nitrogen dioxide (tropoNO₂) and aerosol optical depth (AOD) satellite observations were used. A total of 34 megacities were selected for analysis covering the period from 2005 to 2022. To assess the variability of tropoNO₂ and AOD were employing hierarchical analysis and non-negative matrix factorization. The relationship between air pollutants and energy socioeconomic/environmental indicators is examined, with a particular focus on periods of global financial crisis and the COVID-19 pandemic. The results indicate that tropoNO₂ exhibits stronger positive correlations with energy consumption indicators than AOD, particularly in developed cities. Cluster analysis revealed three primary response patterns among megacities during global crises: cities with minimal pollution variations, cities with moderate fluctuations, and cities with significant changes in emissions. AOD was found to be more stable in developed cities, suggesting better emission control and lower reliance on highly polluting energy sources. In contrast, developing cities showed greater fluctuations in AOD, reflecting their higher sensitivity to economic crises and weaker environmental regulations. However, tropoNO₂ exhibited more heterogeneous behavior, with developed cities predominantly grouped within the category of significant changes, indicating that their emissions are closely tied to motorized transportation. This study highlights the diverse trends in tropoNO₂ and AOD across megacities, driven by socioeconomic, environmental regulatory, and energy-related factors that influence air quality. The findings suggest that transport, electrification and energy efficiency improvements can mitigate pollution impacts. The methodology employed enables the identification of urban emission patterns and their link to economic stability, providing a foundation for environmental mitigation strategies and sustainable urban planning in megacities. By enhancing the understanding of tropoNO₂ and AOD trends, this study contributes to the development of healthier and more sustainable urban environments.

Resumen

Las megaciudades, caracterizadas por una alta densidad poblacional y una intensa actividad industrial, son grandes contribuyentes a la contaminación atmosférica global. Para examinar las tendencias anuales del dióxido de nitrógeno troposférico (tropoNO₂) y de la profundidad óptica de aerosoles (AOD, por sus siglas en inglés), se utilizaron observaciones satelitales. Un total de 34 megaciudades fueron seleccionadas para el análisis, abarcando el período 2005-2022. Para evaluar la variabilidad de tropoNO₂ y AOD se emplearon análisis jerárquicos y factorización matricial no negativa.

La relación entre contaminantes atmosféricos e indicadores energéticos, socioeconómicos y ambientales fue examinada, con especial énfasis en los períodos de la crisis financiera global y la pandemia de COVID-19. Los resultados indican que el tropoNO₂ presenta correlaciones positivas más fuertes con los indicadores de consumo energético que el AOD, particularmente en ciudades desarrolladas. El análisis de clúster reveló tres patrones de respuesta principales entre las megaciudades durante las crisis globales: ciudades con variaciones mínimas de contaminación, ciudades con fluctuaciones moderadas y ciudades con cambios significativos en las emisiones.

El AOD resultó ser más estable en las ciudades desarrolladas, lo que sugiere un mejor control de emisiones y una menor dependencia de fuentes de energía altamente contaminantes. En contraste, las ciudades en desarrollo mostraron mayores fluctuaciones en AOD, reflejando su mayor sensibilidad a las crisis económicas y una regulación ambiental más débil. Sin embargo, el tropoNO₂ exhibió un comportamiento más heterogéneo: las ciudades desarrolladas se agruparon predominantemente en la categoría de cambios significativos, lo que indica que sus emisiones están estrechamente ligadas al transporte motorizado.

Este estudio resalta las diversas tendencias de tropoNO₂ y AOD en las megaciudades, impulsadas por factores socioeconómicos, regulatorios y energéticos que influyen en la calidad del aire. Los hallazgos sugieren que el transporte, la electrificación y las mejoras en eficiencia energética pueden mitigar los impactos de la contaminación. La metodología utilizada permite identificar patrones de emisiones urbanas y su vínculo con la estabilidad económica, proporcionando una base para estrategias de mitigación ambiental y planificación urbana sostenible en megaciudades. Al mejorar la comprensión de las tendencias de tropoNO₂ y AOD, este estudio contribuye al desarrollo de entornos urbanos más saludables y sostenibles.

4.1. Introducción

El aumento global de la población urbana en las últimas décadas ha impulsado el crecimiento en el número de megaciudades, generalmente definidas como aquellas con poblaciones que superan los 10 millones de habitantes (Schneider et al., 2015). De este modo, las megaciudades se han convertido en centros globales de crecimiento poblacional, expansión urbana, producción de energía y demanda energética (Erbertseder et al., 2024). En consecuencia, se ha registrado un incremento en las emisiones de gases de efecto invernadero, contaminantes atmosféricos y sus precursores (Castells-Quintana & Wenban-Smith, 2020). Como resultado, la población mundial está cada vez más expuesta a mayores niveles de contaminación, lo que hace necesarias medidas urgentes de gestión de la calidad del aire y reducción de la polución (Reddington et al., 2021). Esta problemática es particularmente evidente en grandes centros urbanos, donde los niveles de contaminación superan las directrices de la OMS (Sannoh et al., 2024). Ello subraya la necesidad de estrategias integrales de control de la calidad del aire y de investigaciones continuas sobre contaminantes atmosféricos en entornos metropolitanos. La importancia crítica de la investigación en calidad del aire para la salud pública está marcando el camino hacia futuras indagaciones en entornos urbanos a escala mundial (Erbertseder et al., 2024; Georgoulis et al., 2019; Tang et al., 2021; Zhao et al., 2021).

La contaminación atmosférica constituye una amenaza significativa tanto para la salud pública como para el medioambiente, siendo el dióxido de nitrógeno troposférico (tropoNO_2) y los aerosoles dos de los principales contribuyentes. El tropoNO_2 , contaminante clave emitido principalmente en procesos de combustión, es un gas reactivo que desempeña un papel crucial en la formación de ozono troposférico (O_3) y de material particulado fino ($\text{PM}_{2.5}$) (Grange et al., 2017). Los aerosoles, cuantificados mediante la Profundidad Óptica de Aerosoles (AOD), constituyen un indicador indirecto de las concentraciones de $\text{PM}_{2.5}$. Respecto al tropoNO_2 , este contaminante tiene un impacto sustancial en la salud humana, tanto de manera directa, a través de la inhalación, como indirectamente, al actuar como precursor de contaminantes secundarios como O_3 y $\text{PM}_{2.5}$ (Grange et al., 2017). En áreas urbanas, las emisiones de tropoNO_2 están principalmente vinculadas a la combustión de diésel y gasolina en el sector transporte (Vîrghileanu et al., 2020). El tropoNO_2 presenta una vida media fotoquímica corta, que oscila entre dos y seis horas durante el día en verano y entre 12 y 24 horas en invierno (Laughner & Cohen, 2019). Esta corta duración favorece una fuerte correlación entre las concentraciones de tropoNO_2 y las emisiones locales de NO_x de origen antropogénico (Wang et al., 2019). Adicionalmente, el AOD derivado de satélites ha sido ampliamente utilizado como un proxy para estimar las concentraciones troposféricas de $\text{PM}_{2.5}$ (Hammer et al., 2020). El $\text{PM}_{2.5}$ se ha asociado con efectos adversos en la salud, que van desde consecuencias agudas a corto plazo hasta afecciones crónicas, incluyendo aumento de síntomas respiratorios, empeoramiento del asma, incremento de enfermedades cardiovasculares, reducción de la función pulmonar y una mayor mortalidad prematura por enfermedades cardíacas o pulmonares (Sun et al., 2020).

Estudios previos han documentado que las recesiones económicas y las medidas de confinamiento relacionadas con pandemias pueden alterar sustancialmente los patrones de contaminación atmosférica. Por ejemplo, Squizzato et al. (2018) y Seo et al. (2018) hallaron que la crisis financiera global de 2009 contribuyó a reducciones en el material particulado y en contaminantes gaseosos primarios en Nueva York (EE. UU.) y Seúl (Corea del Sur), respectivamente. De igual modo, las restricciones de movilidad impuestas durante la pandemia de COVID-19 en 2020 interrumpieron las actividades cotidianas e influyeron significativamente en la calidad del aire urbano (Dantas et al., 2020; Tobías et al., 2020). Numerosos estudios reportaron variaciones en las concentraciones de contaminantes atmosféricos durante la pandemia en Europa (Muhammad et al., 2020; Tobías et al., 2020), Asia (Wang et al., 2020; Xu et al., 2020), África (Otmani et al., 2020) y Estados Unidos (Goldberg et al., 2020). En América Latina, evidencias de Brasil, Ecuador, Argentina, Colombia, Perú y Chile (e.g., Bolaño-Ortiz et al., 2020; Méndez-Espinosa et al., 2020; Toro et al., 2021; Velayarce et al., 2022) muestran que el tropoNO_2 tiende a exhibir los descensos más pronunciados en ciudades sometidas a fases restrictivas o recesivas. La simultaneidad de estos descensos en contextos geográficos y climáticos diversos sugiere que las reducciones observadas en la contaminación se debieron principalmente a cambios en las actividades antropogénicas, en particular al consumo energético y la movilidad, más que a la variabilidad meteorológica local.

El monitoreo de la contaminación atmosférica mediante teledetección satelital ha demostrado ser una herramienta eficaz, especialmente para el mapeo a gran escala de asentamientos humanos como las megaciudades a escalas continentales y globales (Esch et al., 2017; Taubenböck et al., 2012). Se han realizado importantes esfuerzos de investigación para mejorar la comprensión de los impulsores e impactos de la urbanización y la contaminación atmosférica. Por ejemplo, Georgoulis et al. (2019) analizaron 21 años de datos

globales de tres sensores satelitales (GOME, SCIAMACHY, GOME-2), identificando cambios en las tendencias de tropoNO₂ en 29 megaciudades alrededor del mundo. Erbertseder et al. (2023) examinaron las tendencias de contaminación por tropoNO₂ en 30 megaciudades en relación con el crecimiento urbano, revelando un vínculo entre el nivel de ingreso económico y las tendencias de calidad del aire. Más recientemente, Erbertseder et al. (2024) analizaron las tendencias de tropoNO₂ en 38 megaciudades en relación con la expansión urbana, reportando un aumento anual promedio del 5,06% en tropoNO₂, junto con un crecimiento del 2,87% en las áreas urbanizadas.

La disponibilidad de datos de diversos satélites, como el Ozone Monitoring Instrument (OMI) y el Tropospheric Monitoring Instrument (TROPOMI), para determinar concentraciones de tropoNO₂ y AOD ha sido de vital importancia en los últimos años. Asimismo, el algoritmo MAIAC (Multi-Angle Implementation of Atmospheric Correction), utilizado para obtener AOD a partir de series temporales de mediciones MODIS (Moderate Resolution Imaging Spectroradiometer), ha demostrado una alta aplicabilidad en áreas urbanas (Prunet et al., 2020). Sensores satelitales como MODIS, a bordo de los satélites Terra y Aqua, proveen datos extensos de AOD. MODIS mide la reflectancia de la luz solar en la superficie terrestre y la atmósfera, permitiendo la estimación de propiedades de los aerosoles a gran escala. Además, las mediciones satelitales de AOD ofrecen amplia cobertura espacial y resultan cruciales para el monitoreo global de aerosoles. A diferencia de las mediciones in situ, las observaciones satelitales permiten una recopilación homogénea de datos y una grilla espacial consistente para la evaluación de concentraciones de contaminantes (Volke et al., 2023). Este enfoque ofrece la ventaja de cubrir áreas remotas e inaccesibles, proporcionando información valiosa tanto para evaluaciones globales como regionales de calidad del aire. En consecuencia, los datos satelitales constituyen una fuente fundamental de información, mejorando la comprensión de la exposición a contaminantes atmosféricos en ciudades densamente pobladas (Volke et al., 2023).

