



**UNIVERSIDAD AUTÓNOMA
DEL ESTADO DE MÉXICO**

**FACULTAD DE GEOGRAFÍA
DOCTORADO EN GEOGRAFÍA Y
DESARROLLO GEOTECNOLÓGICO**

**DINÁMICA ESPACIO-TEMPORAL DE LOS CASOS DE
CONTAGIO POR COVID-19 EN LA CIUDAD DE MÉXICO.
PROPUESTA DE UN MODELO ESPACIAL BASADO EN**

TESIS

QUE PARA TENER EL GRADO DE:

**DOCTORA EN GEOGRAFÍA Y
DESARROLLO GEOTECNOLÓGICO**

PRESENTA:

VIOLETA SHAIID BENITEZ VALERIO

COMITÉ TUTORAL:

DRA. MARCELA VIRGINIA SANTANA JUÁREZ

DRA. GIOVANNA SANTANA CASTAÑEDA

DR. IVÁN DARÍO CASTRILLÓN SERNA

Índice

Introducción	11
Antecedentes	13
Planteamiento del problema	21
Preguntas de investigación	24
Justificación.....	24
Hipótesis.....	25
Objetivos	26
Capítulo I. Marco teórico conceptual.....	28
1.1 Fundamentos de la geografía.....	28
1.1.1 Geografía.....	28
1.1.2 Principios de geografía	28
1.1.3 Paradigmas de la geografía para el estudio de COVID-19.....	29
1.2 Geografía de la salud.....	32
1.3 Factores geográficos y ambientales que inciden en la salud de acuerdo con Ana Olivera	37
1.4 Determinantes sociales de la salud y Condicionantes socioespaciales de la salud	39
1.5 Geotecnologías en la salud.....	42
Propuesta Modelo teórico – conceptual para el estudio de la dinámica de la pandemia por COVID-19, a partir de la geografía y modelos espaciales de Inteligencia Artificial.	51
Capítulo II. Metodología.....	57
2.1 Zona de estudio	57

2.2 Tipo de estudio	58
2.3 Fuentes de información	59
2.4 Métodos de investigación.....	60
2.4.1 Hardware	61
2.4.1 Software	61
2.5 Variables e indicadores	61
Variable dependiente.....	61
Variables independientes	63
2.6 Etapas y procesos	65
2.6.1 Esquema metodológico	65
2.6.2 Modelo híbrido CNN+LSTM	73
2.6.2.1 Arquitectura de modelado predictivo de CNN + LSTM.....	75
2.6.3 Modelo XGBoost	77
Capítulo III Dinámica espacio – temporal de las enfermedades respiratorias infecciosas y situación de la pandemia por COVID-19	81
3.1 Historia de las enfermedades respiratorias transmisibles.....	81
3.2 Enfermedades respiratorias infecciosas (2009-2019)	112
3.1 Enfermedades respiratorias infecciosas por grupo de edad	114
3.4 Correlaciones de contaminación y enfermedades respiratorias	117
3.4 Dinámica espacio – temporal de las enfermedades respiratorias infecciosas y situación de la pandemia por COVID-19	119
3.3 Factores geográfico – ambientales	119
3.3.1 Climas	119
3.3.2 Temperatura	120
3.3.3 Condiciones meteorológicas durante la pandemia por COVID-19 (2020- 2023).....	123

3.3.4 Contaminación atmosférica.....	125
3.3.5 Ozono (O ₃)	126
3.3.6 Partículas menores a 10 μm ³ (PM ₁₀) y Partículas menores a 2.5 μm ³ (PM _{2.5})	131
3.3.7 Dióxido de azufre (SO ₂).....	137
3.3.8 Monóxido de carbono (CO)	142
3.3.9 Óxido de nitrógeno (NO _x)	147
3.4 Condiciones sociales	151
3.4.1 Densidad de población	151
3.4.2 Uso de suelo	153
3.4.3 Actividades económicas.....	154
Capítulo IV Dinámica espacio – temporal de la pandemia por COVID-19.....	158
4.1 Condiciones de salud.....	158
4.1.1 Tasa de prevalencia por COVID-19.....	159
4.1.2 Tasa de prevalencia por género de COVID-19	163
4.1.3 Contagios de COVID-19 por grupos de edad	166
4.1.4 Comorbilidades asociadas a COVID-19	170
4.1.5 Combinación de comorbilidades.....	172
4.2 Modelo de predicción de COVID-19.....	173
Predicción del modelo CNN+LSTM por alcaldía.....	175
Importancia relativa de condicionantes de salud y ambientales en la predicción de contagios por COVID-19 con XGBoost.....	195
Conclusiones	199
Bibliografía	207

Índice de figuras

Figura 1 Arquitectura interna del modelo XGBoost.....	48
Figura 2 Esquema funcional del modelo híbrido CNN+LSTM.....	51
Figura 3 Localización de la Ciudad de México	58
Figura 4 Esquema metodológico	66
Figura 5 Modelos predictivos analizados de Machine Learning y Deep Learning.....	73
Figura 6 Arquitectura del modelo CNN + LSTM para la predicción de contagios de COVID-19 por alcaldía de la Ciudad de México	75
Figura 7 Modelo híbrido CNN + LSTM para la predicción de contagios diarios por COVID-19	77
Figura 8 Flujo de modelado predictivo con XGBoost para la estimación de casos diarios de COVID-19 por alcaldía	79
Figura 9 Línea del tiempo de las enfermedades respiratorias.....	100
Figura 10 Localización de pandemias y epidemias de enfermedades respiratorias transmisibles.....	102
Figura 11 Casos acumulados de enfermedades respiratorias infecciosas en la Ciudad de México (2009–2019)	114
Figura 12 Enfermedades respiratorias infecciosas por grupo de edad de la Ciudad de México (2009-2019)	116
Figura 13 Tipos de clima en la Ciudad de México	120
Figura 14 Serie de tiempo de temperaturas máximas, medias, mínimas y humedad media mensual de la Ciudad de México (2009-2021).....	121
Figura 15 Distribución espacio-temporal de la temperatura media mensual, máxima y mínima en la Ciudad de México (2009-2019).....	123
Figura 16 Temperatura y humedad relativa media mensual (2020-2023).....	125
Figura 17 Promedios mensuales de temperatura y ozono y su relación con contagios respiratorios acumulados (2009–2019)	128
Figura 18 distribución de ozono en la Ciudad de México	129
Figura 19 Distribución promedio estacional de Ozono (O ₃) entre 2009 y 2019.....	130
Figura 20 Distribución espacial de días con exposición a PM _{2.5} y PM ₁₀ en la Ciudad de México (2009–2019)	134
Figura 21 Tendencias de PM _{2.5} , PM ₁₀ y contagios respiratorios en la Ciudad de México (2009–2019)	135
Figura 22 Tendencias de PM _{2.5} , PM ₁₀ y contagios por COVID-19 en la Ciudad de México (2020–2023)....	137
Figura 23 Contagios de enfermedades respiratorias infecciosas y dióxido de azufre (SO ₂) (2009-2019).....	139
Figura 24 Distribución promedio estacional de Dióxido de azufre (SO ₂) entre 2009 y 2019	141
Figura 25 Contagios de COVID-19 y acumulación media mensual de SO ₂ (2020-2023).....	142
Figura 26 Contagios de enfermedades respiratorias y monóxido de carbono (2009-2019).....	144
Figura 27 Contagios de COVOD y monóxido de carbono (CO) (2020-2023).....	145
Figura 28 Distribución promedio estacional de Monóxido de carbono (CO) entre 2009 y 2019.....	146

Figura 29 Contagios por enfermedades respiratorias infecciosas (ERI) y concentraciones promedio de óxidos de nitrógeno (NO _x) en la Ciudad de México, 2009–2019.....	148
Figura 30 Contagios por COVID-19 y concentraciones mensuales promedio de óxidos de nitrógeno (NO _x) en la Ciudad de México, 2020–2023.....	149
Figura 31 Distribución promedio estacional de Óxido de nitrógeno (NO _x) (2009 y 2019).....	150
Figura 32 Densidad de población 2020 ((Hab./Km ²), por alcaldía de la Ciudad de México.....	152
Figura 33 Subsector de especialización comercial.....	157
Figura 35 Evolución de los Contagios Acumulados de COVID-19 en la Ciudad de México (2020-2022) ...	160
Figura 34 Tasa de prevalencia 2020, 2021, 2022 por 10,000 habitantes.....	161
Figura 36 Contagios acumulados de COVID-19 anuales por municipio de la Ciudad de México.....	162
Figura 37 Contagios acumulados de COVID-19 por género en la Ciudad de México (2020-2022).....	164
Figura 38 Tasa de prevalencia de COVID-19 por 10,000 hombres en la Ciudad de México.....	164
Figura 39 Tasa de prevalencia de COVID-19 por 10,000 mujeres en la Ciudad de México.....	165
Figura 40 Contagios de COVID-19 por grupos de edad de la Ciudad de México.....	169