Diversos factores influyen en la calidad del aire, incluidos aspectos naturales, económicos y energéticos (Li et al., 2019). La relación entre consumo energético y calidad del aire ha sido ampliamente explorada, estableciéndose un vínculo entre el uso de energía y las concentraciones de emisiones principales (Chen et al., 2018). Estudios realizados en distintas regiones, como Beijing (Zhu et al., 2014), Pakistán (Khan et al., 2016) y en Brasil, China, India e Indonesia (Alam et al., 2016), han demostrado que el consumo energético impacta significativamente en la calidad del aire. A pesar de estos hallazgos, persiste una falta de investigaciones que vinculen y agrupen sistemáticamente ciudades en función de variables energéticas estrechamente relacionadas con la contaminación. En este contexto, comprender mejor la interacción entre la contaminación atmosférica y los sistemas energéticos en países y ciudades con distintos niveles de ingreso y matrices energéticas es crucial (Rentschler & Leonova, 2023). Las respuestas en calidad del aire observadas en países de altos ingresos pueden no ser directamente aplicables a países de bajos ingresos, donde las matrices energéticas difieren de manera significativa (Haakenstad et al., 2022). Es esencial asegurar que los esfuerzos de desarrollo futuro, particularmente en países de ingresos bajos y medios, no agraven la contaminación atmosférica y sus efectos adversos asociados (Rentschler et al., 2023). Se requiere un equilibrio que permita capturar las principales variaciones globales y las características vinculadas a estas diferencias, manteniendo un número mínimo de clústeres que preserve la capacidad de generalización. Se han aplicado diversas metodologías de agrupamiento, incluyendo clasificaciones basadas en indicadores estadísticos (Kovač-Andrić et al., 2010), análisis discriminante lineal (Joly & Peuch, 2012), análisis de componentes principales (Lau et al., 2009) y análisis jerárquico de clúster (Henne et al., 2010).

El presente estudio tiene como objetivo identificar patrones en la relación entre consumo energético y calidad del aire en megaciudades, utilizando tropoNO₂ y AOD como indicadores clave de contaminación atmosférica. Para lograrlo, se aplicaron la Factorización Matricial No Negativa (NMF) (Lee et al., 2009) y el Análisis Jerárquico de Clústeres (HC) a fin de explorar y clasificar patrones de calidad del aire. La combinación del análisis jerárquico con NMF permite organizar los sitios en un dendrograma a partir de factores extraídos de los datos, vinculándolos con variables energéticas. El HC fue preferido frente a técnicas no jerárquicas debido a su robustez y a la evaluación más objetiva de la asignación de clústeres a través del dendrograma resultante, especialmente al integrarse con NMF (Malley et al., 2014). Para garantizar la robustez y consistencia de los grupos identificados, también se compararon los resultados con técnicas alternativas de reducción de dimensionalidad, como el Análisis de Componentes Principales (PCA), y algoritmos de agrupamiento como K-means.

El análisis se llevó a cabo comparando las variaciones de tropoNO₂ y AOD durante años de crisis globales respecto de los valores promedio en años no críticos. Este enfoque fue seleccionado debido a las mejoras

significativas en calidad del aire y cambios en el consumo energético observados en áreas urbanas durante períodos de recesión económica (Zambrano-Monserrate & Ruano, 2020). Por ejemplo, los estudios de Squizzato et al. (2018) y Seo et al. (2018) mostraron que la crisis financiera global de 2009 probablemente contribuyó a reducciones en material particulado y contaminantes gaseosos primarios en Nueva York (EE. UU.) y Seúl (Corea del Sur). De manera similar, las medidas de confinamiento implementadas para controlar la propagación del COVID-19 en 2020 alteraron la vida cotidiana e impactaron de manera significativa en la calidad del aire urbano (Dantas et al., 2020; Tobías et al., 2020). Durante la pandemia se reportaron variaciones en las concentraciones de contaminantes atmosféricos en Europa (Tobías et al., 2020), Asia (Xu et al., 2020), África (Otmami et al., 2020), América Latina (Méndez-Espinosa et al., 2020; Toro A. et al., 2021), Estados Unidos (Goldberg et al., 2020) y a escala global (Tang et al., 2021). Nuestro objetivo es proporcionar una comprensión más profunda de las interacciones entre contaminación y consumo energético en entornos urbanos, analizando cómo los cambios en la calidad del aire se correlacionan con variaciones en el consumo de energía. Este enfoque busca identificar políticas efectivas de reducción de emisiones y apoyar la transición hacia sistemas energéticos más sostenibles.

El resto del artículo se estructura de la siguiente manera: la Sección 2 describe el área de estudio y los conjuntos de datos utilizados, seguida de una descripción detallada de la metodología. Las Secciones 3 y 4 presentan los resultados y la discusión, que incluyen hallazgos clave, limitaciones y perspectivas futuras. Finalmente, la Sección 5 presenta las conclusiones del estudio.

4.2. Metodología

4.2.1 Área de estudio

Nuestro estudio se centró en las principales megaciudades del mundo, y se descargaron datos correspondientes a las 100 megaciudades más grandes a nivel global, según la definición de las Naciones Unidas. El conjunto de datos se obtuvo de <https://population.un.org/wup/>. Se aplicó un criterio de filtrado para incluir únicamente ciudades con un área mayor a 100 km². Además, se estableció un máximo de dos ciudades por país. Este proceso de selección dio como resultado una lista final de 34 ciudades, las cuales se presentan en la Figura 4.1, con más detalles disponibles en la Tabla S4.1.

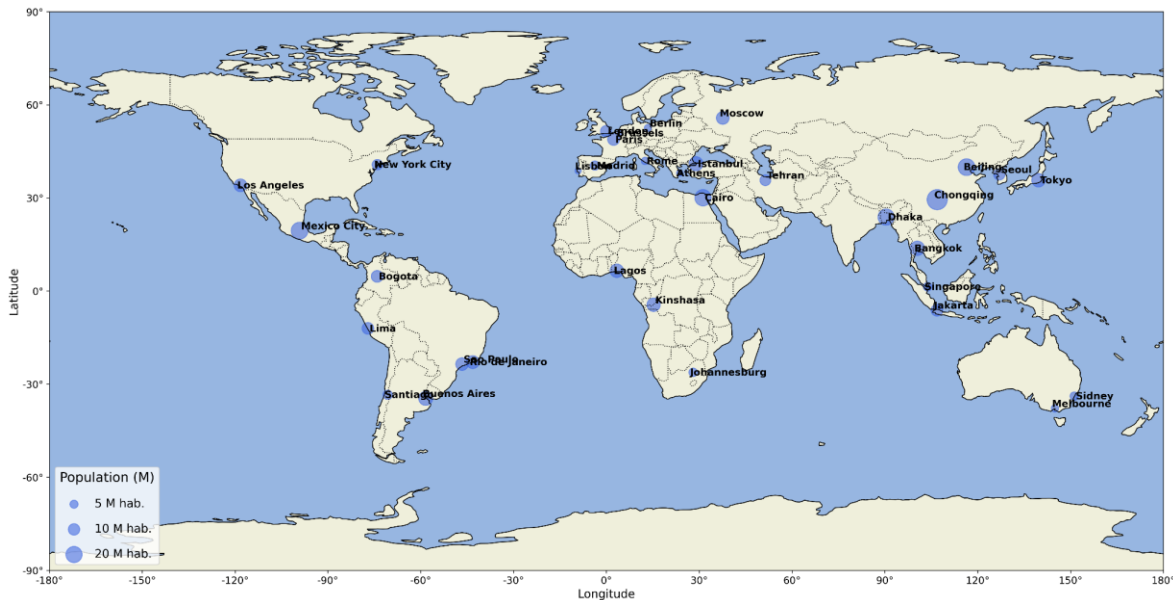


Figura 4.1. Localización geográfica de las 34 megaciudades consideradas en este estudio.

4.2.2 Marco Metodológico

El marco conceptual y la metodología se ilustran en la Figura 4.2. En primer lugar, se prepararon dos conjuntos de datos que contienen concentraciones de tropoNO₂ y AOD provenientes de OMI y MODIS. En segundo lugar, se aplicó un filtro de calidad para asegurar la fiabilidad de los valores derivados de satélite. Específicamente, para cada ciudad y año se excluyeron los píxeles con valores negativos, y solo se conservaron los días con al menos seis píxeles no nulos dentro del área de estudio definida; posteriormente, se calcularon los promedios anuales de tropoNO₂ y AOD.

Esta serie temporal, que abarca desde 2005 hasta 2022, se recopiló con el fin de capturar las variaciones y la respuesta de diferentes ciudades ante crisis socioeconómicas globales. La metodología se basa en analizar, jerarquizar y clasificar las megaciudades de acuerdo con los patrones de tropoNO₂ y AOD. Para identificar las variaciones y respuestas de las megaciudades ante las crisis socioeconómicas globales y la pandemia de COVID-19, se correlacionaron mediante relaciones estadísticas con indicadores energéticos, económicos y ambientales. Los indicadores seleccionados fueron: Intensidad Energética (EI), Consumo Primario de Energía Fósil (FFPEC), Consumo de Energía Per Cápita (PCEU), Luces Nocturnas (NL), Producto Interno Bruto per cápita (PIB) e Índice de Desempeño Ambiental (EPI).

Para analizar estas extensas series temporales, se aplicó la técnica de Factorización de Matriz No Negativa (NMF), y sus resultados se combinaron con el Análisis de Clúster Jerárquico (HC) para explorar y clasificar patrones. Más detalles sobre las bases de datos, los pasos metodológicos y los fundamentos teóricos que respaldan este estudio se describen en las siguientes secciones.

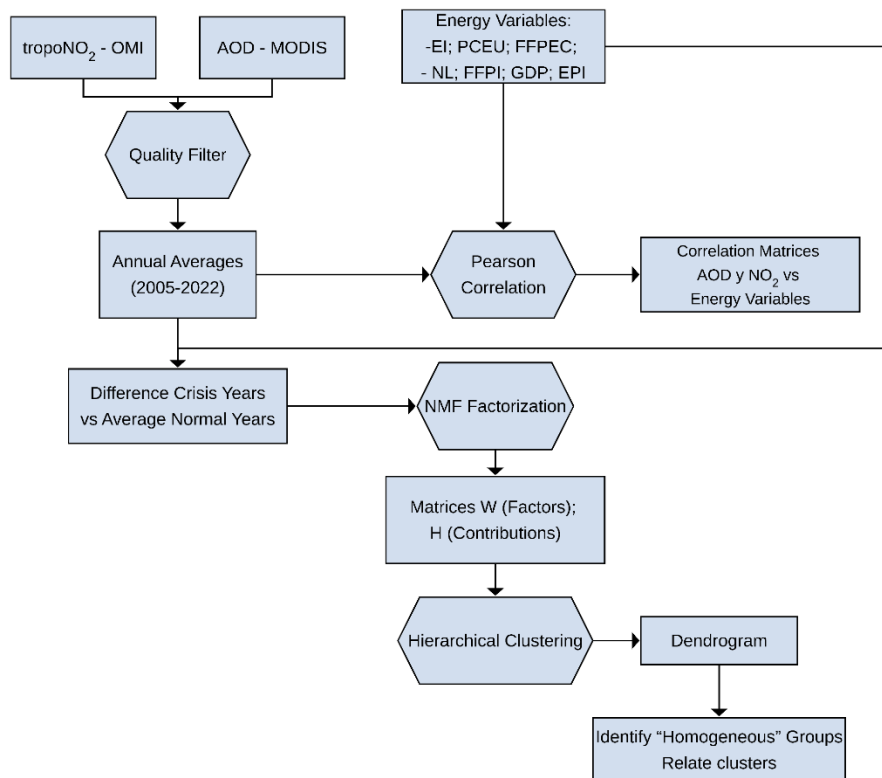


Fig. 4.2.: Diagrama de flujo que muestra los pasos principales del método: EI (Intensidad Energética), FFPEC (Consumo Primario de Energía Fósil), PCEU (Consumo de Energía Per Cápita) y NL (Luces Nocturnas), Producto Interno Bruto per cápita (PIB, en dólares constantes de 2015) e Índice de Desempeño Ambiental (EPI).

4.2.3 Datos Satelitales y Reanálisis

El OMI estaba a bordo del satélite Aura (Levelt et al., 2006). OMI es un espectrómetro UV-VIS que mide valores de columna de NO₂ troposférico. El manual de usuario en línea de la NASA para los productos OMI (Giovanni, 2014) proporciona detalles sobre el filtrado de datos, definiciones de análisis y algoritmos basados en el enfoque de Espectroscopía de Absorción Óptica Diferencial (DOAS), así como procedimientos de control de calidad para filtrar y etiquetar datos. Para este estudio, se usaron promedios mensuales de los datos diarios de NO₂ troposférico de OMI de nivel 3 (L3) (OMNO2d) (Lamsal et al., 2021). El conjunto de datos OMNO2 está en nivel L3, con una resolución espacial de 0,25° × 0,25° en una cuadrícula global. Además, solo se consideraron píxeles con una fracción de nubes inferior al 30%. Los datos se obtuvieron de la plataforma Giovanni (<https://giovanni.gsfc.nasa.gov/>) y cubrieron el período 2011–2020, lo que permitió un análisis temporal extendido de las tendencias de NO₂.

Para la Profundidad Óptica de Aerosoles (AOD), se utilizó el producto combinado de los satélites Terra y Aqua de MODIS (Moderate Resolution Imaging Spectroradiometer), conocido como Multi-angle Implementation of Atmospheric Correction (MAIAC) Land Aerosol Optical Depth (MCD19A2.061, Nivel 2). Este producto proporciona datos diarios de AOD de Nivel 2 con resolución espacial de 1 km, generados por los sensores MODIS a bordo de los satélites Terra y Aqua, utilizando el algoritmo MAIAC. El conjunto de datos MCD19A2 Versión 6, que entrega datos de profundidad de aerosoles de alta resolución (1 km por píxel) sobre superficies terrestres, fue extraído y procesado en Google Earth Engine (Gorelick et al., 2017). Esta plataforma es particularmente adecuada para manejar de manera eficiente grandes conjuntos de datos geoespaciales. Los datos de AOD se recopilaron desde el 1 de enero de 2005 hasta el 31 de diciembre de 2023.

Los indicadores de consumo de energía permiten analizar los sistemas energéticos tanto a escala global como regional (Martins et al., 2019). Este estudio incorporó siete variables listadas en la Tabla 4.1. El conjunto de datos global de Luces Nocturnas (NL) del sensor VIIRS se utilizó como indicador energético. VIIRS proporciona rejillas de radiancia libres de nubes a escala mensual, disponibles desde 2012 (Elvidge et al., 2021). Para los años anteriores, se utilizaron las series temporales de Luces Nocturnas del Operational Linescan System (DMSP-OLS) del Programa de Satélites Meteorológicos de Defensa de la Fuerza Aérea de EE.UU. Estos conjuntos de datos están disponibles públicamente en el NOAA National Geophysical Data Center (NGDC).

La dimensión económica también se incorporó en el análisis mediante la inclusión de indicadores económicos como el PIB per cápita (en dólares constantes de 2015). Para interpretar los resultados desde la perspectiva de las regulaciones ambientales aplicables a cada ciudad, se utilizó el indicador EPI (Environmental Performance Index). El EPI proporciona un tablero comparativo que resalta a los líderes y rezagados en desempeño ambiental, ofreciendo una perspectiva comparativa que ayuda a comprender los determinantes del progreso ambiental alcanzado por distintos países en términos de políticas ambientales. Más detalles disponibles en: <https://epi.envirocenter.yale.edu>.

Table 4.1. List of Variables and indicators of Energy Consume

Indicator/Variables	Abbreviation	Unit	Source
Nighttime Lights	NL	The average of the visible band digital number values	NOAA
Fossil Fuel Primary Energy Consumption	FFPEC	Terawatt-hours (TWh)	Statistical Review of World Energy (2024)
Per Capita Energy Use	PCEU	kilowatt-hours (kWh) per person (kWh)	Statistical Review of World Energy (2024)
Primary energy consumption per GDP	EI	kilowatt-hours (kWh) per dollar	Statistical Review of World Energy (2024)
Fossil Fuel Price Index (West Texas Intermediate)	FFPI	No Unit	Statistical Review of World Energy (2024)
GDP per capita (constant 2015 US dollars)	GDP	US dollars	World Development Index
Environmental Performance Index	EPI	No Unit	Block et al. (2024)

4.2.5 Análisis de Datos

Para los datos satelitales de teledetección, los píxeles se promediaron dentro de cuadrículas de $1^\circ \times 1^\circ$ para generar conjuntos de datos diarios medios, reflejando los valores promedio de los píxeles para cada ciudad analizada. Solo se consideraron los promedios diarios que incluían un mínimo de cinco píxeles válidos por cuadrícula. Para analizar la correlación entre los indicadores de consumo energético y el AOD/tropoNO₂, se calcularon promedios anuales y se utilizó el coeficiente de correlación de Pearson para evaluar su relación.

Las variaciones de tropoNO₂ y AOD durante los años de crisis globales se compararon con los años sin crisis. Estos eventos tuvieron un impacto global, afectando a todas las regiones del mundo en distintos grados. Aunque cada crisis tuvo un año específico de inicio, sus efectos variaron según las estructuras económicas regionales y la velocidad de implementación de las políticas. Por lo tanto, las diferencias se calcularon en relación con los años sin crisis, comparando específicamente 2008 y 2009 (crisis financiera subprime) y 2020 y 2021 (crisis del COVID-19). Para los años sin crisis, se seleccionaron como período de referencia los tres años previos a cada crisis.

4.2.5.1 Factorización de Matrices No Negativa (NMF)

Para identificar patrones y relaciones entre ciudades en función de las variaciones de tropoNO₂ y AOD relativas a los cambios en el consumo energético, se empleó un enfoque de análisis multivariante. Los métodos aplicados incluyeron NMF (Non-negative Matrix Factorization; Lee & Seung, 2001) para identificar patrones subyacentes en los datos y clúster jerárquico para clasificar las megaciudades de acuerdo con los factores/patrones extraídos mediante NMF. Para el análisis NMF, se construyeron dos matrices de datos normalizadas por separado: una para tropoNO₂ y otra para AOD. En cada caso, las columnas de la matriz representan las diferencias entre el promedio anual de un año de crisis y la media de los años no críticos precedentes. Los años de crisis considerados fueron 2008 y 2009 (crisis financiera global) y 2020 y 2021 (pandemia de COVID-19), capturando así los impactos tanto de corto como de mediano plazo de las principales disrupciones globales. Para cada contaminante, este procedimiento generó una matriz de 34 ciudades \times 4 diferencias de años de crisis, lo que permitió detectar patrones espaciales y temporales consistentes en los cambios de contaminantes a lo largo de distintos eventos de crisis.

Las ventajas de este enfoque radican en que el NMF reduce los datos originales en n factores latentes, capturando patrones relevantes y filtrando ruido o redundancia en las variables originales. Al basar el agrupamiento en los factores latentes extraídos con NMF, los clústeres resultantes reflejan patrones significativos en el contexto de los componentes identificados (Mayer et al., 2014). Cada variable se combinó en una matriz $N \times M$ (V), donde N representa las dimensiones temporales (4 diferencias anuales) y M el número de ciudades consideradas (34). NMF descompone V en dos matrices de salida: W ($n \times r$) y H ($r \times m$), cuyo producto $W \times H$ aproxima la matriz de entrada V . Esta aproximación se logra minimizando la distancia euclídea entre la matriz de entrada y el producto de las matrices de salida, es decir, $(V - WH)^2$. El parámetro r representa el número de factores usados para simplificar V . La matriz H contiene la contribución de cada factor a cada sitio de monitoreo, mientras que W detalla la composición de cada factor (Lee et al., 2009). La selección del número adecuado de factores (r) es un paso crítico para asegurar una interpretación significativa de los patrones extraídos (Gaujoux & Seoighe, 2010).

En este estudio, se aplicaron dos factores ($r = 2$) para describir los datos observados con un número limitado de componentes. Un procedimiento típico de NMF ejecuta el algoritmo con múltiples inicializaciones aleatorias para las matrices W y H . Para garantizar la robustez de los resultados, se realizaron 100 iteraciones utilizando el algoritmo NMF de Brunet et al. (2004).

4.2.5.2 Clusterización Jerárquica

En los algoritmos de agrupamiento jerárquico, los clústeres se forman de manera iterativa para generar un dendrograma que representa la estructura jerárquica de los grupos formulados (Saxena et al., 2017). La elección de los parámetros de agrupamiento puede tener un impacto significativo en el resultado final del clustering (Malley et al., 2014). Tras obtener los factores mediante NMF, se aplicó el agrupamiento jerárquico para

clasificar las ciudades en función de los perfiles derivados (W). Este análisis utilizó la distancia euclídea estándar como métrica de similitud y el método de Ward para la fusión de clústeres, que minimiza el incremento en la suma de cuadrados intra-grupo en cada paso. El dendrograma resultante visualiza la estructura jerárquica de los clústeres, permitiendo examinar las relaciones entre ciudades según sus perfiles de comportamiento a través de las variables analizadas.

Para confirmar la fiabilidad de los clústeres, los resultados de NMF/HC se verificaron empleando un método de agrupamiento alternativo basado en PCA + k-means. El Análisis de Componentes Principales (PCA) es ampliamente utilizado para la asignación de fuentes y la reducción de dimensionalidad (Chauhan et al., 2025). Además, técnicas de clustering como K-means han sido aplicadas para identificar regímenes de contaminación y comprender procesos atmosféricos (Licen et al., 2023).

4.3. Resultados

4.3.1 Promedios anuales de tropoNO₂ y AOD

La Figura 4.3 presenta las concentraciones anuales promedio de tropoNO₂ y AOD basadas en observaciones satelitales desde 2005 hasta 2022 para las megaciudades. Las concentraciones medias anuales de tropoNO₂ en estas megaciudades varían entre 17.4 Pmolec/cm² (Beijing) y 1.06 Pmolec/cm² (Bogotá). Los datos satelitales muestran una disminución sostenida y significativa de tropoNO₂ en Beijing y Chongqing (parte inferior de la Fig. 4.3b, curvas azules). Esto se debe tanto a la reducción de emisiones por generación eléctrica (cambio de carbón a gas y energías renovables), como a la electrificación del parque vehicular (World Bank, 2022).

Por ejemplo, la baja variabilidad del tropoNO₂ en Beijing durante las crisis no es solo un reflejo de los niveles de actividad actuales, sino el resultado de una década de reformas estructurales e intervenciones políticas sostenidas (Zhang et al., 2019). Estos cambios estructurales y regulatorios significan que Beijing enfrentó las recientes crisis globales (como los confinamientos por COVID-19) con emisiones ya reducidas. Esto convierte a Beijing en un modelo de cómo ciudades con alto consumo energético pueden alcanzar reducciones absolutas de emisiones y estabilidad en la calidad del aire, incluso en períodos de disrupción económica o social. En contraste, megaciudades en regiones en rápido desarrollo, como Teherán, Dacca y Chongqing, muestran concentraciones de tropoNO₂ relativamente estables o en aumento. Por otro lado, megaciudades en regiones desarrolladas, como Los Ángeles, Nueva York y Seúl, presentan una reducción consistente en sus concentraciones de tropoNO₂ (Goldberg et al., 2020). En ciudades europeas, como Londres, Berlín, Bruselas y Madrid, se observa una tendencia descendente, aunque con fluctuaciones periódicas.

En América Latina y Oceanía, las concentraciones regionales promedio son generalmente bajas (a menudo por debajo de 4.17 Pmolec/cm²), aunque aún se identifican puntos críticos urbanos en megaciudades debido a emisiones locales (Nakada et al., 2020). La pandemia de COVID-19 en 2020-2021 tuvo un fuerte impacto en los niveles de tropoNO₂ en la mayoría de las megaciudades, con reducciones abruptas en urbes de alta actividad económica como Beijing, Yakarta, Johannesburgo, Nueva York, Londres, Madrid y São Paulo. Investigaciones previas durante confinamientos estrictos reportaron reducciones de 30–50% en São Paulo y Nueva York (Lama et al., 2023). Esto confirma que reducciones intensas y generalizadas de emisiones urbanas (especialmente de tráfico e industria) generan mejoras rápidas y sustanciales en la calidad del aire por tropoNO₂, independientemente del continente o de los niveles de contaminación previos a la pandemia.

En cuanto al AOD, se observan tendencias diferenciadas entre las megaciudades. Los valores medios anuales varían entre 877.7 (Chongqing) y 112.8 (Roma). Las megaciudades con alta actividad industrial, como Chongqing, Beijing, Kinshasa, Lagos y Dacca, presentan valores persistentemente altos (≥ 322.29). Sin embargo, es relevante destacar que tanto Beijing como Chongqing muestran la misma disminución sostenida en el tiempo en ambos contaminantes. En contraste, megaciudades desarrolladas como Los Ángeles, Nueva York, Melbourne y Sídney mantienen valores bajos de AOD (≤ 200). En ciudades en desarrollo, como Santiago, Bogotá y Lima, el AOD muestra fluctuaciones moderadas.