Índice de tablas

Tabla 1 Registro de casos COVID-19 en México.....	22
Tabla 2 Modelos teóricos de transición epidemiológica.....	36
Tabla 3 Determinantes y condicionantes socioespaciales de la salud.....	41
Tabla 4 Línea del tiempo de las enfermedades infecciosas respiratorias.....	103
Tabla 5 Alcaldía Azcapotzalco CNN+LSTM 01 al 15 de septiembre 2023.....	176
Tabla 6 Alcaldía Coyoacán CNN+LSTM 01 al 15 de septiembre 2023.....	178
Tabla 7 Alcaldía Cuajimalpa de Morelos CNN+LSTM 01 al 15 de septiembre 2023.....	179
Tabla 8 Alcaldía Gustavo A. Madero CNN+LSTM 01 al 15 de septiembre 2023.....	180
Tabla 9 Alcaldía Iztacalco CNN+LSTM 01 al 15 de septiembre 2023.....	181
Tabla 10 Iztapalapa CNN+LSTM 01 al 15 de septiembre 2023.....	182
Tabla 11 Alcaldía La Magdalena Contreras CNN+LSTM 01 al 15 de septiembre 2023.....	183
Tabla 12 Milpa Alta CNN+LSTM 01 de septiembre 2023.....	185
Tabla 13 Alcaldía Álvaro Obregón CNN+LSTM 01 al 15 de septiembre 2023.....	186
Tabla 14 Tláhuac CNN+LSTM 01 al 15 de septiembre 2023.....	187
Tabla 15 Alcaldía Tlalpan CNN+LSTM 01 al 15 de septiembre 2023.....	188
Tabla 16 Alcaldía Xochimilco CNN+LSTM 01 al 15 de septiembre 2023.....	189
Tabla 17 Alcaldía Benito Juárez CNN+LSTM 01 al 15 de septiembre 2023.....	190
Tabla 18 Alcaldía Cuauhtémoc CNN+LSTM 01 al 15 de septiembre 2023.....	191
Tabla 19 Alcaldía Cuauhtémoc CNN+LSTM 01 al 15 de septiembre 2023.....	192
Tabla 20 Alcaldía Venustiano Carranza CNN+LSTM 01 al 15 de septiembre 2023.....	193

Tabla 21 Evaluación del modelo del modelo CNN+LSTM	194
Tabla 22 Importancia relativa de variables en la predicción de contagios de COVID-19 por alcaldía en la Ciudad de México, estimada con XGBoost.....	197
Tabla 23 Evaluación del modelo XGBoost por alcaldía.....	198

Resumen

La investigación genera un modelo espacial sustentado en inteligencia artificial espacial para analizar la dinámica espacio-temporal de los contagios por COVID-19 en la Ciudad de México, incorporando variables geográficas, ambientales, socioeconómicas y epidemiológicas. Desde una perspectiva geotecnológica, se integran técnicas de aprendizaje profundo y sistemas de información geográfica para determinar y representar la propagación del virus en entornos urbanos con altas densidades de población. El sustento teórico se basa en conceptos como el de Condicionantes Socioespaciales de la Salud y geointercalación epidemiológica, que explican la vulnerabilidad sanitaria como resultado de interacciones acumulativas entre factores estructurales, ambientales y clínicos. Con base en datos oficiales y mediante interpolación IDW, se emplearon dos modelos predictivos: CNN+LSTM y XGBoost. Este último identificó a la hipertensión como el principal factor explicativo en nueve delegaciones, seguido por diabetes y obesidad. Aunque los contaminantes atmosféricos mostraron menor peso general, en zonas como Iztapalapa y Gustavo A. Madero, el dióxido de azufre y el asma adquirieron relevancia. Los hallazgos respaldan el uso de modelos espaciales con inteligencia artificial para comprender dinámicas espaciotemporales complejas urbanas en salud y destacan la importancia de contar con microdatos territoriales para una gestión territorial en salud más efectiva y diferenciada de acuerdo con los contextos geográficos.

Palabras clave: Dinámica espacio-temporal, Condicionantes Socioespaciales de la Salud, COVID-19, Inteligencia Artificial

Abstract

This research develops a spatial model supported by spatial artificial intelligence to analyze the spatiotemporal dynamics of COVID-19 infections in Mexico City, incorporating geographic, environmental, socioeconomic, and epidemiological variables. From a geotechnological perspective, the study integrates deep learning techniques and geographic information systems to identify and represent the spread of the virus in densely populated urban environments. The theoretical framework draws on concepts such as Sociospatial Conditionals of Health and Epidemiological Geointercalation, which explain health vulnerability as the outcome of cumulative interactions between structural, environmental, and clinical factors. Based on official data and using inverse distance weighting (IDW) interpolation, two predictive models were applied: CNN+LSTM and XGBoost. The latter identified hypertension as the main explanatory factor in nine boroughs, followed by diabetes and obesity. Although air pollutants had a lower overall weight, sulfur dioxide and asthma gained relevance in boroughs such as Iztapalapa and Gustavo A. Madero. The findings support the use of spatial models enhanced by artificial intelligence to understand complex urban health spatiotemporal dynamics and underscore the importance of territorially disaggregated microdata for more effective and context-sensitive territorial health management.

Key words: Spatio-temporal dynamics, Sociospatial Conditionals of Health, COVID-19, Artificial Intelligence

Introducción

A lo largo de la historia, diversos brotes epidemiológicos han puesto en riesgo la vida de naciones enteras, generando profundas afectaciones económicas y sociales a nivel global. Un caso histórico emblemático fue la epidemia de cólera de 1854 en Londres, que marcó el inicio de la planificación moderna y la identificación de sitios con mayor riesgo epidemiológico.

Diversas disciplinas científicas han estudiado la dinámica de propagación de enfermedades para comprender sus patrones y efectos. La geografía también se ha destacado por analizar la distribución espaciotemporal de enfermedades, identificar áreas de mayor riesgo, explicar las dinámicas espacio – temporales, evaluar su impacto geográfico; así como el análisis de la accesibilidad a servicios de salud y proponer políticas públicas focalizadas intersectoriales en materia de salud.

La geografía, en conjunto con la planificación urbana, considera al COVID-19 como un fenómeno evolutivo atípico que ha impactado principalmente a la población urbana. Durante la pandemia interactuaron factores sociales, demográficos, étnicos, económicos, de infraestructura y ambientales que incidieron en una notable variabilidad espacial en las ciudades, condicionando tanto la propagación como el impacto de la enfermedad.

Derivado de lo anterior, la ciencia geográfica ha implementado modelos espaciales de localización, causalidad, correlación, evolución y distribución del brote epidemiológico, con el apoyo de herramientas geoinformáticas como son los Sistemas de Información Geográfica (SIG), programación, modelos estadísticos e Inteligencia Artificial (IA). Estos modelos deben ser capaces de captar la complejidad de las dinámicas territoriales para ofrecer respuestas integrales ante escenarios de crisis sanitaria, para generar conocimiento geográfico a fin de contribuir en una sociedad más preparada, para reducir los impactos de fenómenos inesperados como la COVID-19.

Esta investigación tiene como objetivo: modelar la dinámica espaciotemporal de los casos de contagio por COVID-19 en la Ciudad de México, como base para generar un prototipo espacial basado en Inteligencia Artificial considerando características geográficas, ambientales y epidemiológicas.

Esta investigación aporta elementos geográficos para atenuar la influencia del COVID-19 como una de las enfermedades respiratorias con mayor impacto a nivel mundial y nacional, principalmente en la estación invernal. El nivel de desagregación territorial es la alcaldía (antes delegación) a fin de identificar las heterogeneidades urbanas vinculadas a la distribución del riesgo sanitario. Dichas heterogeneidades, condicionadas por factores ambientales, económicos, sociales y epidemiológicas, que inciden directamente en la dinámica del contagio y en la capacidad de respuesta institucional. El análisis de estos factores constituye conocimiento clave para el diseño de políticas públicas orientadas al desarrollo urbano sostenible y al fortalecimiento de los sistemas de salud pública a nivel nacional, que coadyuvan al logro de los ODS 3 Salud y bienestar y ODS 11 Ciudades y comunidades sostenibles.

El presente estudio se estructura en cuatro capítulos. El Capítulo I desarrolla el marco teórico-conceptual, con base en los principios fundamentales de la geografía y su aplicación en la geografía de la salud. Se abordan los condicionantes socioespaciales que inciden en los riesgos sanitarios, y se analiza el papel de las geotecnologías y la inteligencia artificial en el análisis de fenómenos territoriales epidemiológicos complejos. El Capítulo II expone la metodología basada en un enfoque longitudinal y cuantitativo, aplicada al contexto urbano de la Ciudad de México. Se detallan las fuentes de información utilizadas, las variables e indicadores seleccionados, así como las etapas del proceso analítico. El Capítulo III examina la evolución espacio-temporal de las enfermedades respiratorias infecciosas entre 2009 y 2019, donde se identifica las dinámicas espacio-temporales en relación con los niveles de contaminación ambiental y diversos factores geográficos previos a la pandemia de COVID-19. Finalmente, el Capítulo IV analiza la dinámica territorial del COVID-19, su distribución diferenciada y las condiciones estructurales asociadas a su propagación. En este apartado se formula un modelo predictivo sustentado en variables ambientales, y epidemiológicas, orientado a comprender la lógica espacial del contagio.

Antecedentes

Derivado de las crisis sanitarias ocurridas a nivel mundial, diversas áreas del conocimiento han desarrollado investigaciones enfocadas en proporcionar soluciones ante la pandemia del virus SARS-CoV-2. Diferentes publicaciones han demostrado que el control, mitigación y prevención de enfermedades transmisibles requieren conocimientos epidemiológicos, geográficos, sociodemográficos y el uso de herramientas tecnológicas avanzadas.

En este contexto, la geografía ha empleado Sistemas de Información Geográfica (SIG) para analizar la localización, distribución, asociación, y evolución de las enfermedades infecciosas como la tuberculosis, la influenza H1N1, el ébola y el COVID-19. Este enfoque ha resaltado la necesidad de desarrollar modelos predictivos más precisos e inteligentes que prevengan la salud urbana.

Actualmente es el caso de las aplicaciones de algoritmos de Inteligencia Artificial (IA) que durante las pandemias se han implementado como elementos clave para respaldar actividades de salud pública, incluyendo la prevención, el monitoreo y la toma de decisiones. Estas herramientas marcan el inicio de un enfoque integrador en la salud pública urbana. En los últimos años, se han desarrollado investigaciones de carácter multidisciplinario, las cuales se describen a continuación.

Escala mundial

Durante una crisis sanitaria, la toma de decisiones rápidas e informadas es fundamental. Sin embargo, esto representa un desafío para los investigadores debido a la escasez de información a escalas locales, la limitación de recursos y las estrictas exigencias de tiempo.