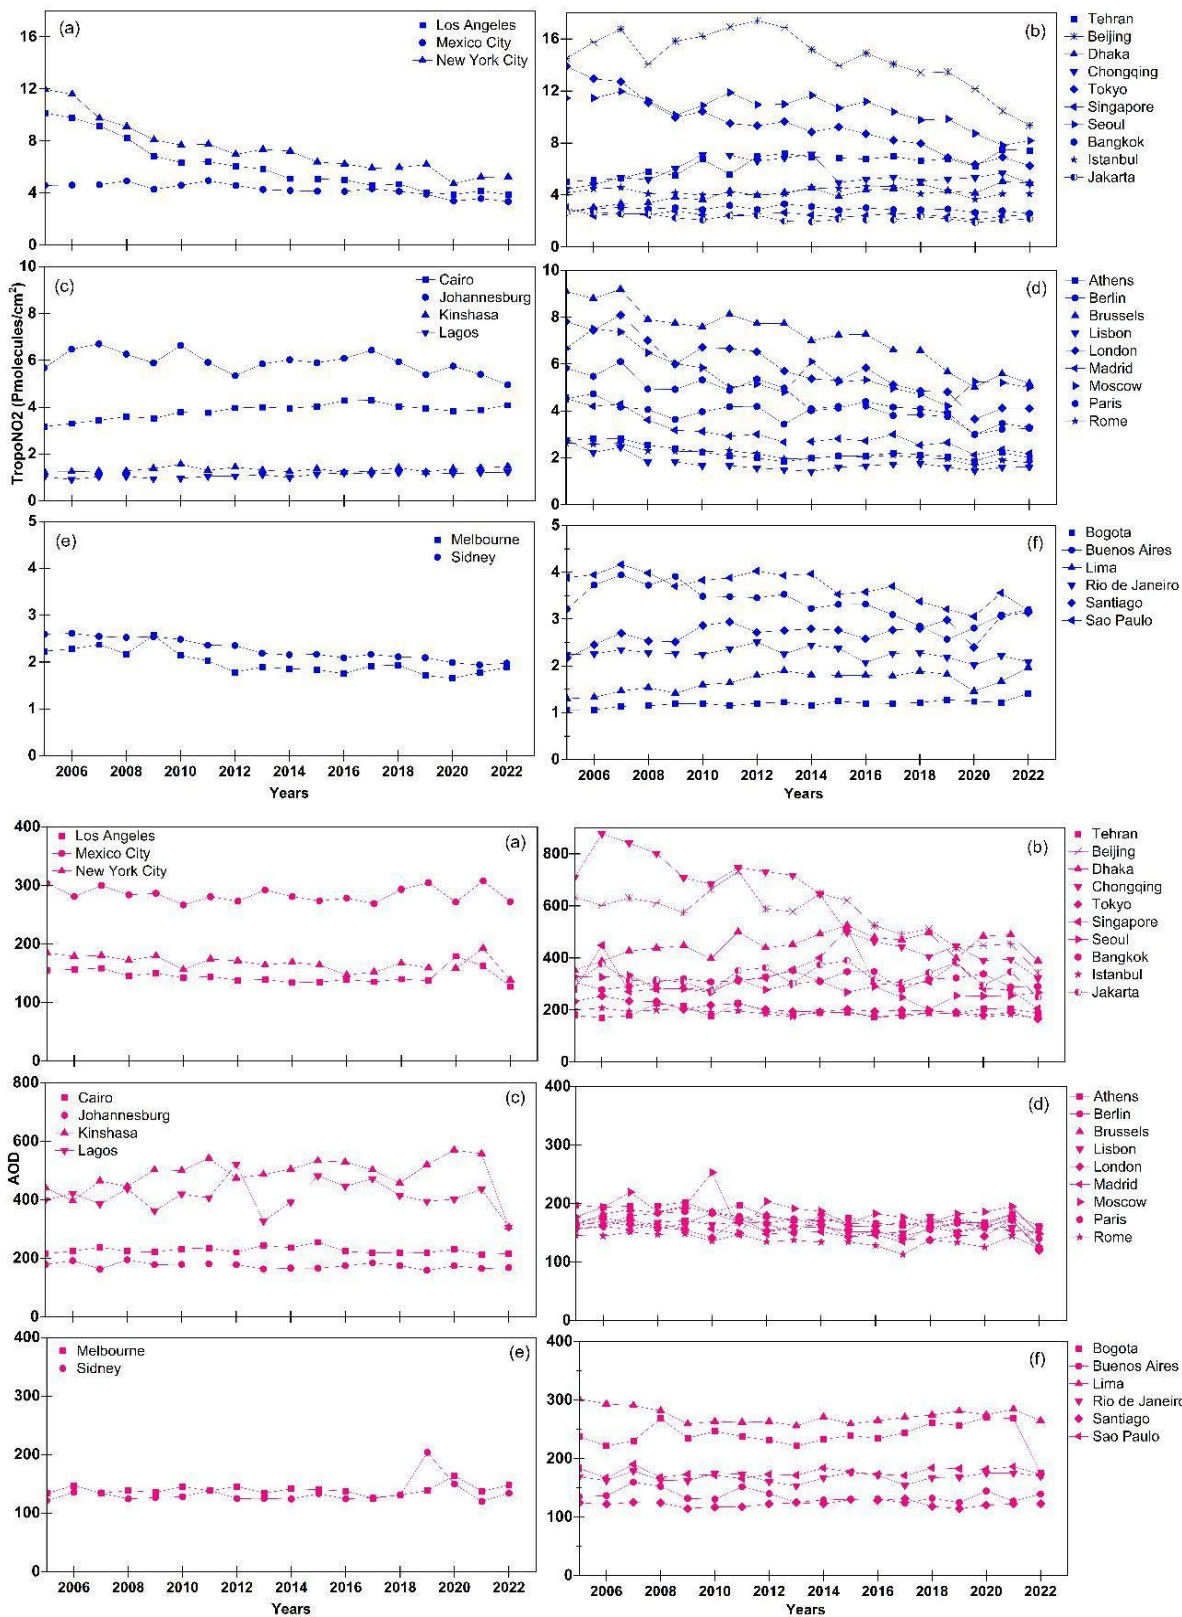


Fig. 4.3.: Promedios anuales de tropoNO₂ (gráficas azules) y AOD (gráficas rojas) en (a) Norteamérica, (b) Asia, (c) África, (d) Europa, (e) Oceanía y (f) Sudamérica durante los años 2005-2022.

4.3.2 Correlaciones entre indicadores energéticos y proxies de contaminación atmosférica.

Las matrices de correlación obtenidas mediante el coeficiente de correlación de Pearson en la Figura 4.4 ilustran la relación entre los promedios anuales de AOD y tropoNO₂ y diversas variables energéticas (EI, FFPEC, PCEU, NL y FFPI) en diferentes megaciudades. Las series temporales de las variables energéticas se presentan en la Tabla S2. El análisis de los datos de tropoNO₂ revela diferencias entre las megaciudades, probablemente influenciadas por factores como el consumo energético, el crecimiento económico, los patrones de transporte y las políticas regulatorias.

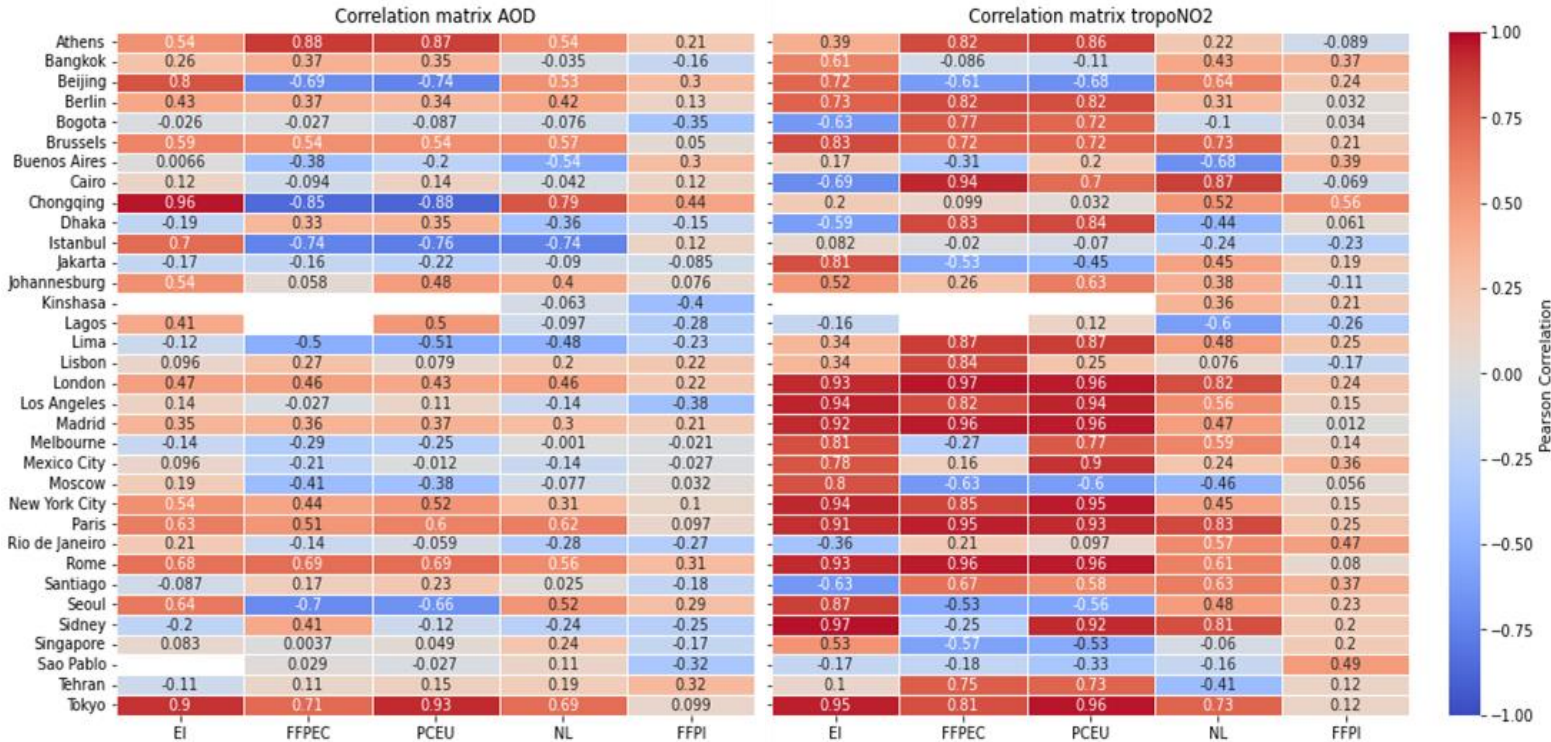


Figura 4.4. Matrices de correlación entre los promedios anuales de AOD y tropoNO₂ para las megaciudades estudiadas, en relación con las variables energéticas: EI (Intensidad Energética), FFPEC (Consumo Primario de Energía Fósil), PCEU (Uso de Energía Per Cápita), NL (Luces Nocturnas) y FFPI (Índice de Precios de Combustibles Fósiles). Las correlaciones positivas se representan en tonos rojos, mientras que las correlaciones negativas se muestran en tonos azules.

Los resultados generales revelan que el tropoNO₂ muestra asociaciones fuertes y consistentes con los indicadores energéticos, particularmente en ciudades altamente desarrolladas con uso intensivo de energía e infraestructura densa. En ciudades de Europa, Norteamérica y Asia —como Tokio, París, Berlín, Londres, Moscú, Nueva York y Madrid— los coeficientes de correlación superan con frecuencia $r = 0.85$, lo que indica una estrecha relación entre las emisiones de tropoNO₂ y los patrones de consumo energético, especialmente de los sectores de transporte e industria. Por ejemplo, Tokio exhibe correlaciones muy altas con EI ($r = 0.95$), PCEU ($r = 0.96$) y NL ($r = 0.87$). De manera similar, París muestra asociaciones sólidas con FFPEC ($r = 0.94$), PCEU ($r = 0.93$) y NL ($r = 0.92$). Otras ciudades como Madrid, Berlín, Londres y Nueva York presentan correlaciones estables en el rango de 0.85 a 0.95 en estas mismas variables. Moscú y Los Ángeles también muestran fuertes vínculos con EI y otras métricas energéticas, lo que sugiere que los niveles de tropoNO₂ en estas ciudades reflejan estrechamente las fluctuaciones en la demanda energética.