Las geotecnologías, combinadas con la Inteligencia Artificial (IA), han permitido desarrollar modelos computacionales que responden a crisis sanitarias causadas por conflictos bélicos, desastres naturales y brotes epidemiológicos, abordando diferentes escalas espaciales de análisis.

Particularmente, el caso de las enfermedades respiratorias, se han llevado a cabo investigaciones para analizar tendencias y patrones espaciotemporales del Síndrome Respiratorio Agudo Severo (SARS). Estas incluyen el desarrollo de páginas web que permiten el monitoreo global de áreas vulnerables y de riesgo (Kamel Boulos, 2004).

Investigaciones a escala global han aplicado técnicas de IA, como las Redes Neuronales Artificiales (ANN, por sus siglas en inglés), para modelar la interacción entre variables socioeconómicas y enfermedades infecciosas. Mansour et al. (2022) identificaron que las tasas de morbilidad y mortalidad tuvieron un impacto considerable en naciones del hemisferio sur sobre todo con ingresos económicos limitados. Para enfrentar esta problemática, desarrollaron modelos computacionales diseñados para la estructuración de estrategias orientadas al control de la transmisión y la mitigación de riesgos asociados a enfermedades contagiosas.

Asimismo, Kianfar et al., (2022) emplearon Redes Neuronales Multicapa (por sus siglas en inglés, MLP: *Multilayer Perceptron*) para evaluar la relevancia y la correlación espacial de 75 indicadores sociales, epidemiológicos y de calidad del aire a nivel global. Sus hallazgos demostraron que las MPL constituyen herramientas capaces para abordar desafíos epidemiológicos vinculados a determinantes sociales y ambientales, resaltando su utilidad en el análisis integrado de múltiples dimensiones.

Investigaciones basadas en el uso de SIG han evidenciado que los factores geográficos y ambientales, como el clima (Chen et al. 2021; Su et al. 2020), temperatura (Bashir et al., 2020; Bedford et al., 2015), humedad relativa (Dalziel et al., 2018; Thai et al., 2015), calidad del aire (Fattorini y Regoli, 2020; Bert y Stephen, 2002) y condicionantes de la salud, como los ingresos (Patel et al., 2020), número de integrantes de la familia (Truong & Asare, 2021), la actividad económica (Banco de México, 2020), nivel educativo (Faghri et al., 2021), densidad de población (Teller, 2021), el sexo (Nielsen et al., 2021b) y población vulnerable (Decoster et al., 2021b) influyen significativamente en el incremento de la morbilidad y la mortalidad asociadas al COVID-19.

Estudios recientes han demostrado que grupos poblacionales como las personas con bajos ingresos, trabajadores ocasionales, adultos mayores, migrantes, personas con antecedentes de discriminación (Grill et al., 2021) han sufrido las consecuencias de la

pandemia. Las limitantes socioeconómicas, las deficiencias hospitalarias y la gestión de políticas públicas han sido una muestra clara de la realidad países en vías de desarrollo.

Ante este escenario, las principales causas de contagio y propagación de enfermedades respiratorias, como el virus COVID-19, se relacionan directamente con las desigualdades sociales y económicas. Esta situación ha puesto en riesgo tanto la salud como la vida de amplios sectores de la población.

Por otra parte, en Hong Kong, se estudiaron los patrones de propagación del SARS, identificándose que las áreas con mayor número de casos se concentraban en zonas con alta densidad poblacional (Lai et al., 2004). Por otro lado, en China, Jiang et al. (2011) aplicaron modelos de autocorrelación espacial para el análisis de las posibles causas de propagación de la influenza H1N1. Sus hallazgos revelaron que los factores sociales de riesgo de contagio se manifiestan principalmente en espacios públicos.

Desde la aparición del COVID-19, en Asia se han llevado a cabo múltiples estudios sobre la dinámica de propagación de enfermedades respiratorias y su relación con factores ambientales. En China, Song et al., (2021) propusieron un método de análisis de concentración las correlaciones de la contaminación del aire y la incidencia a la influenza (H1N1) en las principales ciudades de China. Sus resultados evidenciaron una correlación espacial positiva entre los altos niveles de contaminación y la incidencia de la influenza.

En el contexto de la pandemia por COVID-19 Yang et al., (2020) desarrollaron un modelo de IA para la predicción de factores de contagio con el método de Susceptible, Expuesto, Infeccioso, Eliminado (SEIR) el cual fue el más preciso para pronosticar los posibles picos y tamaños de brotes de contagio.

Posteriormente, Lin et al., (2021) exploran la correlación entre factores climáticos y la mortalidad de COVID-19 en Wuhan mediante métodos de autocorrelación espacial. Identificaron que existe una correlación positiva entre factores atmosféricos y la propagación del virus en áreas centrales de la ciudad.

Por otro lado, Wang et al., (2022) evaluaron la efectividad de la IA en la prevención, control de infecciones durante la primera ola de COVID-19. Para ello, analizaron los historiales de viajes, grupos de contacto, tasa de letalidad, entre otros. En este estudio, se

demonstró que la identificación y las alertas tempranas de brotes de enfermedades con técnicas de IA y los SIG son un elemento clave para la prevención de enfermedades transmisibles.

En India, Mishra et al., (2020) propusieron, a inicios de la pandemia, un índice de vulnerabilidad urbana por coronavirus con datos demográficos, salud mental, morbilidades respiratorias y condiciones de vida. Este índice permitió identificar que el aumento de la vulnerabilidad a los contagios estaba estrechamente relacionado con las medidas de distanciamiento social y la disponibilidad de agua potable, elementos clave para garantizar el cumplimiento de protocolos sanitarios en zonas urbanas.

Por su parte, Das y Beborrtta (2022) emplearon un análisis de decisiones de criterios múltiples para identificar regiones críticas de contagio. Además, propusieron un modelo de aprendizaje profundo (Deep Learning, DL, por sus siglas en inglés) orientado a apoyar a los tomadores de decisiones en el diseño de políticas públicas de salud.

En Irán, Mohammad Ayyoubzadeh et al (2020) aplicaron un modelo de minería de datos combinado con técnicas de aprendizaje profundo para predecir la propagación del COVID-19. Este estudio analizó las tendencias de búsqueda en Google junto con los casos positivos de COVID-19, lo que permitió anticipar brotes de la enfermedad.

Pourghasemi et al (2020) utilizaron técnicas de aprendizaje automático para analizar las condiciones hidrometeorológicas, la movilidad de origen y destino hacia centros de servicios especializados, e identificar los factores que incrementan el riesgo de contagio en la provincia de Fars, Irán.

Razavi-Termeh et al (2022) elaboraron un mapa de vulnerabilidad al contagio en diversas provincias iraníes mediante el uso de redes neuronales artificiales. Este análisis demostró que la densidad de población y las zonas con un mayor número de adultos mayores tienen un impacto significativo en el riesgo de contagio.

Moneer Yahya et al (2021) propusieron modelos para pronóstico de series temporales, regresión lineal en pacientes infectados, recuperados y defunciones que fueron muestras para predecir a futuro posibles casos de pacientes infectados en un periodo de seis meses.

En Italia, Gatto et al (2020) desarrollaron un modelo espaciotemporal para el análisis de la propagación del coronavirus mediante el método Markov Monte Carlo (MCMC). Este

modelo integró variables del enfoque Susceptible, Expuesto, Infeccioso y Recuperado (SEIR), así como factores socioeconómicos, para modelar la dinámica de la pandemia a corto plazo.

Murgante et al (2020) emplearon técnicas de análisis espacial para identificar la correlación y distribución geográfica de la mortalidad asociada al COVID-19. Su estudio consideró variables geográficas, ambientales y socioeconómicas, destacando que factores como la densidad de población y la movilidad urbana actúan como elementos de atracción hacia las áreas urbanas. Esto, a su vez, influye significativamente en la calidad del aire y contribuye al incremento de brotes de contagio, especialmente en zonas periféricas con alta afluencia de personas.

En Suiza Marini et al (2020) desarrollaron un modelo de IA para predecir la evolución de la pandemia. Este modelo incorporó variables relacionadas con viajeros fronterizos, transporte, condiciones de vivienda, enfermedades crónicas, factores climáticos e infraestructura hospitalaria.

Por otro lado, en África, Mukandavire et al (2020) diseñaron modelos de IA para la cuantificación de la transmisibilidad temprana del COVID-19. Su estudio destacó que el enfoque SEIR es particularmente adecuado para la predicción preliminar a corto plazo de la transmisibilidad del virus.

En California, Aleuy et al (2018) identificaron la agrupación estadística de múltiples cepas de Bronquitis Infecciosa (BI) en el periodo de 2008-2012 por medio de modelos multinomiales y permutaciones espaciales, los cuales permitieron la elaboración de simulaciones a largo plazo.

Así mismo, Tiwari et al (2021) desarrollaron un modelo de Machine Learning para el cálculo del Índice de Vulnerabilidad COVID-19 (C19VI) utilizando variables socioeconómicas a nivel de condado. Los resultados demostraron que el índice C19VI puede predecir de manera precisa y confiable los daños potenciales asociados al virus.

Almalki et al., (2022) analizaron la correlación espacial entre factores de salubridad, alimentación y su asociación con la propagación con de COVID-19 mediante un modelo de Regresión de Aprendizaje Automático. Sus hallazgos evidenciaron que las comorbilidades

preexistentes y la pobreza son factores clave que explican la propagación del COVID-19 en Estados Unidos.

En el caso de Latinoamérica, Castro et al (2021) analizaron la dinámica de dispersión espacial por coronavirus en Brasil utilizando un método bayesiano y análisis de Moran. Este estudio identificó que las zonas turísticas y comerciales con alta concurrencia son puntos críticos de contagio, resaltando la influencia de la actividad económica en la propagación del virus.

A escala global, se han desarrollado numerosas investigaciones de carácter multidisciplinario que convergen en tres pilares fundamentales para la comprensión y gestión de eventos pandémicos: (i) la geografía de la salud, (ii) la inteligencia artificial y (iii) los Sistemas de Información Geográfica (SIG). Los trabajos analizados coinciden en la importancia de integrar variables sociales, ambientales y de la salud, al reconocer que estas condicionantes inciden de manera significativa en los patrones de contagio de enfermedades respiratorias infecciosas, como el COVID-19.

Existe consenso entre diversos autores en que la propagación de estas enfermedades no debe analizarse únicamente desde una perspectiva biológica, sino como resultado de una compleja interacción entre factores socioespaciales. En este sentido, Mansour et al. (2022), Kianfar et al. (2022), Das y Beborrtta (2022), así como Yahya et al. (2021), subrayan la efectividad de modelos basados en Redes Neuronales y técnicas de aprendizaje profundo, dada su capacidad para integrar un amplio espectro de variables y adaptarse a distintos contextos geográficos. Por su parte, Fattorini y Regoli (2020) y Song et al. (2021) destacan la relevancia de incorporar factores ambientales especialmente la calidad del aire y las condiciones climáticas en los análisis epidemiológicos, al evidenciar su relación directa con los niveles de morbilidad y mortalidad.

Si bien se identifican divergencias metodológicas, por ejemplo, en los estudios de Wang et al. (2022) y Mukandavire et al. (2020), que centran su enfoque en modelos epidemiológicos SEIR con estructuras más rígidas frente a enfoques de aprendizaje automático más flexibles, todos los autores coinciden en la necesidad de desarrollar herramientas predictivas multidimensionales. Dichas herramientas deben ser capaces de

captar la complejidad de las dinámicas territoriales para ofrecer respuestas integrales ante escenarios de crisis sanitaria.

Escala nacional

Las enfermedades respiratorias infecciosas epidémicas y pandémicas en México han sido un incentivo de investigación geográfica en las últimas décadas. En este contexto, se han desarrollado estudios sobre estas que han destacado por su aporte al análisis de los patrones espacio temporales. Zaragoza Bastida et al (2012) demostraron, mediante el uso de SIG, que la distribución espacial de la tuberculosis se concentra principalmente en zonas cercanas a las periferias de la Ciudad de México.

A inicios de la pandemia de COVID-19, Bello-Chavolla et al (2021) identificaron los determinantes estructurales y de salud que incrementan la susceptibilidad al contagio. Utilizando el método de Newton-Raphson, aplicaron un modelo de regresión de riesgos proporcionales de Cox con datos de casos sospechosos, variables sociales y epidemiológicas se encontró que las comorbilidades en conjunto con la edad son un determinante estructural de contagio y muerte por COVID-19.

Conde-Gutiérrez et al (2021) realizaron la predicción de muertes con base en los datos acumulados de las defunciones por COVID-19 en México. Compararon el rendimiento del algoritmo de Levenberg-Marquardt y BFGS (Broyden-Fletcher-Goldfarb-Shanno), concluyendo que el último se ajusta mejor a los datos reales disponibles.

Los análisis espaciales han sido herramientas clave para la toma de decisiones y la identificación de patrones correlacionales de contagios, defunciones ocasionadas por el coronavirus. Ramírez-Aldana et al (2021) realizaron un análisis epidemiológico espacial temprano del brote de contagios en México y hallaron que los casos de contagios están principalmente asociados con enfermedades metabólicas, migraciones internas y externas, la escases de personal médico por habitantes y las condiciones de económicas en áreas urbanas.

Sierra-Alcocer et al (2022) propusieron un Índice de Vulnerabilidad Social Dinámica (DvSoVI) capaz de medir la evolución de exposición de la población la vulnerabilidad de ciertos lugares y la susceptibilidad al contagio por COVID-19. Este índice incluye variables

como la tasa de mortalidad, acceso a servicios de salud e infraestructura hospitalaria, rezago educativo, pobreza, vivienda, ingresos, nutrición y enfermedades crónicas degenerativas.

También, se analizaron los patrones de distribución espacial y densidad de casos con el método de densidad de Kernel y la Desviación Elipse Estándar. Estos análisis, basados en datos de ocurrencia de contagios, tránsito vehicular, accidentes e inundaciones, identificaron que los estados conurbados a la Ciudad de México tienen un mayor riesgo de propagación del SARS-CoV-2. Las zonas con alta movilidad peatonal y vehicular, las áreas comerciales y las residenciales con intensa actividad económica fueron identificadas como focos de transmisión significativa (Barajas-Carrillo et al., 2022; Vilchez et al., 2022).

La pandemia causada por el SARS-CoV-2 ha marcado profundamente la historia contemporánea, exponiendo desigualdades sociales, hospitalarias y económicas a nivel global. En México, la desigualdad en el acceso a la atención médica afecta principalmente a pacientes con ingresos limitados, adultos mayores y personas con comorbilidades, quienes son particularmente vulnerables al contagio y sus consecuencias (Mollalo et al., 2020). Las comunidades más desfavorecidas, que habitan en zonas urbanas densamente pobladas y de difícil acceso, enfrentan mayores riesgos debido a la falta de equidad en la provisión de servicios de salud (Gustafsson et al., 2022).

Los estudios desarrollados en el contexto nacional comparten una preocupación común por identificar patrones espaciales y sociales que explican la propagación del COVID-19 en México, coincidiendo en que las desigualdades estructurales como el acceso limitado a servicios de salud, la pobreza, la movilidad urbana y la presencia de comorbilidades han exacerbado la vulnerabilidad de ciertos grupos poblacionales. Autores como Bello-Chavolla et al. (2021) y Sierra-Alcocer et al. (2022) coinciden en reconocer la influencia de los condicionantes sociales y estructurales en la exposición y el desenlace de la enfermedad, aunque difieren en sus métodos de análisis el primero mediante modelos estadísticos clásicos y el segundo a través de la construcción de un índice multidimensional. Asimismo, Conde-Gutiérrez et al. (2021) priorizan enfoques de predicción algorítmica centrados en el comportamiento de las curvas de mortalidad, estudios como el de Ramírez-Aldana et al. (2021) se enfocan en comprender los patrones territoriales mediante análisis espacial temprano.

Estas investigaciones ofrecen una base sólida para comprender la dimensión geográfica de la pandemia en México; sin embargo, se requiere de enfoques que no solo describan la desigualdad territorial, sino que propongan mecanismos concretos para intervenir en ella, integrando análisis cuantitativos y cualitativos que den cuenta de las experiencias sociales del contagio en los territorios más vulnerables.

Planteamiento del problema

De acuerdo con los datos presentados por el Institute for Health Metrics and Evaluation (IHME) para el 2019 la población mundial se encontraba en riesgo de salud debido a que 74.37% falleció de alguna enfermedad no transmisible crónica degenerativa como es el caso de enfermedades cardiovasculares, digestivas, diabetes mellitus, entre otras. Con respecto a las enfermedades transmisibles 18.3% de la población falleció de VIH/SIDA, infecciones de transmisión sexual (ETS), infecciones respiratorias y tuberculosis, infecciones entéricas (bacterianas y parasitarias), malaria, etcétera y el resto fallecieron por lesiones en el transporte, autolesiones y violencia. a finales del 2019, la Ciudad de Wuhan ubicada en la provincia de Hubei en China, fue identificada como la ciudad dónde se presentó el primer paciente infectado por el virus de COVID-19, el cual se expandió rápidamente en 214 países afectando la salud pública de la población mundial además provocando el aumento acelerado del número de casos infectados (Pham et al., 2020).

Como respuesta directa a esta propagación acelerada y su impacto global, el Dr. Tedros Adhanom Ghebreyesus director general de la Organización Mundial de la Salud (OMS) el 11 de marzo de 2020 declaró a la crisis sanitaria como “pandemia” haciendo un llamado a todas las naciones a tomar medidas de prevención de atención a pacientes, así como medidas de confinamiento, distanciamiento físico e higiene, situación que provocó el cierre de centros educativos, restaurantes, negocios, se limitaron los viajes nacionales e internacionales, reuniones sociales además se convocó a las naciones hacer cumplir los estatutos de confinamiento sanitario (World Health Organization, 2020c).

El ingreso de pacientes en hospitales públicos y privados aumentó de tal forma que para el 16 de septiembre 2022 se registró la muerte de 6,529,812 de personas a nivel mundial,

616,839,350 contagios de los cuales 14,121,868 fueron casos activos, 40,472 que se encontraron en estado crítico por COVID-19 (Worldometers, 2022).

De acuerdo con los datos presentados por la ONU (2020), el mundo se encuentra nuevamente en una crisis sanitaria que ha tenido impactos sociales, económicos, migratorios, educativos, laborales que van mucho más allá del ámbito epidemiológico (Rose-Redwood et al., 2020). Las áreas densamente pobladas, los sitios con altos índices de ocupación de viviendas y los ingresos *per capita* son factores que fluyen en probabilidades de propagación del virus SARS-CoV-2 (Molina-Torres et al., 2021).

El confinamiento, el desempleo, la falta de servicios en el hogar, la marginación, la desigualdad social han sido algunos de los factores que más han afectado a la población que vive en condiciones de bajos ingresos de tal modo que imposibilitan a familias completas a no cumplir con las medidas de sanidad propuestas por la OMS dando como resultado el aumento del riesgo de contagio y defunción, así como el incremento de probabilidad de surgimiento de nuevas oleadas epidemiológicas y variantes del COVID-19 (Capistran et al., 2021).

De acuerdo los datos proporcionados por OMS sobre el coronavirus COVID-19 en México se han reportado los siguientes datos (Tabla 1) de enero de 2020 hasta el 31 diciembre de 2022 se identificaron de manera exponencial cinco curvas epidemiológicas de las cuales se han presentado principalmente en espacios urbanos y en particular en la Ciudad de México.

México enfrentó diversos a diversos desafíos en materia de servicios públicos como es el caso de infraestructura de salud, acceso a medicamentos, pruebas COVID-19, situación que ha provocado el incremento de casos confirmados y en el peor de los casos el aumento de defunciones. Para marzo de 2022 México se posicionó en el 20vo lugar como uno de los países con mayor número de contagios.