Mientras tanto, ciudades como Dacca, Kinshasa y Lagos muestran correlaciones débiles o incluso negativas entre tropoNO₂ e indicadores energéticos. En Dacca, por ejemplo, más del 40% del PM_{2.5} y de las estimaciones asociadas de tropoNO₂ durante los períodos de mayor contaminación se atribuyen a la quema de biomasa —en particular la quema de residuos agrícolas y combustibles domésticos— en lugar del consumo de combustibles fósiles (Rahman et al., 2020). Estos patrones reflejan contextos donde el uso informal de energía, la combustión de biomasa y la quema a cielo abierto dominan la dinámica de la contaminación atmosférica más que las

métricas formales de consumo energético. Hallazgos similares en ciudades de África Occidental, como Kinshasa y Lagos, destacan que los fuegos domésticos, la quema de residuos y el polvo vial contribuyen más significativamente al tropoNO₂ y a los aerosoles que el uso regulado de energía en transporte o industria (Adon et al., 2016).

En cuanto al FFPI, las correlaciones con tropoNO₂ fueron en general más débiles y variables. Algunas ciudades, como Buenos Aires ($r = 0.35$), Tokio ($r = 0.12$) y Beijing ($r = 0.24$), mostraron asociaciones positivas moderadas. En contraste, ciudades como Yakarta, Kinshasa e Estambul presentaron correlaciones negativas con FFPI. Sin embargo, estas tendencias parecen depender del contexto y probablemente estén influidas por las políticas nacionales de precios, los subsidios y la elasticidad de la demanda energética en cada ciudad.

En lo que respecta al AOD, los patrones de correlación son más heterogéneos, lo que indica que este indicador está influido por factores estructurales y sistémicos, no solo por el consumo energético a corto plazo. Por ejemplo, Chongqing muestra correlaciones positivas muy altas con EI ($r = 0.96$), FFPEC ($r = 0.94$) y PCEU ($r = 0.88$), destacando un fuerte vínculo entre los sistemas energéticos basados en combustibles fósiles y la carga de aerosoles. Tokio también presenta correlaciones altas con EI ($r = 0.90$), PCEU ($r = 0.93$) y NL ($r = 0.69$), señalando una relación persistente entre la intensidad energética y el contenido de partículas atmosféricas. Ciudades como Atenas, Roma y París exhiben correlaciones de moderadas a altas con varios indicadores energéticos, especialmente EI y PCEU, lo que respalda la noción de que la estructura y eficiencia energética son impulsores clave de las tendencias en AOD. En contraste, ciudades como Estambul, Daca y Buenos Aires presentan correlaciones débiles o negativas, destacando el caso de Estambul ($r = -0.76$; $r = -0.74$), lo que sugiere que fuentes localizadas no relacionadas con la energía o condiciones meteorológicas pueden dominar la variabilidad de aerosoles en estos casos.

En relación con FFPI y AOD, las asociaciones también fueron modestas. Ciudades como El Cairo ($r = 0.42$) y Buenos Aires ($r = 0.36$) mostraron correlaciones positivas moderadas. En contraste, Ciudad de México, Yakarta y Kinshasa presentaron correlaciones débiles o negativas con FFPI. Finalmente, ciudades como Ciudad de México, Río de Janeiro y Santiago muestran correlaciones bajas o no significativas ($r < 0.3$) con todos los indicadores energéticos, lo que implica un desacoplamiento relativo entre el AOD y los patrones de consumo energético, posiblemente debido a fuentes de emisión mixtas o a la predominancia de factores meteorológicos y topográficos regionales en la concentración de aerosoles.

Estos resultados refuerzan la interpretación de que el tropoNO₂ está más directamente asociado al consumo energético de combustión a corto plazo, mientras que los patrones de AOD reflejan características estructurales de más largo plazo en el sistema energético, como la combinación de combustibles, la eficiencia y la gobernanza urbana. El FFPI muestra relaciones más variables y dependientes de cada ciudad, lo que resalta cómo las señales de mercado pueden influir en las emisiones de manera diferente según la elasticidad de la demanda energética y los contextos regulatorios. Estas distinciones son críticas para orientar respuestas de política diferenciadas en estrategias de mitigación de la contaminación urbana, dependiendo del tipo de contaminante, la dinámica de precios y el perfil energético específico de cada ciudad.

4.3.3 Análisis de factorización y clusterización

En las Figuras 4.5 A-B, los dendrogramas se basan en las diferencias en los promedios de tropoNO₂ y AOD entre años normales y años de crisis (crisis subprime 2008-2009 y pandemia de COVID-19 2020-2021). Estos gráficos ilustran cómo las ciudades se agrupan de acuerdo con sus patrones de cambio en las concentraciones de tropoNO₂ (Figura 4.5A) y de AOD (Figura 4.5B). Los dendrogramas fueron construidos utilizando los componentes NMF y el método de Ward, con la distancia euclidiana como métrica de similitud. Los colores representan las agrupaciones aproximadas formadas en función de la asociación entre ciudades.

En los dendrogramas de la Figura 5, las ciudades se agrupan según la similitud de sus perfiles temporales de tropoNO₂ y AOD, capturados por los componentes NMF. El eje vertical representa la distancia de enlace, que cuantifica qué tan diferentes son dos ciudades o grupos de ciudades. Estas distancias suelen derivarse de una métrica, como la distancia euclidiana, aplicada a los componentes factorizados de NMF que reflejan los patrones clave de variación en las series temporales de tropoNO₂. Las ciudades que se fusionan cerca de la base del dendrograma (es decir, en valores bajos del eje Y) presentan firmas de contaminación temporal muy similares, mientras que aquellas que se unen más arriba son progresivamente más diferentes. Los grupos se forman a medida que el algoritmo de clustering vincula iterativamente los pares de ciudades o clústeres más cercanos en función de estas distancias, resultando en una estructura jerárquica en forma de árbol anidado.




Fig. 4.5: Dendrograma de agrupamiento jerárquico basado en los componentes de NMF de tropoNO₂ (A) y AOD (B), calculados a partir de las diferencias entre años normales y años de crisis económicas.

En el dendrograma de tropoNO₂ (Figura 4.5A), las ciudades se agrupan según su grado de cambio en las concentraciones de tropoNO₂: aquellas con cambios significativos se ubican a la extrema derecha (en verde), las que presentan cambios moderados en la parte superior izquierda (en naranja), y las que muestran cambios mínimos o estables en la parte inferior izquierda (en los grupos naranja y azul). Este análisis ilustra cómo las dinámicas económicas y las restricciones durante las crisis impactan las emisiones urbanas de NO₂.

El grupo azul está compuesto por Beijing, Moscú y Johannesburgo. El grupo naranja incluye Bogotá, Buenos Aires, Lima, Río de Janeiro, Santiago, São Paulo, Melbourne, Estambul, Yakarta, Atenas, El Cairo y Lagos. Finalmente, el grupo verde está formado por Los Ángeles, Nueva York, Sídney, Londres, Bruselas, Berlín, París y Madrid. En el caso de la agrupación de AOD derivada del dendrograma (Figura 5B), el grupo azul (ciudades del lado izquierdo de la Figura 4.5B) incluye Bruselas, Bangkok, Londres, Nueva York y París, que exhiben baja variabilidad en AOD. El grupo verde (ciudades del lado derecho de la Figura 5B) contiene ciudades como Beijing, Lagos y Daka, que muestran las mayores variaciones en AOD durante los años de crisis. Por último, el grupo naranja (ciudades en la parte central de la Figura 5B) incluye a Los Ángeles, Buenos Aires y Santiago, que presentan variaciones moderadas en AOD.

4.3.2.1 Relación grupos tropoNO₂ con respecto a variables energéticas

La agrupación de ciudades según su comportamiento en tropoNO₂ durante los períodos de crisis reveló patrones estructurales distintivos en su uso de energía y resiliencia económica.

Las ciudades del grupo verde (ver Figura 4A) se caracterizan por un alto consumo energético per cápita (PCEU), baja intensidad energética (EI) y una sólida gobernanza ambiental, reflejada en valores consistentemente altos de luces nocturnas (NL) y en un FFPEC estable a lo largo del tiempo. Estas ciudades mantuvieron una demanda

energética relativamente estable tanto durante la crisis financiera de 2008–2009 como en la pandemia de COVID-19, con solo leves y breves descensos. Sus concentraciones de tropoNO₂ disminuyeron abruptamente durante las crisis.

En contraste, las ciudades del grupo naranja (ver Figura 4A) presentaron menor PCEU, mayor EI e indicadores de gobernanza más débiles. Estas ciudades experimentaron descensos más pronunciados en FFPEC y PCEU durante las crisis, lo que revela una mayor vulnerabilidad a las disrupciones económicas. A pesar de las reducciones observadas en el uso de energía, los cambios en tropoNO₂ fueron más moderados, lo que indica un acoplamiento menos eficiente entre la demanda energética y los niveles de contaminación.

Por su parte, el grupo azul, que incluye ciudades como Beijing, Teherán y Moscú, refleja un perfil intermedio: FFPEC moderado a alto, EI elevado y NL moderado. Estas ciudades también registraron reducciones en tropoNO₂ durante las crisis, pero sus patrones fueron menos consistentes.

4.3.2.2 Relación grupos AOD con respecto a variables energéticas

Ciudades con altos valores de NL y FFPEC (Tokio, Londres, Nueva York, Seúl, Bruselas), se agrupan mayormente en el grupo naranja grupo naranja, caracterizado por baja variabilidad en las diferencias de AOD entre años normales y de crisis. Poseen los valores más altos de NL, lo que sugiere una intensa actividad económica nocturna y urbana. Tienen altos valores de FFPEC, lo que refleja una elevada demanda de energía en sus sectores productivos y de transporte. También en el grupo naranja aparecen ciudades como Ciudad de México, Buenos Aires, São Paulo, Estambul y Bangkok con una moderada variabilidad en AOD para los años de crisis. Poseen valores intermedios de PCEU, reflejando un consumo energético per cápita moderado. Su IE es más alta en comparación con ciudades altamente desarrolladas, indicando una mayor dependencia de combustibles fósiles para su productividad. En el grupo verde se presentan ciudades como Lagos, Dhaka, Chongqing y Bogotá mostrando una alta variabilidad en las diferencias de AOD entre años normales y de crisis. Tienen bajos valores de PCEU, lo que indica un menor acceso a energía per cápita, pero una alta dependencia del uso de combustibles convencionales como carbón y diésel. Poseen altos valores de IE (Intensidad Energética), lo que sugiere una baja eficiencia en el uso de la energía. En el grupo Azul (parte izquierda del naranja) ciudades como Bruselas, Bangkok, Londres, Nueva York y París tienen baja variabilidad en AOD. Su consumo energético es relativamente alto, pero con IE baja, lo que indica mayor eficiencia.

4.4. Discusión

Este estudio analizó a las megaciudades globales en relación con el tropoNO₂ y el AOD, examinando su relación estadística con el consumo de energía, indicadores económicos y de regulación ambiental. El análisis abarcó el período 2005–2022, con el objetivo de capturar variaciones y respuestas de diferentes ciudades frente a crisis socioeconómicas globales a lo largo del tiempo. Se utilizaron datos satelitales, ya que estudios previos con este tipo de información han revelado sistemáticamente niveles más altos de tropoNO₂ en áreas urbanas e industriales (Müller et al., 2022; Beirle et al., 2019), lo que resalta el potencial de la teledetección para inferir patrones de actividad económica y energética en diversas regiones (Bichler et al., 2023). Los registros satelitales de largo plazo han sido esenciales para identificar cómo los países desarrollados (agrupados en el clúster verde del tropoNO₂ en este estudio) han logrado reducciones en la contaminación por tropoNO₂ mediante medidas políticas (Hilboll et al., 2013; Castellanos y Boersma, 2012; Russell et al., 2012). En contraste, se han observado tendencias crecientes de NO₂ en megaciudades de los grupos azules del clúster, como aquellas en Asia, generalmente vinculadas al rápido crecimiento industrial. Este estudio de largo plazo se alinea con investigaciones previas, como la de Georgoulis et al. (2019), que analizó tendencias y patrones de tropoNO₂ en múltiples megaciudades mediante teledetección satelital, y la de Bichler et al. (2023), que examinó los cambios de tropoNO₂ en Los Ángeles (EE.UU.) y Tokio (Japón). En nuestro análisis, varias megaciudades mostraron claras disminuciones en las concentraciones de tropoNO₂ y/o AOD durante ambos períodos de crisis. Durante la crisis financiera de 2008–2009, ciudades como Berlín, Bruselas, Los Ángeles, Nueva York, París, Seúl, Singapur y Tokio registraron notorias reducciones de tropoNO₂, mientras que Beijing, Buenos Aires, El Cairo, Lima, Londres, Santiago y São Paulo experimentaron descensos en AOD. En la pandemia de COVID-19 de 2020, la lista de ciudades con disminuciones se amplió significativamente. Se observaron reducciones de tropoNO₂ en Atenas, Daca, Johannesburgo, Madrid, Melbourne, Ciudad de México, Río de Janeiro, Roma, Santiago y Teherán, entre muchas otras, mientras que el AOD disminuyó en Chongqing, Estambul, Yakarta,

Lagos, Roma y Berlín. La simultaneidad de estas reducciones en una amplia gama de contextos urbanos, climáticos y económicos refuerza la hipótesis de que tales caídas en la contaminación fueron impulsadas principalmente por cambios en variables antropogénicas, en particular en el consumo de energía y los patrones de movilidad, más que por efectos meteorológicos locales.