Tabla 1 Registro de casos COVID-19 en México

Periodo	Casos confirmados	Casos de defunciones
Enero a junio 2020	269,344	39,946
Julio a diciembre 2020	1,226,723	107,677
Enero a junio 2021	1,045,450	91,920
Julio a diciembre 2021	1,497,831	63,752

Enero a junio 2022	2,073,868	22,470
Julio a diciembre 2022	1,136,465	4,945
Total	7,249,681	330,710

Fuente: World Health Organization (2022)

Cabe señalar que, en México los epicentros de la pandemia por COVID-19 se presentaron principalmente en ciudades, siendo una de ellas la Ciudad de México, por ser la que alberga la mayor población, movilidad, zonas de empleo, centros educativos, entre otros. Actualmente no existe un modelo geográfico basado en IA de la dinámica espacial de la pandemia de COVID-19, considerando características geográficas, ambientales, epidemiológicas y socioeconómicas de la Ciudad de México.

La pandemia derivada del virus SARS-CoV-2 (COVID-19) se ha manifestado a través de diversas dinámicas interrelacionadas, muchas de ellas con implicaciones espaciales significativas, como el aumento de población desempleada, cierre de negocios de alimentos, centros educativos, cierre parcial o total de frontera, espacios públicos sin personas, calles vacías, desigualdades sociales y disparidades económicas que han llevado a entender el fenómeno como geográfico que es potencialmente cartografiable visto desde las ciencias de la salud, las ciencias sociales, la ingeniería, etcétera es posible correlacionar elementos espaciotemporales para la formulación de respuestas científicas, políticas apropiadas, la proyección de distribución espacial y las tendencias temporales de la propagación del virus (Franch-Pardo et al., 2020).

Para el caso de la Ciudad de México existen pocos estudios de la dinámica espaciotemporal de los casos de contagios y defunciones por COVID-19, en la actualidad no se ha diseñado una propuesta de un modelo integral espacial donde se analicen los condicionantes de la salud como son los geográficos, ambientales, socioeconómicos y epidemiológicos basado en IA.

Los brotes de enfermedades infecciosas representan una amenaza para la salud de la población de todo el mundo; la enfermedad por coronavirus (COVID-19) ha causado una emergencia sanitaria que demanda investigaciones integrales para el análisis del comportamiento de la infección y es una oportunidad para atender las necesidades de la población por parte de las organizaciones gubernamentales del mundo. Bajo este contexto surgen los siguientes cuestionamientos.

Preguntas de investigación

1. ¿Desde la perspectiva geográfica qué discusiones teóricas – metodológicas se han realizado sobre modelos espaciales de Inteligencia Artificial de la dinámica espaciotemporal y tendencias de la pandemia por COVID-19?
2. ¿Cuáles condicionantes socioespaciales geográficos, ambientales, socioeconómicos y epidemiológicos incidieron en la tendencia de la distribución y permanencia de la pandemia de COVID-19 en la Ciudad de México?
3. ¿Cómo diseñar y aplicar un modelo integral de Inteligencia Artificial que permita el monitoreo y tendencia de la dinámica espacio – temporal de la pandemia de COVID-19 en la Ciudad de México, de acuerdo con los condicionantes socioespaciales de la salud?

Justificación

Científica académica

El análisis de diversas teorías relacionadas con la salud como la teoría de Lerner, Omran y Frenk (Bolaños, 2000; Hernández Bernal & Santana Juárez, 2022) que explican la transición epidemiológica, la desigualdad sanitaria o la polarización de la morbilidad, las cuales son la base, sin embargo desde la geografía se le incorpora la dimensión espacial, que permite esa interrelación de factores geográficos, ambientales, sociales y epidemiológicos que muestran la variabilidad espacial de la COVID-19 en México, en territorios específicos en este caso las alcaldías de la Ciudad de México.

El diseño de un modelo basado en IA de la tendencia espacial de la pandemia de COVID-19 en la Ciudad de México, puede ser posible diseñarlo considerando características geográficas, ambientales, epidemiológicas y socioeconómicas, que permitirá una visión integral de este fenómeno. A partir dicho modelo es posible analizar, monitorear y predecir los factores geográficos que inciden en la propagación y distribución de la pandemia por COVID-19 en la Ciudad de México.

Un modelo de inteligencia artificial de la dinámica espacio temporal de la COVID-19 de la Ciudad de México, constituye un aporte científico para tomadores de decisiones a largo,

mediano y corto plazo que coadyuva en la reducción de desigualdades en salud y en la reducción de costos sanitarios que impactan a nivel general, familiar e individual. Un modelo estratégico de IA es base en el diseño de políticas públicas focalizadas para mejorar la salud de la población en las etapas de la prevención de enfermedades y promoción de la salud.

Contextual: geográfica, ambiental, socioeconómica y epidemiológica)

Los brotes de enfermedades respiratorias durante las últimas décadas se han convertido en un problema global que ha afectado la vida de millones de personas alrededor del mundo, diversos investigadores han hecho uso de herramientas geográficas como los SIG para la ubicación de riesgos, pronósticos espaciales, monitoreo, así como el diseño de modelos de logística para la gestión y distribución de suministros (Pourghasemi et al., 2020)

La situación actual del virus SARS-COV2 que produce la enfermedad de COVID-19 ha generado un riesgo crítico de contagios, el uso de modelos de Inteligencia Artificial (IA), mapas, SIG, tableros estadísticos son herramientas de gran utilidad para ayudar a los gobiernos locales e internacionales a la toma de decisiones para controlar y mitigar el alto riesgo de contagios por el virus

Además, esta investigación coadyuva en los Objetivos del Desarrollo sostenible de la Agenda 2030 de las Naciones Unidas, en específico en dos objetivos:

- Objetivo 3 Salud y bienestar: Garantizar una vida sana y promover el bienestar de todos en todas las edades”.
- Objetivo 11 Ciudades y comunidades sostenibles: Lograr que las ciudades y los asentamientos humanos sean inclusivos, seguros, resilientes y sostenibles”.

Hipótesis

El diseño de un modelo espacial basado en Inteligencia Artificial que represente la dinámica espacio-temporal y las tendencias de la pandemia de COVID-19 en la Ciudad de México, durante las cinco curvas epidemiológicas comprendidas entre 2020 y 2023, es viable a partir de la variabilidad de los condicionantes socioespaciales de la salud como: la localización, las condiciones meteorológicas, la contaminación atmosférica y la presencia de comorbilidades. Este modelo permite optimizar los procesos de análisis, establecer la

tendencia de propagación del virus SARS-CoV-2 y fortalecer los mecanismos de monitoreo y predicción.

Objetivos

Objetivo general

Modelar la dinámica espacio - temporal de los casos de contagio por COVID-19 en la Ciudad de México, como base para generar un prototipo espacial basado en inteligencia artificial considerando características geográficas, ambientales y epidemiológicas.

Objetivos particulares

1. Construir un marco teórico – conceptual para el análisis de la dinámica de la pandemia por COVID-19, fundamentado en la geografía y modelos espaciales de Inteligencia Artificial
2. Analizar la dinámica espacio - temporal de la pandemia por COVID-19 a partir de los condicionantes socioespaciales de la salud.
3. Diseñar un modelo espacial integral basado en Inteligencia Artificial de la dinámica espacio - temporal de la pandemia de COVID-19 con base en los condicionantes socioespaciales de la salud que permita el análisis de la tendencia y predicción de casos de contagios.

Capítulo I

Marco teórico conceptual

Capítulo I. Marco teórico conceptual

1.1 Fundamentos de la geografía

1.1.1 Geografía

Desde su concepción más clásica la geografía es la ciencia que se encarga de estudiar la distribución y las características de la superficie terrestre, Además, se dedica al estudio de la Tierra en su totalidad que incluye las características físicas, humanas y su relación con el espacio geográfico.

1.1.2 Principios de geografía

(a) Localización: es uno de los elementos que hace referencia al lugar y la ubicación en la comprensión de fenómenos y procesos geográficos, es fundamental para comprender la relación espaciotemporal del hombre y sociedad en el espacio geográfico. El deber del geógrafo es conocer con exactitud dónde se produce el fenómeno estudiado (Berry, 1964). (b) Causalidad: este principio sugiere que los fenómenos y procesos del espacio geográfico no son aislados, estudia las causas que originan, agravan e incrementan un fenómeno en el espacio. (c) Evolución: es uno de los principios que se relaciona con el proceso de incremento, decremento de un fenómeno, requiere un análisis histórico que da punto de partida para conocer la dinámica espaciotemporal de agentes transformadores; (d) Correlación o conexión, la correlación proviene de las relaciones e interacciones del hombre con su medio; (e) Comparación: se refiere a la importancia de contrastar, áreas, regiones, procesos sociales, económicos, ambientales, permite identificar similitudes o diferencias en las relaciones hombre-espacio (Lipp, 2016).

Por medio de los principios de la geografía es posible dar respuesta a los siguientes cuestionamientos derivados de la pandemia por COVID-19 ¿Cuáles son las características espaciales donde se presentan los mayores índices de casos de contagio?, ¿cuáles son las causas sociales, ambientales y epidemiológicas que inciden en la propagación?, ¿cómo se relaciona la pandemia por COVID-19 con comorbilidades de la población más afectada?, ¿cuáles son las regiones con mayor riesgo de contagio a corto, mediano y largo plazo?. Estos cuestionamientos permiten la identificación de demandas en materia de salud que requiere la población a diferentes escalas espaciales de análisis.

Los principios de la geografía permiten una primera aproximación a los fenómenos del espacio, su aplicación ha evolucionado hacia enfoques más complejos que integran teorías, herramientas científicas y metodológicas para abordar problemáticas contemporáneas. Esta evolución ha dado lugar a distintos paradigmas geográficos que no solo enriquecen el análisis espacial, sino que permiten explicar con mayor profundidad los procesos sociales, ambientales y epidemiológicos.