La matriz de correlación entre tropoNO_2 e indicadores energéticos revela una considerable heterogeneidad entre ciudades, reflejando la diversidad estructural, económica y política en la que ocurren las emisiones urbanas. No obstante, en la mayoría de las ciudades estudiadas se observa una relación significativa y robusta entre el tropoNO_2 y al menos una variable energética. Este patrón es particularmente fuerte en ciudades industrializadas de altos ingresos como Tokio, París, Madrid, Berlín y Nueva York, donde los coeficientes de correlación con variables como EI, PCEU y FFPEC suelen superar 0.85. Estos hallazgos son consistentes con estudios previos que muestran que, en economías desarrolladas, las emisiones están estrechamente ligadas a los patrones de uso de combustibles fósiles en transporte y actividades industriales (Liu et al., 2020; Goldberg et al., 2020; Vîrghileanu et al., 2020). En contraste, se observan correlaciones más bajas en muchas ciudades en desarrollo, como Dacca, El Cairo y Kinshasa, donde los niveles de tropoNO_2 están influidos no solo por los sistemas energéticos formales, sino también por fuentes informales y no reguladas, como la quema de biomasa, la incineración de residuos y el uso ineficiente de combustibles residenciales (Khan et al., 2023). Por ejemplo, en Dacca más del 40% del $\text{PM}_{2.5}$ ambiental y las emisiones asociadas de tropoNO_x se atribuyen a la biomasa y a la combustión doméstica, superando las emisiones de la industria (Islam et al., 2025). En ciudades como Singapur, donde el consumo energético per cápita es alto pero las políticas de calidad del aire son estrictas, las correlaciones moderadas ($r \sim 0.5$) sugieren un desacoplamiento parcial entre consumo energético y niveles de tropoNO_2 . Esto refleja el papel de una gobernanza ambiental efectiva, la innovación tecnológica y la adopción de fuentes más limpias en la reducción de emisiones, incluso en contextos de crecimiento económico (Tan et al., 2021; Tanzer-Gruener et al., 2020).

En cuanto al AOD, la estructura de correlaciones resulta más variable y a menudo más débil que en el caso del tropoNO_2 . Las correlaciones más altas y positivas se observaron en ciudades fuertemente industrializadas como Tokio, Chongqing y Beijing, donde el sistema energético sigue dominado por combustibles fósiles y las emisiones industriales contribuyen directamente a las concentraciones de aerosoles. En estas ciudades, el AOD se correlaciona fuertemente con EI, PCEU y FFPEC, lo que apoya la interpretación de que la contaminación particulada está estrechamente vinculada a la estructura e intensidad energética (Zhang et al., 2021). Por el contrario, ciudades como Ciudad de México, Santiago y Río de Janeiro mostraron correlaciones bajas o no significativas, lo que sugiere que factores geográficos y climáticos, junto con fuentes difusas o mixtas de emisión, pueden dominar la variabilidad de aerosoles, desvinculando las tendencias de AOD del uso directo de energía. En general, los resultados confirman que el tropoNO_2 depende más directamente de las actividades de combustión humanas, especialmente en transporte e industria, mientras que el AOD refleja una mezcla más amplia y compleja de fuentes de emisión y procesos atmosféricos, que incluyen transporte de largo alcance y formación secundaria de aerosoles (Kroll et al., 2020).

Del análisis de diferentes indicadores energéticos (NL, FFPEC, PCEU, EI y FFPI), así como de políticas económicas y ambientales en relación con los clústeres identificados en los dendrogramas de diferencias de tropoNO_2 y AOD (años de crisis vs. años normales), emergen varios patrones clave sobre la relación entre consumo de energía, emisiones urbanas y la respuesta de las ciudades ante crisis económicas globales. El agrupamiento de ciudades basado en cambios en concentraciones de tropoNO_2 y AOD durante períodos de crisis globales reveló estructuras energéticas y socioeconómicas subyacentes claramente diferenciadas. En el caso del tropoNO_2 , el clúster naranja (Figura 5A), que incluye ciudades como Bogotá, Santiago, Yakarta y Atenas, comprende principalmente urbes en desarrollo caracterizadas por bajo FFPEC, bajo PCEU y bajos puntajes EPI. Estas ciudades también presentan menor PIB per cápita, alta intensidad energética (EI) y bajos valores de NL, reflejando limitada eficiencia energética e infraestructura débil. En este grupo, las fluctuaciones en tropoNO_2 durante las crisis parecen estar más asociadas con vulnerabilidad estructural y baja resiliencia, dado que sus sistemas urbanos carecen de capacidad institucional y tecnológica para amortiguar choques externos (Giani et al., 2020; Le Quéré et al., 2020). En contraste, el clúster verde (Figura 4A), con ciudades como Berlín, París, Nueva York, Londres y Tokio, presenta altos valores de PCEU y FFPEC, pero bajos de EI y elevados de EPI. Estas características sugieren sistemas energéticos más eficientes y limpios, respaldados por regulaciones ambientales fuertes y transporte diversificado (Zhou et al., 2021; Liu et al., 2022). Estas ciudades tendieron a mostrar reducciones más marcadas en tropoNO_2 durante las crisis, en particular durante los confinamientos por COVID-19, probablemente debido a su mayor capacidad institucional de respuesta y a

la predominancia de emisiones provenientes de fuentes reguladas como el tráfico vehicular (Goldberg et al., 2020; Bauwens et al., 2020). Por otro lado, el clúster azul (Figura 5A), que incluye a ciudades como Beijing y Moscú, se caracteriza por alta intensidad energética, elevado consumo fósil y bajo desempeño ambiental, reflejando una fuerte dependencia de energías fósiles y una gobernanza ambiental limitada. Durante el confinamiento por COVID-19 en Beijing, las observaciones satelitales revelaron una disminución de ~29% en tropoNO₂, atribuida principalmente a la reducción del tráfico vehicular (~47%), aunque los niveles de contaminación se recuperaron rápidamente al levantarse las restricciones, indicando cambios estructurales limitados (Zhang et al., 2024). De manera similar, intervenciones puntuales durante los Juegos Olímpicos de Beijing 2008 y alertas de smog posteriores lograron reducciones de corto plazo (30–40% en emisiones), pero estos avances no se sostuvieron sin una aplicación fuerte y continua de políticas locales (Wen et al., 2024).

En el caso del AOD, los resultados del clúster muestran también perfiles energéticos y ambientales diferenciados. El clúster verde (París, Bruselas, Londres y Sídney, Figura 5B) reúne ciudades con baja EI, alta PCEU, mayor PIB per cápita y mejor desempeño ambiental. Estas tendieron a mostrar niveles estables de AOD durante disrupciones económicas, lo que sugiere políticas efectivas de control de emisiones particuladas y menor dependencia de fuentes contaminantes como la biomasa residencial o la industria basada en carbón (Tobías et al., 2020; Wang et al., 2021). Por el contrario, el clúster naranja (Lagos, Daca, Bogotá y Chongqing, Figura 5B) agrupa ciudades con alta EI, bajo PCEU, bajo producto económico y débil gobernanza ambiental. En estos contextos, la variabilidad de AOD se incrementó bruscamente durante las crisis, señalando una mayor susceptibilidad a fuentes de aerosoles sensibles a la actividad, incluyendo quema de biomasa, construcción informal y tráfico no regulado (Otmani et al., 2020; Gkatzelis et al., 2021). Esto subraya el papel de la vulnerabilidad urbana y las características de los sistemas energéticos en las respuestas de contaminación particulada bajo condiciones de estrés externo.

Para garantizar la solidez y estabilidad de los resultados de agrupamiento, se comparó el enfoque NMF + HC utilizado en este estudio con un método alternativo ampliamente aceptado: análisis de componentes principales seguido de agrupamiento k-means (PCA + k-means) (Chauhan et al., 2025). La comparación mostró un alto grado de consistencia entre los clústeres de NMF + HC y los producidos por PCA + k-means, especialmente entre los perfiles urbanos más distintos. Por ejemplo, las ciudades desarrolladas fueron agrupadas consistentemente en ambos métodos, reforzando la interpretación de sus características compartidas de eficiencia energética y regulación ambiental. Las ciudades en desarrollo también se mantuvieron en los mismos grupos, caracterizadas por bajo consumo energético per cápita, alta intensidad energética y gobernanza ambiental débil. Esta triangulación metodológica respalda la conclusión de que el agrupamiento NMF + HC produce resultados fiables e interpretables que reflejan diferencias estructurales en los sistemas energéticos urbanos y la dinámica de la contaminación.

Los hallazgos anteriores indican que los niveles y variaciones de contaminación están estrechamente vinculados al consumo energético y al nivel de desarrollo urbano, lo cual coincide con estudios previos como Bichler et al. (2023), que demostraron que las tendencias de NO₂ pueden servir como indicadores de transiciones sostenibles en la economía y la energía. Nuestros resultados se alinean con los de Georgoulas et al. (2019), Liang y Gong (2020) y Erbertseder et al. (2024), mostrando que los patrones de contaminación están fuertemente correlacionados con la estabilidad económica y las políticas ambientales, con tendencias que varían según los niveles de desarrollo urbano.

Las diferencias en la variabilidad de AOD y tropoNO₂ durante crisis económicas reflejan cómo la estructura económica, el nivel de desarrollo y las regulaciones ambientales influyen en la contaminación atmosférica. Mientras el AOD permanece más estable en ciudades desarrolladas debido a un mejor control de emisiones y menor dependencia de fuentes contaminantes, en ciudades en desarrollo es más variable. El AOD actúa como un proxy de las concentraciones de PM_{2.5} vinculadas al sector energético industrial (Calvo et al., 2022). En cambio, las tendencias de tropoNO₂ son más heterogéneas, con algunas ciudades desarrolladas y en desarrollo mostrando reducciones significativas durante las crisis, aunque principalmente observadas en los clústeres de ciudades desarrolladas. Las emisiones de tropoNO₂ están ligadas principalmente a la combustión de diésel y gasolina en el transporte, directamente asociada con los niveles de movilidad poblacional (Vîrghileanu et al., 2020).

Este estudio resalta la amplia aplicabilidad del monitoreo satelital en el análisis de la contaminación atmosférica urbana. Sin embargo, es necesario reconocer ciertas limitaciones. La cobertura nubosa puede afectar la disponibilidad de observaciones satelitales, especialmente durante episodios de alta contaminación, lo que podría introducir sesgos en la evaluación de la variabilidad espacial y temporal (Erbertseder et al., 2024). El uso

de datos satelitales de resolución diaria impone restricciones para capturar variaciones intradiarias en los niveles de contaminación. La ausencia de un análisis a nivel de políticas impide una evaluación detallada de cómo estrategias específicas de mitigación impactan en las emisiones urbanas y el consumo de energía. Para superar estas limitaciones, estudios futuros podrían incorporar datos de sensores más recientes como Sentinel-5P/TROPOMI, que ofrecen mayor resolución espacial y espectral. Además, integrar información sobre políticas y regulaciones locales permitiría una interpretación más completa de la relación entre contaminación atmosférica y consumo energético, proporcionando un marco más sólido para evaluar el impacto de medidas de reducción de emisiones. Investigaciones recientes destacan la importancia de estudiar la variabilidad del tropoNO₂ como un proxy del ritmo económico y de los impactos de las políticas (Bichler y Bittner, 2022; Al Yammahi y Aung, 2023). Por lo tanto, los cambios temporales en el tropoNO₂ podrían vincularse a factores de estrés económico o a políticas de mitigación, lo que sugiere la necesidad de incorporar tales enfoques en futuros monitoreos de alta resolución.