1.1.3 Paradigmas de la geografía para el estudio de COVID-19

1.1.3.1 Paradigma neopositivista

A partir del surgimiento del paradigma neopositivista a mediados del siglo XX en la ciencia geográfica ha adoptado un enfoque metodológico y epistemológico que ha servido para la aplicación de métodos científicos objetivos que expliquen fenómenos geográficos a partir de principios de la lógica, observación, medición de datos empíricos de los fenómenos sociales y ambientales.

Se enfoca en la recopilación de datos empíricos y en la formulación de leyes que rigen la organización del espacio (Reche Cruz, 1987) a partir de la observación de patrones y regularidades en los fenómenos geográficos. Busca la objetividad, precisión y medición del espacio, tiene como premisa eliminar interpretaciones subjetivas de fenómenos geográficos por lo que se fundamenta en la científicidad del espacio medible y cuantificable, pretende alcanzar una visión unificada del mundo (Delgado Mahecha, 2003). Derivado de la necesidad de modelar surge la geografía cuantitativa para modelar la organización espacial de la sociedad.

A partir del interés cognoscitivo que se vivía en la época se da inicio a una nueva geografía que parte de la utilización del método hipotético, deductivo, inductivo para el análisis científico del espacio, donde el lenguaje matemático, estadístico rigen en la ordenación espacial (Pillet Capdepón, 2004), para ello se apoyaron de teorías de la localización que explican través de representaciones cartográficas la realidad de fenómenos del espacio absoluto a partir de modelos geométricos como es la centralidad, accesibilidad, vecindad, aglomeración, nodos, rutas, entre otros.

Nueva geografía

La nueva geografía surgió en la década de 1960 como una respuesta crítica a la geografía tradicional y la geografía regional, se fundamentó como disciplina científica que busca analizar patrones espaciales de los fenómenos sociales y su interacción con el medio ambiente (relación hombre – medio). Desde sus inicios propuso el desarrollo de innovaciones metodológicas que expliquen las relaciones espaciales desde una perspectiva geométrica, encaminada al análisis de localización e interacción espacial de fenómenos socioambientales.

Se desarrollaron modelos explicativos gravitatorios, potenciales, locacionales para identificar patrones espaciales de fenómenos socioeconómicos de la época. Esta corriente del pensamiento dio origen a otras disciplinas geográficas como la geografía urbana, geografía económica, geografía política y la planificación territorial, debido a que es una corriente del pensamiento dinámica se ha caracterizado por su amplio compromiso con el análisis riguroso y científico de procesos espaciales, así como la solución de estos (Ortega Valcárcel, 2000).

Geografía cuantitativa

La revolución cuantitativa en la geografía supuso una reconfiguración profunda del modo en que se abordaban los fenómenos espaciales. Lejos de limitarse a una incorporación técnica, este cambio integró principios estructurales de disciplinas como las matemáticas, la física y la estadística, trasladando sus métodos al análisis territorial. Así, el espacio dejó de entenderse únicamente como un escenario descriptivo para convertirse en una entidad medible, susceptible de ser modelada bajo estructuras lógicas y predictivas. De acuerdo con Sheppard (2001) se enfoca en el uso de herramientas y técnicas estadísticas para analizar y explicar patrones espaciales de fenómenos geográficos, permite el desarrollo de investigaciones precisas y detalladas del espacio.

Se incorporó la estadística como una herramienta para medir las relaciones de variables espaciales a través de métodos de análisis multivariado, correlaciones múltiples, el análisis de componentes principales, análisis factorial, el análisis clúster, así como métodos para calcular pronósticos y predicciones de series de tiempo (Sánchez, 2010).

Su principal objetivo se fundamenta en producir modelos matemáticos y estadísticos que cuantifiquen, explique y predigan procesos espaciales, por ejemplo, la distribución de la

población, el crecimiento urbano, la estructura comercial, modelos de transporte, desde la perspectiva de la salud se ha empelado para la modelación cuantitativa de la propagación de enfermedades y su correlación con factores socioeconómicos.

El análisis espacial ha sido una herramienta útil para la toma de decisiones, en primera instancia permite la identificación de patrones y tendencias espaciales, visualización de la información geográfica, análisis de relaciones espaciales, modelación de procesos sociales y ambientales y la optimización de procesos.

Ante la necesidad de comprender y explicar patrones espaciales que se observan en la superficie terrestre, diversos investigadores como Robles, Brian Berry, William Bunge y André Joliveau desarrollaron nuevas herramientas y métodos precisos para analizar el espacio geográfico a partir de cartografía temática y tecnologías computacionales como los Sistemas de Información Geográfica (SIG), el manejo de grandes bases de datos que permiten hacer simulaciones de sistemas geográficos. Bajo este contexto se da inicio al análisis espacial y a un paradigma geotecnológico.

1.1.3.2 Paradigma geotecnológico

En los últimos tiempos el avance computacional en conjunto con las Tecnologías de la Información y la Comunicación (TIC) han tomado gran importancia en la vida cotidiana de las personas. Las TIC se ha implementado en gran cantidad de campos tales como la industria, la medicina, entretenimiento, ocio, educación, entre otras. En particular, en la geografía ha requerido de herramientas y técnicas informáticas para el almacenamiento, organización y administración de grandes bases de datos espaciales para la automatización de dichos procesos.

Derivado de lo anterior surge un nuevo paradigma geotecnológico que tiene los elementos conceptuales, tecnológicos y de análisis cuantitativo como una nueva visión integral del espacio geográfico por medio de sistemas cibernéticos, humanos y electrónicos para el análisis de sistemas geográfico-ambientales y socioeconómicos (Oropeza & Díaz, 2007).

A partir del avance computacional de la década de 1980 fue posible la automatización de procedimientos de análisis espacial y a partir del surgimiento de la *Automated Geography*

(geografía automatizada). El paradigma geotecnológico consiste en ver la realidad del espacio geográfico a través de las Tecnologías de la Información Geográfica (TIG) y la Geografía global como campo disciplinario (G. Buzai, 2001).

Esta visión digital del espacio geográfico se ha encargado de elaborar modelos de análisis espacial con SIG, Procesamiento Digital de Imágenes (PDI) y Sistemas de Posicionamiento Global (por sus siglas en inglés GPS) mediante el uso de computadoras personales (Buzai, 2001) imágenes de satélite y recientemente drones, sensores, nubes de puntos que permiten la elaboración de un análisis detallado del espacio.

A partir de este conjunto de paradigmas, la geografía ha ampliado su campo de aplicación hacia nuevas áreas de conocimiento para el análisis espacial y la comprensión de las desigualdades territoriales. La geografía de la salud retoma estos enfoques para estudiar cómo los factores físicos, sociales y tecnológicos se entrelazan en la configuración de los patrones espacio temporales de la salud.

1.2 Geografía de la salud

El origen de la geografía de la salud y su relación con el medio ambiente se remota a 1960, cuando se comenzó a investigar y comprender la dinámica de la distribución geográfica de las enfermedades. En este contexto, se empezó a analizar cómo los factores geográficos y socioeconómicos influyen en la propagación espacial de las enfermedades. Según Ortega Valcárcel (2000), esta disciplina se ha recuperado y renovado por tener un enfoque centrado en salud y bienestar de la población. Tiene diferentes campos de actuación, que comprenden procesos de vigilancia de enfermedades, atención, promoción de salud, así como el acceso a servicios de salud de la población (Barcellos et al.,2018).

Algunos de los aspectos que estudia la geografía de la salud es la distribución geográfica de enfermedades donde identifica patrones de distribución, concentración de estas en áreas o regiones específicas; factores geográficos y ambientales, explica cómo factores climáticos, topográficos, hídricos o faunísticos pueden influir de manera directa o indirecta en la aparición y propagación de enfermedades; factores sociales como la movilidad y desplazamiento de poblaciones urbanas e indígenas facilitan la diseminación de enfermedades en zonas de origen y destino; el acceso a servicios de salud.

1.2.1 Dinámica espacio temporal de infecciones respiratorias

El análisis de la dinámica espacio temporal de la propagación de enfermedades infecciosas se encarga de comprender la distribución de patrones temporales y espaciales, se utilizan para medir la dinámica de una enfermedad a través de diferentes grupos de población durante su propagación. Las enfermedades infecciosas no siempre están asociadas con la población infectada y las poblaciones tradicionalmente consideradas vulnerables ya que los riesgos de infección in transmisión son causados por diferentes covariables como la densidad de población, movilidad, condiciones de la vivienda, empleo, cultura y niveles de contaminación (Lan & Delmelle, 2023).

1.2.3 Aspectos conceptuales de la salud

En la salud el término epidemiología se concibe como el estudio minucioso de la distribución y los determinantes que inciden en los eventos de salud, esto abarca tanto los eventos de salud a nivel individual como los fenómenos que afectan colectivamente a las poblaciones humanas. (Littman, 2009). Para abordar el concepto de salud de manera integral se recurre a la Organización Mundial de la Salud (2023), la describe como un recurso fundamental para el desarrollo individual, comunitario y social. Esto va más allá de la ausencia de enfermedad o discapacidad, implicando un estado de completo bienestar físico, mental y social, vinculado en la paz y la seguridad inclusiva de la población. La salud se manifiesta, además, como la capacidad de adaptación a los desafíos cotidianos, el acceso a servicios de salud médica, y la influencia del entorno físico y social que promueva el bienestar y el desarrollo sostenible.

En el ámbito de la morbilidad, hace referencia al estado sintomático o no saludable de una enfermedad o condición, cuya estimación se lleva a cabo por su prevalencia o incidencia. La primera describe la proporción y la incidencia muestra la frecuencia de la población con una condición en particular (Bien Hernández & Kim, 2022).