4.5. Conclusión

Este estudio analizó la relación entre las concentraciones anuales de tropoNO₂ y AOD en megaciudades globales, examinando su conexión con indicadores energéticos, socioeconómicos y ambientales clave durante el período 2005–2022. Los resultados revelan que las correlaciones entre el tropoNO₂ y las variables energéticas son, en general, más fuertes y consistentes que las observadas para el AOD, lo que pone de relieve la dependencia directa del tropoNO₂ respecto de las actividades antropogénicas, como el transporte y la industria. Las ciudades desarrolladas mostraron correlaciones directas y robustas, mientras que las ciudades en desarrollo presentaron relaciones más variables, reflejando diferencias en las fuentes de contaminación y en los patrones de consumo energético.

El análisis de agrupamiento de ciudades evidenció respuestas heterogéneas vinculadas a factores estructurales subyacentes. Ciudades con alto consumo energético per cápita, baja intensidad energética, una gobernanza ambiental sólida y mayor PIB per cápita, como París, Nueva York y Tokio, tendieron a mostrar reducciones más marcadas en el tropoNO₂ y niveles más estables de AOD durante los choques económicos, lo que sugiere mayor resiliencia y capacidad de respuesta en sus sistemas urbanos. En contraste, ciudades con alta intensidad energética, bajo acceso a energía y regulaciones ambientales más débiles, como Bogotá, Daca y Lagos, mostraron respuestas más volátiles en la contaminación, especialmente en el AOD, lo que indica una mayor exposición y menor capacidad adaptativa. Estos hallazgos refuerzan el papel crucial del monitoreo satelital en la evaluación de la calidad del aire y en el análisis del impacto de las políticas energéticas, económicas y ambientales sobre la contaminación urbana. Sin embargo, el estudio también subraya la necesidad de integrar regulaciones ambientales y estrategias de mitigación que permitan comprender mejor la relación entre consumo de energía y tendencias de contaminación. Además, el enfoque propuesto demostró ser eficaz para identificar y agrupar megaciudades en función de sus niveles de consumo energético y su grado de desarrollo.

En conclusión, este estudio sugiere que la evolución de la contaminación atmosférica en las megaciudades está intrínsecamente ligada a su desarrollo económico, eficiencia energética y capacidad de adaptación frente a crisis globales. La implementación de políticas de descarbonización y la mejora de la eficiencia energética no solo podrían reducir las emisiones de tropoNO₂ y la contaminación por material particulado, sino también fortalecer la resiliencia de las ciudades ante fluctuaciones económicas y ambientales.

Referencia

- Alam, M. M., Murad, M. W., Noman, A. H. M., & Ozturk, I. (2016). Relationships among carbon emissions, economic growth, energy consumption and population growth: Testing Environmental Kuznets Curve hypothesis for Brazil, China, India and Indonesia. *Ecological Indicators*, 70, 466–479. <https://doi.org/10.1016/J.ECOLIND.2016.06.043>
- Bichler, R., Schönebeck, S. S., & Bittner, M. (2023). Observing decoupling processes of NO₂ pollution and GDP growth based on satellite observations for Los Angeles and Tokyo. *Atmospheric Environment*, 310, 119968. <https://doi.org/10.1016/J.ATMOENV.2023.119968>
- Brunet, J. P., Tamayo, P., Golub, T. R., & Mesirov, J. P. (2004). Metagenes and molecular pattern discovery using matrix factorization. *Proceedings of the National Academy of Sciences of the United States of America*, 101(12), 4164–4169. https://doi.org/10.1073/PNAS.0308531101/SUPPL_FILE/08531DATASET9.RTF
- Calvo, R., Álamos, N., Huneeus, N., & O’Ryan, R. (2022). Energy poverty effects on policy-based PM_{2.5} emissions mitigation in southern and central Chile. *Energy Policy*, 161, 112762. <https://doi.org/10.1016/J.ENPOL.2021.112762>
- Castells-Quintana, D., & Wenban-Smith, H. (2020). Population Dynamics, Urbanisation without Growth, and the Rise of Megacities. *The Journal of Development Studies*, 56(9), 1663–1682. <https://doi.org/10.1080/00220388.2019.1702160>
- Chen, H., Hao, Y., Li, J., & Song, X. (2018). The impact of environmental regulation, shadow economy, and corruption on environmental quality: Theory and empirical evidence from China. *Journal of Cleaner Production*, 195, 200–214. <https://doi.org/10.1016/J.JCLEPRO.2018.05.206>
- Dantas, G., Siciliano, B., França, B. B., da Silva, C. M., & Arbilla, G. (2020). The impact of COVID-19 partial lockdown on the air quality of the city of Rio de Janeiro, Brazil. *Science of The Total Environment*, 729, 139085. <https://doi.org/10.1016/J.SCITOTENV.2020.139085>
- Elvidge, C. D., Zhizhin, M., Ghosh, T., Hsu, F. C., & Taneja, J. (2021). Annual Time Series of Global VIIRS Nighttime Lights Derived from Monthly Averages: 2012 to 2019. *Remote Sensing 2021*, Vol. 13, Page 922, 13(5), 922. <https://doi.org/10.3390/RS13050922>
- Erbertseder, T., Taubenbock, H., Esch, T., Gilardi, L., Paeth, H., & Dech, S. (2024). NO₂Air Pollution Trends and Settlement Growth in Megacities. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 12058–12076. <https://doi.org/10.1109/JSTARS.2024.3419573>
- Esch, T., Heldens, W., Hirner, A., Keil, M., Marconcini, M., Roth, A., Zeidler, J., Dech, S., & Strano, E. (2017). Breaking new ground in mapping human settlements from space – The Global Urban Footprint. *ISPRS Journal of Photogrammetry and Remote Sensing*, 134, 30–42. <https://doi.org/10.1016/J.ISPRSJPRS.2017.10.012>
- Gaujoux, R., & Seoighe, C. (2010). A flexible R package for nonnegative matrix factorization. *BMC Bioinformatics*, 11(1), 1–9. <https://doi.org/10.1186/1471-2105-11-367/FIGURES/5>
- Georgoulas, A. K., Van Der, R. A. J., Stammes, P., Folkert Boersma, K., & Eskes, H. J. (2019). Trends and trend reversal detection in 2 decades of tropospheric NO₂ satellite observations. *Atmospheric Chemistry and Physics*, 19(9), 6269–6294. <https://doi.org/10.5194/ACP-19-6269-2019>
- Goldberg, D. L., Anenberg, S. C., Griffin, D., McLinden, C. A., Lu, Z., & Streets, D. G. (2020). Disentangling the Impact of the COVID-19 Lockdowns on Urban NO₂ From Natural Variability. *Geophysical Research Letters*, 47(17), e2020GL089269. <https://doi.org/10.1029/2020GL089269>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/J.RSE.2017.06.031>
- Grange, S. K., Lewis, A. C., Moller, S. J., & Carslaw, D. C. (2017). Lower vehicular primary emissions of NO₂ in Europe than assumed in policy projections. *Nature Geoscience* 2017 10:12, 10(12), 914–918. <https://doi.org/10.1038/s41561-017-0009-0>
- Haakenstad, A., Yearwood, J. A., Fullman, N., Bintz, C., Bienhoff, K., Weaver, M. R., Nandakumar, V., Joffe, J. N., LeGrand, K. E., Knight, M., Abbafati, C., Abbasi-Kangevari, M., Abdoli, A., Zuñiga, R. A. A., Adedeji, I. A., Adekanmbi, V., Adetokunboh, O. O., Afzal, M. S., Afzal, S., ... Lozano, R. (2022). Assessing performance of the Healthcare Access and Quality Index, overall and by select age groups, for 204 countries and territories, 1990–2019: a systematic analysis from the Global Burden of Disease Study 2019. *The Lancet Global Health*, 10(12), e1715–e1743. [https://doi.org/10.1016/S2214-109X\(22\)00429-6/ATTACHMENT/78116600-9F51-48B5-B773-1A486560A1D1/MMC1.PDF](https://doi.org/10.1016/S2214-109X(22)00429-6/ATTACHMENT/78116600-9F51-48B5-B773-1A486560A1D1/MMC1.PDF)
- Hammer, M. S., Van Donkelaar, A., Li, C., Lyapustin, A., Sayer, A. M., Hsu, N. C., Levy, R. C., Garay, M. J., Kalashnikova, O. V., Kahn, R. A., Brauer, M., Apte, J. S., Henze, D. K., Zhang, L., Zhang, Q., Ford, B., Pierce, J. R., & Martin, R. V. (2020). Global Estimates and Long-Term Trends of Fine Particulate Matter Concentrations (1998-2018). *Environmental Science and Technology*, 54(13), 7879–7890. https://doi.org/10.1021/ACS.EST.0C01764/ASSET/IMAGES/LARGE/ES0C01764_0007.JPEG

- Henne, S., Brunner, D., Folini, D., Solberg, S., Klausen, J., & Buchmann, B. (2010). Assessment of parameters describing representativeness of air quality in-situ measurement sites. *Atmospheric Chemistry and Physics*, 10(8), 3561–3581. <https://doi.org/10.5194/ACP-10-3561-2010>
- Joly, M., & Peuch, V. H. (2012). Objective classification of air quality monitoring sites over Europe. *Atmospheric Environment*, 47, 111–123. <https://doi.org/10.1016/J.ATMOSENV.2011.11.025>
- Khan, M. M., Zaman, K., Irfan, D., Awan, U., Ali, G., Kyophilavong, P., Shahbaz, M., & Naseem, I. (2016). Triangular relationship among energy consumption, air pollution and water resources in Pakistan. *Journal of Cleaner Production*, 112, 1375–1385. <https://doi.org/10.1016/J.JCLEPRO.2015.01.094>
- Kovač-Andrić, E., Šorgo, G., Kezele, N., Cvitaš, T., & Klasinc, L. (2010). Photochemical pollution indicators-an analysis of 12 European monitoring stations. *Environmental Monitoring and Assessment*, 165(1–4), 577–583. <https://doi.org/10.1007/S10661-009-0969-7/METRICS>
- Lau, J., Hung, W. T., & Cheung, C. S. (2009). Interpretation of air quality in relation to monitoring station's surroundings. *Atmospheric Environment*, 43(4), 769–777. <https://doi.org/10.1016/J.ATMOSENV.2008.11.008>
- Laughner, J. L., & Cohen, R. C. (2019). Direct observation of changing NOx lifetime in North American cities. *Science*, 366(6466), 723–727. https://doi.org/10.1126/SCIENCE.AAX6832/SUPPL_FILE/AAX6832-LAUGHNER-SM.PDF
- Lee, J. H., Park, S., Ahn, C. M., & Kim, D. (2009). Automatic generic document summarization based on non-negative matrix factorization. *Information Processing & Management*, 45(1), 20–34. <https://doi.org/10.1016/J.IPM.2008.06.002>
- Li, R., Wang, Z., Cui, L., Fu, H., Zhang, L., Kong, L., Chen, W., & Chen, J. (2019). Air pollution characteristics in China during 2015–2016: Spatiotemporal variations and key meteorological factors. *Science of The Total Environment*, 648, 902–915. <https://doi.org/10.1016/J.SCITOTENV.2018.08.181>
- Liang, L., & Gong, P. (2020). Urban and air pollution: a multi-city study of long-term effects of urban landscape patterns on air quality trends. *Scientific Reports* 2020 10:1, 10(1), 1–13. <https://doi.org/10.1038/s41598-020-74524-9>
- Malley, C. S., Braban, C. F., & Heal, M. R. (2014). The application of hierarchical cluster analysis and non-negative matrix factorization to European atmospheric monitoring site classification. *Atmospheric Research*, 138, 30–40. <https://doi.org/10.1016/J.ATMOSRES.2013.10.019>
- Martins, F., Felgueiras, C., Smítková, M., & Caetano, N. (2019). Analysis of Fossil Fuel Energy Consumption and Environmental Impacts in European Countries. *Energies* 2019, Vol. 12, Page 964, 12(6), 964. <https://doi.org/10.3390/EN12060964>
- Mendez-Espinosa, J. F., Rojas, N. Y., Vargas, J., Pachón, J. E., Belalcazar, L. C., & Ramírez, O. (2020). Air quality variations in Northern South America during the COVID-19 lockdown. *Science of The Total Environment*, 749, 141621. <https://doi.org/10.1016/J.SCITOTENV.2020.141621>
- Otmani, A., Benchrif, A., Tahri, M., Bounakhla, M., Chakir, E. M., El Bouch, M., & Krombi, M. (2020). Impact of Covid-19 lockdown on PM10, SO2 and NO2 concentrations in Salé City (Morocco). *Science of The Total Environment*, 735, 139541. <https://doi.org/10.1016/J.SCITOTENV.2020.139541>
- Prunet, P., Lezeaux, O., Camy-Peyret, C., & Thevenon, H. (2020). Analysis of the NO2 tropospheric product from S5P TROPOMI for monitoring pollution at city scale. *City and Environment Interactions*, 8, 100051. <https://doi.org/10.1016/J.CACINT.2020.100051>
- Reddington, C. L., Conibear, L., Robinson, S., Knote, C., Arnold, S. R., & Spracklen, D. V. (2021). Air Pollution From Forest and Vegetation Fires in Southeast Asia Disproportionately Impacts the Poor. *GeoHealth*, 5(9), e2021GH000418. <https://doi.org/10.1029/2021GH000418>
- Rentschler, J., & Leonova, N. (2023). Global air pollution exposure and poverty. *Nature Communications* 2023 14:1, 14(1), 1–11. <https://doi.org/10.1038/s41467-023-39797-4>
- Sannoh, F., Fatmi, Z., Carpenter, D. O., Santoso, M., Siddique, A., Khan, K., Zeb, J., Hussain, M. M., & Khwaja, H. A. (2024). Air pollution we breathe: Assessing the air quality and human health impact in a megacity of Southeast Asia. *Science of The Total Environment*, 942, 173403. <https://doi.org/10.1016/J.SCITOTENV.2024.173403>
- Saxena, A., Prasad, M., Gupta, A., Bharill, N., Patel, O. P., Tiwari, A., Er, M. J., Ding, W., & Lin, C. T. (2017). A review of clustering techniques and developments. *Neurocomputing*, 267, 664–681. <https://doi.org/10.1016/J.NEUCOM.2017.06.053>
- Schneider, P., Lahoz, W. A., & Van Der A, R. (2015). Recent satellite-based trends of tropospheric nitrogen dioxide over large urban agglomerations worldwide. *Atmospheric Chemistry and Physics*, 15(3), 1205–1220. <https://doi.org/10.5194/ACP-15-1205-2015>