Las enfermedades infecciosas o enfermedades transmisibles se definen como aquellas provocadas por microorganismos patógenos, como las bacterias, virus, parásitos y hongos, que pueden propagarse de una persona a otra, ya sea de forma directa o indirecta. Los mecanismos de transmisión y de propagación de las enfermedades puede ser a través del contacto directo,

aéreo, acuático o alimentario, vectorial y del medio ambiente (R. Zhang et al., 2020), por ejemplo, por medio de alimentos y el consumo de agua contaminada; por vectores, transmitidas por insectos como los mosquitos y las garrapatas; enfermedades transmitidas al hombre por animales (zoonosis), en particular por la mordida de animales; las enfermedades de transmisión sexual a través de prácticas sexuales inseguras, enfermedades transmitidas por contacto directo con sangre o fluidos corporales infectados. Enfermedades transmitidas por el aire que involucran partículas menores a $5\mu\text{m}$ que se dispersan en el aire y son inhaladas por los individuos como es el caso del COVID-19, influenza H1N1, entre otras (World Health Organization, 2023a).

La comorbilidad, por su parte, engloba la coexistencia de más de un trastorno en un solo individuo estos suelen ser más graves, crónicos y difíciles de tratar en comparación con los trastornos aislados (Sanyaolu et al., 2020). En el contexto de la pandemia por COVID-19 se ha demostrado que las personas con condiciones médicas subyacentes, como hipertensión y diabetes han sido los casos más severos derivados del virus SARS-CoV-2 (Singh et al., 2020). Las personas con algún tipo de padecimiento respiratorio tienen cuatro veces mayor riesgo de contraer el virus en comparación a los que no tienen ninguna afección respiratoria, por ejemplo, pacientes con la enfermedad pulmonar obstructiva crónica (EPOC) han tenido mayor riesgo de enfermarse gravemente por COVID-19 (Zhao et al., 2020).

Actualmente se observa un momento de crisis sanitaria donde la pandemia por coronavirus ha mostrado el estado de salud de la población mundial, la eficiencia del sistema de salud, el monitoreo, censos y conteos de población con algún tipo de padecimiento

1.2.4 Principales teorías para el estudio de la salud

Teoría de la transición epidemiológica Omran (1971)

La teoría de la transición surge de postulados demográficos que explicaban el descenso de la mortalidad en Europa y de los estadios de la sociedad propuestos por Frederiksen, quien señaló en 1969 que los patrones de mortalidad, morbilidad, fecundidad y la organización de servicios de salud son el resultado de las relaciones de procesos económicos (Hernández Bernal & Santana Juárez, 2022).

La teoría de Omran postula la transición de un patrón de causas de muerte por enfermedades infecciosas con alta mortalidad especialmente en edades jóvenes a un patrón dominado por enfermedades degenerativas y enfermedades producidas por la acción del hombre, como las formas más importantes de morbilidad y causas de muerte. La teoría se sustenta en que los cambios de salud y los patrones de enfermedad están estrechamente relacionados con las transiciones demográficas y económicas que constituyen la compleja modernización de países occidentales (Omran, 1971). Los supuestos de la teoría muestran una visión integral de la relación de la población y la salud a lo largo del tiempo. La mortalidad es un factor clave en la dinámica demográfica, durante la transición epidemiológica, las enfermedades degenerativas causadas o exacerbadas por el comportamiento humano reemplazan gradualmente a las pandemias infecciosas como la principal fuente de morbilidad y mortalidad. Además, la teoría muestra que los cambios más significativos en los patrones de salud y enfermedad se concentran en niños y mujeres jóvenes, estos cambios están intrínsecamente relacionados con la demografía, la transformación económica y social de la población (McCracken & Phillips, 2020). También, argumenta la importancia de conocer las variaciones subnacionales en los perfiles y en la actualidad es un referente para la planificación y estrategias de salud (Bolaños, 2000).

Se caracteriza por tres etapas llamadas la causa de muerte dominante, la primera consiste en la edad de la peste y el hambre: donde la mortalidad es alta e indeterminada, situación que impide el crecimiento de la población, este estadio muestra una esperanza de vida baja que oscila entre los 20 y 40 años; la segunda fase de la edad de las pandemias retraídas: la mortalidad es menos frecuente y tiende a desaparecer gradualmente, la esperanza de vida al nacer se incrementa de 30 a 50 años y el crecimiento de la población es sostenido. En la última fase de la edad de las enfermedades degenerativas y las producidas por el hombre: el descenso de la mortalidad continúa y eventualmente se aproxima a la estabilidad, la esperanza de vida al nacer aumenta gradualmente (Omran, 1971).

Posterior a la teoría de la transición epidemiológica, Lerner en 1973, propuso la transición de las condiciones de salud y la transición de la atención sanitaria las cuales están determinadas por procesos de desarrollo social, económico, tecnológico y político (Frenk et al., 1991; Hernández Bernal & Santana Juárez, 2022).

En América Latina, Frenk en 1991 propone el modelo prolongado y polarizado como una propuesta de análisis de transición epidemiológica para países en vías de desarrollo como México donde establece que los estándares de morbilidad y mortalidad son reversibles en espacios urbanos donde se presentan enfermedades no transmisibles y en espacios rurales que padecen enfermedades infecciosas.

- *Modelo prolongado y polarizado de Julio Frenk (1991)*

El modelo de la polarización prolongado de la transición epidemiológica, se propuso como un modelo adaptado a los procesos epidemiológicos en espacios urbanos y rurales de países latinoamericanos, que consiste en la a) Superposición de etapas: este distintivo se enfoca en explicar que las diferentes etapas de la transición epidemiológica se superponen al mismo tiempo en países como México, de tal manera que el número de defunciones por diarreas, enfermedades respiratorias, enfermedades cardíacas, accidentes y violencia eran en proporciones muy similares; b) Contrastación: el cambio de mortalidad a morbilidad ocurre no solo en las enfermedades degenerativas, sino también en procesos infecciosos; c) Transición prolongada: existencia de un estancamiento de morbimortalidad mixta en la que sigue habiendo una gran incidencia de infecciones comunes sin que se llegue al predominio absoluto de los procesos crónicos; d) Polarización epidemiológica: introduce diferencias heterogéneas cualitativas en el tipo de enfermedades que padecen los diversos grupos sociales, las poblaciones más desfavorecidas continúan padeciendo de morbilidades pretransiciones, mientras que las poblaciones más favorecidas experimentan patrones postransicionales (Frenk et al., 1991).

La Tabla 2 integra, de manera sistematizada, los principales enfoques teóricos sobre la transición epidemiológica previamente desarrollados, destacando sus fundamentos conceptuales y aportes al análisis de las transformaciones en los perfiles de salud poblacional.

Tabla 2 Modelos teóricos de transición epidemiológica

Autor	Teoría	Aportes
Frederiksen (1969)	Los estadios de la sociedad	Analizó la evolución económica, demográfica y su relación con problemas de servicios de salud Presentó cuatro estadios de la sociedad Tradicional Transición temprana Transición tardía

		Transición moderna
Omran (1971)	Teoría de la transición epidemiológica	<p>Propone las fases de la causa de muerte dominante:</p> <p>La edad de la peste y el hambre</p> <p>La edad de las pandemias retraídas</p> <p>La edad de enfermedades degenerativas y causadas por el hombre</p> <p>Cambios a largo plazo en los patrones de muerte, enfermedad e invalidez de una población, se presenta junto con transformaciones demográficas, sociales y económicas</p>
Lerner (1973)	Transición de la salud	<p>La transición de condiciones de salud: se refiere a los cambios de frecuencia, magnitud y distribución de las condiciones de salud, expresadas en procesos de mortalidad, morbilidad, e invalidez que influyen en la transición epidemiológica</p> <p>Transición de la atención sanitaria: se refiere a la organización del sistema de salud con respecto al suministro de servicios, está determinada por desarrollos sociales, económicos, políticos y tecnológicos</p> <p>Etapas sucesivas: 1) vitalidad baja, 2) control creciente de la mortalidad, y 3) concepción ampliada de la salud</p>
Frenk (1991)	Modelo prolongado y polarizado	<p>Propone un modelo para espacios rurales y urbanos de países latinoamericanos que consiste en:</p> <p>Superposición de etapas</p> <p>Contrastación</p> <p>Transición prolongada</p> <p>Polarización epidemiológica</p>

Fuente: Elaboración propia con base en (Frenk et al., 1991; Hernández Bernal & Santana Juárez, 2022)

La teoría epidemiológica permite comprender los cambios históricos en los perfiles de salud y enfermedad en distintos contextos sociales. Sin embargo, para profundizar en su análisis desde una perspectiva territorial, es indispensable considerar los factores geográficos y ambientales que inciden en dichos procesos. En este sentido, Ana Olivera constituye un referente clave para vincular las condiciones del entorno con los riesgos sanitarios diferenciados que enfrentan las poblaciones. Como a continuación se explica

1.3 Factores geográficos y ambientales que inciden en la salud de acuerdo con Ana Olivera

Los factores geográficos y ambientales desempeñan un papel importante en la aparición, propagación, control de epidemias y pandemias. Las condiciones ambientales exteriores ejercen una influencia significativa en la salud humana. Esto se debe a las alteraciones a nivel global en las concentraciones de sustancias químicas

en la atmósfera, las cuales pueden generar enfermedades. Por ejemplo, los factores climáticos están asociados con diversas patologías geográficas. El cambio climático y la variabilidad atmosférica imponen exigencias adaptativas al organismo.

Las variaciones térmicas, como las olas de calor o de frío inusuales, pueden incrementar la mortalidad en adultos mayores. En áreas urbanas, el viento puede transportar contaminantes atmosféricos procedentes de sectores industriales. Además, los factores topográficos también influyen al generar un gradiente térmico en las ciudades. Estas suelen exhibir temperaturas superiores en comparación con las zonas rurales debido a procesos de urbanización, efectos de isla de calor urbano y la carencia de áreas verdes (Olivera, 1993).