- Seo, J., Park, D. S. R., Kim, J. Y., Youn, D., Lim, Y. Bin, & Kim, Y. (2018). Effects of meteorology and emissions on urban air quality: A quantitative statistical approach to long-term records (1999-2016) in Seoul, South Korea. *Atmospheric Chemistry and Physics*, 18(21), 16121–16137. <https://doi.org/10.5194/ACP-18-16121-2018>
- Squizzato, S., Masiol, M., Rich, D. Q., & Hopke, P. K. (2018). PM_{2.5} and gaseous pollutants in New York State during 2005–2016: Spatial variability, temporal trends, and economic influences. *Atmospheric Environment*, 183, 209–224. <https://doi.org/10.1016/J.ATMOENV.2018.03.045>
- Sun, B., Shi, Y., Li, Y., Jiang, J., Liang, S., Duan, J., & Sun, Z. (2020). Short-term PM_{2.5} exposure induces sustained pulmonary fibrosis development during post-exposure period in rats. *Journal of Hazardous Materials*, 385, 121566. <https://doi.org/10.1016/J.JHAZMAT.2019.121566>
- Tang, Y., Sun, T., Luo, Z., Omidvar, H., Theeuwes, N., Xie, X., Xiong, J., Yao, R., & Grimmond, S. (2021). Urban meteorological forcing data for building energy simulations. *Building and Environment*, 204, 108088. <https://doi.org/10.1016/J.BUILDENV.2021.108088>
- Taubenböck, H., Esch, T., Felbier, A., Wiesner, M., Roth, A., & Dech, S. (2012). Monitoring urbanization in mega cities from space. *Remote Sensing of Environment*, 117, 162–176. <https://doi.org/10.1016/J.RSE.2011.09.015>
- Tobías, A., Carnerero, C., Reche, C., Massagué, J., Via, M., Minguillón, M. C., Alastuey, A., & Querol, X. (2020). Changes in air quality during the lockdown in Barcelona (Spain) one month into the SARS-CoV-2 epidemic. *Science of The Total Environment*, 726, 138540. <https://doi.org/10.1016/J.SCITOTENV.2020.138540>
- Toro A., R., Catalán, F., Urdanivia, F. R., Rojas, J. P., Manzano, C. A., Seguel, R., Gallardo, L., Osses, M., Pantoja, N., & Leiva-Guzman, M. A. (2021). Air pollution and COVID-19 lockdown in a large South American city: Santiago Metropolitan Area, Chile. *Urban Climate*, 36, 100803. <https://doi.org/10.1016/J.UCLIM.2021.100803>
- Virghileanu, M., Săvulescu, I., Mihai, B. A., Nistor, C., & Dobre, R. (2020). Nitrogen Dioxide (NO₂) Pollution Monitoring with Sentinel-5P Satellite Imagery over Europe during the Coronavirus Pandemic Outbreak. *Remote Sensing 2020*, Vol. 12, Page 3575, 12(21), 3575. <https://doi.org/10.3390/RS12213575>
- Volke, M. I., Abarca-del-Rio, R., & Ulloa-Tesser, C. (2023). Impact of mobility restrictions on NO₂ concentrations in key Latin American cities during the first wave of the COVID-19 pandemic. *Urban Climate*, 48, 101412. <https://doi.org/10.1016/J.UCLIM.2023.101412>
- Wang, Y., Hu, M., Wang, Y., Zheng, J., Shang, D., Yang, Y., Liu, Y., Li, X., Tang, R., Zhu, W., Du, Z., Wu, Y., Guo, S., Wu, Z., Lou, S., Hallquist, M., & Yu, J. Z. (2019). The formation of nitro-aromatic compounds under high NO_x and anthropogenic VOC conditions in urban Beijing, China. *Atmospheric Chemistry and Physics*, 19(11), 7649–7665. <https://doi.org/10.5194/ACP-19-7649-2019>
- Xu, K., Cui, K., Young, L. H., Hsieh, Y. K., Wang, Y. F., Zhang, J., & Wan, S. (2020). Impact of the COVID-19 Event on Air Quality in Central China. *Aerosol and Air Quality Research*, 20(5), 915–929. <https://doi.org/10.4209/AAQR.2020.04.0150>
- Zambrano-Monserrate, M. A., & Ruano, M. A. (2020). Has air quality improved in Ecuador during the COVID-19 pandemic? A parametric analysis. *Air Quality, Atmosphere and Health*, 13(8), 929–938. <https://doi.org/10.1007/S11869-020-00866-Y/TABLES/3>
- Zhao, X., Zhou, W., & Han, L. (2021). The spatial and seasonal complexity of PM_{2.5} pollution in cities from a social-ecological perspective. *Journal of Cleaner Production*, 309, 127476. <https://doi.org/10.1016/J.JCLEPRO.2021.127476>
- Zhu, S., He, C., & Liu, Y. (2014). Going green or going away: Environmental regulation, economic geography and firms' strategies in China's pollution-intensive industries. *Geoforum*, 55, 53–65. <https://doi.org/10.1016/J.GEOFORUM.2014.05.004>

Capítulo 5:

5.1. Conclusión

La contaminación atmosférica es una de las principales preocupaciones ambientales a nivel global y su reducción constituye un objetivo central dentro de los Objetivos de Desarrollo Sostenible (ODS). Entre los factores más determinantes para la calidad del aire se encuentra el consumo energético, dado que la combustión de combustibles fósiles genera emisiones de dióxido de nitrógeno (NO_2) y material particulado fino ($\text{PM}_{2.5}$), ambos con efectos adversos sobre la salud humana y los ecosistemas. Sin embargo, resulta crítico establecer un nexo sistemático entre el consumo energético y la contaminación atmosférica, que permita comprender cómo la estructura del sistema energético, las fuentes de generación y la eficiencia de uso de la energía condicionan las emisiones. Este vínculo es especialmente relevante en contextos donde los patrones energéticos pueden cambiar drásticamente, como en crisis económicas, sanitarias o geopolíticas. No obstante, los resultados de cualquier intervención no serán homogéneos, ya que las realidades socioeconómicas, climáticas y de gobernanza de las ciudades determinan la magnitud y persistencia de las mejoras en la calidad del aire. Por ello, la toma de decisiones y el desarrollo de modelos predictivos y sistemas de monitoreo deben integrar explícitamente variables energéticas y adaptarse a la diversidad de contextos urbanos. A pesar de los avances, la mayoría de los estudios previos han abordado esta problemática desde una perspectiva local o regional, basándose en datos de monitoreo terrestre o modelos de transporte químico, lo que limita la capacidad de capturar variaciones abruptas y comparables entre múltiples urbes. Hasta ahora, no existía un análisis a gran escala que evaluara de forma integrada la interacción entre sistemas energéticos y calidad del aire en múltiples megaciudades del mundo, incorporando su heterogeneidad y las lecciones para diseñar políticas más efectivas.

El presente estudio integró el análisis de series temporales satelitales de contaminación atmosférica (tropo NO_2 y AOD), variables energéticas y factores socioeconómicos para evaluar la respuesta de las megaciudades a crisis globales, combinando técnicas de normalización meteorológica, aprendizaje automático y análisis multiescala. En conjunto, los tres capítulos ofrecen evidencia robusta de que la interacción entre sistemas energéticos, movilidad urbana y gobernanza determina tanto la magnitud como la persistencia de las mejoras en calidad del aire.

En el capítulo “Impact of mobility restrictions on NO_2 concentrations in key Latin American cities during the first wave of the COVID-19 pandemic”, centrado en 17 ciudades latinoamericanas durante la pandemia de COVID-19, se identificaron reducciones significativas de tropo NO_2 entre marzo y junio de 2020 frente a 2019, con descensos destacados en Lima (-47,5%), Santiago (-36,1%) y São Paulo (-27%). Estas reducciones se asociaron fuertemente a la caída de la movilidad vinculada al transporte y no a variaciones meteorológicas, lo que confirma que restricciones poblacionales amplias pueden producir mejoras rápidas y temporales en la calidad del aire urbano. La correlación con disminuciones en consumo diésel refuerza la conexión directa con el sistema energético y los patrones de movilidad.

En el capítulo “Assessing the Influence of Energy Consumption on Tropospheric NO_2 in Santiago, Chile: A Multi-Method Approach Using Satellite Data”, el análisis de Santiago de Chile para la crisis financiera 2008–2009 y la pandemia de 2020 mostró que las reducciones de tropo NO_2 (-3% y -27%, respectivamente) evidencian que las crisis económicas pueden generar cambios significativos pero temporales en la calidad del aire. Mediante causalidad no lineal (EDM) se demostró que el tropo NO_2 mantiene vínculos robustos con indicadores energéticos como el consumo de energía per cápita, la intensidad energética y las luces nocturnas, lo que subraya que la dinámica energética es un modulador central de la respuesta ambiental de las ciudades.

En el capítulo “Clustering Time Series Analysis of Tropospheric NO_2 and AOD Satellite Data in Global Megacities: Exploring Patterns Linked to Energy-Related Variables”, el análisis global de 34 megaciudades (2005–2022) identificó tres patrones de respuesta: (i) ciudades con alta eficiencia energética y regulación ambiental, como Tokio, con reducciones sostenidas de NO_2 y estabilidad en AOD; (ii) urbes con alta intensidad energética y baja gobernanza, como Dakha, con reducciones limitadas y efímeras; y (iii) grandes emisores

fósiles, con caídas puntuales de NO_2 pero sin cambios estructurales debido a dependencia energética y emisiones residenciales. Tropo NO_2 mantuvo correlaciones más consistentes con FFPEC, PCEU y EI que AOD, este último más sensible a factores naturales y meteorológicos.

En conjunto, los hallazgos demuestran que el efecto de las crisis sobre la calidad del aire está condicionado por la estructura del sistema energético, el grado de gobernanza ambiental y la resiliencia urbana. Las metodologías desarrolladas, que integran datos satelitales, proxies energéticos y machine learning, no solo permiten mejorar la caracterización de estos vínculos, sino que también pueden orientar políticas públicas hacia intervenciones focalizadas, anticipar escenarios críticos y evaluar cuantitativamente el impacto de medidas de transición energética, movilidad sostenible y mitigación de emisiones. Se recomienda incorporar sistemáticamente la dinámica energética, mediante consumo y proxies como la luz nocturna, en sistemas de monitoreo y modelos predictivos de alerta temprana para las megaciudades del futuro.