1.3.1 Climáticos

Las vías respiratorias superiores en climas fríos muestran una alta sensibilidad al aire frío, lo que ha llevado a investigaciones que exploran la conexión entre el aire frío y la rinitis tanto alérgica como no alérgica, subrayando su relevancia en la rinitis, la cual es un factor de riesgo para el desarrollo del asma. También los microclimas, son factores que cumplen una función fundamental en el confort térmico de las personas, dado que el organismo humano dispone de sistemas de regulación térmica susceptibles de ser influenciados por las condiciones ambientales. Las variaciones de estos parámetros pueden influir en la percepción térmica, siendo la alta humedad en verano incómoda debido a que la dificultad de evaporación del sudor, el viento puede intensificar la sensación de frío al incrementar la pérdida de calor corporal (D'Amato et al., 2015; D'Amato et al., 2018).

1.3.2 Meteorológicos

Las condiciones meteorológicas, como altas temperaturas, humedad y los cambios de presión barométrica han sido un factor importante que incide en el aumento de niveles de contaminación, lo que ha demostrado tener un impacto en la salud humana, incluyendo el incremento en visitas a servicios de urgencias, consultas médicas relacionadas con la enfermedad pulmonar obstructiva crónica (EPOC) (Ding et al., 2017). En zonas urbanas las enfermedades respiratorias han mostrado tener una correlación fuerte con variables meteorológicas como la humedad, precipitaciones, y la velocidad del viento (D. S. Zhang et al., 2011)

1.3.3 Antrópicos

Las enfermedades respiratorias virales graves y su relación con altos niveles de contaminación se encuentran estrechamente relacionadas, debido a que impactan a aproximadamente el 10 al 20% de la población. Contaminantes como PM_{2.5}, PM₁₀, el dióxido de azufre, dióxido de nitrógeno, monóxido de carbono y el ozono pueden agravar la susceptibilidad a estas infecciones y aumentar su gravedad. Además, se ha sugerido que una elevada concentración de contaminantes atmosféricos, combinados con ciertas condiciones meteorológicas, podrían favorecer una mayor permanencia de partículas virales en el aire (Domingo & Rovira, 2020).

Las personas que viven en zonas con altos niveles de contaminación del aire tienen mayor probabilidad de sufrir trastornos respiratorios y son más susceptibles a contraer infecciones virales (Marquès et al., 2020). La contaminación atmosférica afecta negativamente el funcionamiento de los cilios, que constituyen la principal barrera de defensa de las vías respiratorias superiores (Xie et al., 2019).

La influencia del entorno geográfico y de los factores ambientales en la salud es innegable; no obstante, estas variables no actúan de manera aislada. Su efecto se ve modulado por aspectos estructurales más amplios que definen las condiciones de vida de la población. Es por lo que resulta necesario integrar el análisis de los determinantes sociales y los condicionantes socioespaciales de la salud, para entender cómo interactúan los contextos sociales, económicos y territoriales en la configuración de escenarios de vulnerabilidad.

1.4 Determinantes sociales de la salud y Condicionantes socioespaciales de la salud

Determinantes sociales de la salud

Hasta 2018, la geografía se había enfocado en el estudio de los determinantes de la salud para comprender la relación del entorno geográfico y la salud de las personas. En este contexto, se identificaron desigualdades de la salud con base en la conceptualización propuesta por la OMS, la cual define a los determinantes de la salud (DSS) como “las circunstancias en que las personas nacen crecen, trabajan, viven y envejecen, incluido el conjunto más amplio de fuerzas y sistemas que influyen sobre las condiciones de vida

cotidiana”. Estas circunstancias son el resultado de la distribución de recursos económicos y poder a nivel local hasta nivel mundial, donde la polarización de desigualdad en salud se ve en países mayormente favorecidos versus países poco favorecidos.

Al mismo tiempo las diferencias en salud pueden identificarse de manera evidente a diferentes escalas de gobierno de un país en el caso de países como México este puede ser en estados, regiones, municipios, localidades, colonias; aunado a ello los determinantes intermedios como los estilos de vida, factores conductuales, psicológicos, acceso a la atención médica, nivel educativo y empleo repercuten en el estado de salud de las personas en lo individual y en lo colectivo.

Dadas la naturaleza conceptual del determinismo social de la salud estudia las características sociales que generan una constante unívoca, sin posibilidad de respuesta, niega la posibilidad de modificar el curso de los acontecimientos del estado de salud de las personas y solo estudia las características sociales y económicas (G. Buzai & Santana Juárez, 2018).

En México Frenk et al., (1986) han estudiado las condiciones de salud de la población y la respuesta social organizada a dichas condiciones bajo tres ejes conceptuales a) las necesidades de la salud, b) los servicios que satisfacen esas necesidades y c) los recursos que se requieren para producir dichos servicios. Este enfoque se encuentra relacionados a la salud pública de la epidemiología y por lo tanto no estudia el espacio geográfico, los factores ambientales y de origen antrópico que inciden en el estado de salud de la población.

Condicionantes socioespaciales de la salud (Buzai y Santana)

Bajo este contexto la geografía requiere de fundamentos conceptuales y metodológicos que permitan comprender las características espaciales a partir de las relaciones del hombre y el espacio geográfico para el análisis de la salud de la población tomando en cuenta que las condiciones sociales, económicas y ambientales no son absolutas, estas varían en tiempo y espacio en cada individuo, por ello se propone abordar a la pandemia de COVID-19 desde los condicionantes socioespaciales de la salud que a continuación se describen.

Buzai y Santana Juárez (2018) definen a los condicionantes socioespaciales de la salud como todo condicionamiento contextual será socioespacial en un tiempo específico que influye en la situación de la salud de la población, pero no la determinan, esto se debe a que siempre existe un margen de incertidumbre que surge de las características individuales y de las respuestas del hombre ante los problemas de salud.

El estudio de la salud humana es posible analizarlo a través de las condiciones de vida de las ciudades poniendo principal atención en la situación laboral y habitacional de la población como un primer acercamiento a las condiciones adversas en espacios urbanos. El fundamento conceptual y metodológico en primera instancia comprueba los contextos socioespaciales a partir de las dimensiones educativas, económicas, de construcción, servicios y pobreza, cada una de estas variables de costo indica que los puntajes más altos corresponden a situaciones desfavorables a partir de categorías de Muy alto, Alto, Medio, Bajo y Muy bajo. Además, muestran cuantitativa y espacialmente las características de áreas prioritarias que requieren atención de servicios de salud como una herramienta útil para tomadores de decisiones y para la implementación de políticas públicas hiperfocalizadas que permitan disminuir disparidades socioespaciales (G. Buzai, 2021).

Como se muestra en la Tabla 3, se establece la distinción entre los determinantes sociales de la salud, propuestos por la OMS (2008), y los condicionantes socioespaciales formulados por Buzai y Santana Juárez (2018).

Tabla 3 Determinantes y condicionantes socioespaciales de la salud

Determinantes	Condicionantes socioespaciales
Las circunstancias en que las personas nacen crecen, trabajan y envejecen, incluyendo el conjunto más amplio de fuerza, y sistemas que influyen sobre las condiciones de vida cotidiana	Parte del determinismo parcial ubicado entre el determinismo y el indeterminismo
Se basa en las inequidades sanitarias	Incorpora la dimensión espacial
Niega a las personas la posibilidad de modificar el curso de los acontecimientos	Las condiciones influyen en la situación de salud, pero no la determinan, siempre existe un margen de incertidumbre.
-Determinismo social: considera como determinantes aspectos sociales -Determinismo geográfico considera como determinantes aspectos ambientales	Todo condicionamiento será socioespacial en un tiempo específico

Estudia características sociales que generan una constante unívoca, sin posibilidad de respuesta del estado de salud de las personas.	Abarca teóricamente la totalidad de condicionantes contextuales, por ejemplo, las condiciones sociales que inciden en la propagación de COVID-19 en zonas urbanas
---	---

Elaboración propia con base en Buzai & Santana Juárez (2018).

Los condicionantes socioespaciales de la salud no se limitan a una argumentación conceptual, requiere de herramientas metodológicas y geotecnológicas capaces de medir y representar la complejidad conceptual. Para ello, las geotecnologías ya consolidadas adquieren un papel estratégico en el estudio de la geografía de la salud al ofrecer posibilidades avanzadas para la integración del espacio, el tiempo y las condiciones preexistentes que configuran los escenarios urbanos y rurales. Su incorporación no solo fortalece el abordaje interdisciplinario, sino que permite la vinculación entre aspectos teóricos conceptuales y las realidades territoriales.

1.5 Geotecnologías en la salud

1.5.1 Sistemas de Información Geográfica

En 1854, John Snow, padre de la epidemiología moderna, identificó grupos de casos de cólera en Londres alrededor de una bomba de agua pública, situación que se convirtió en un punto de contagio debido al agua contaminada. El doctor Snow identificó la distribución espacial de los brotes de contagio y defunciones de cólera a partir de un mapa empírico. Desde entonces la cartografía y las herramientas geográficas han sido elementos importantes dentro de la epidemiología (Lan & Delmelle, 2023).

En la actualidad, es posible identificar diversas funcionalidades de las herramientas geoespaciales, tales como la captura de datos georreferenciados, la gestión y análisis espacial. En un entorno globalizado los SIG pueden integrarse con otras herramientas para abordar las necesidades de salud de la población. Esto incluye el uso de la estadística, programación y algoritmos de Inteligencia Artificial capaces de almacenar, procesar y analizar grandes conjuntos de datos espaciales.

En medio de crisis sociales, ambientales y sanitarias, los SIG han sido un medio para visualizar y analizar las características espaciales de datos epidemiológicos, estos brindan

información científica que permite identificar relaciones espaciales con otras variables e identificar la dinámica de transmisión y la agrupación de enfermedades (M. Xu et al., 2021).

La evolución en el uso de los Sistemas de Información Geográfica ha permitido avanzar hacia enfoques analíticos más robustos en tiempos más reducidos en los que ya no se limita a la representación básica de información territorial, sino que se integran datos masivos y diversos que enriquecen la visualización cartográfica, generando cartografía más detallada y dinámica.

1.5.2 Ciencia de datos espaciales

La ciencia de datos, en términos generales se refiere a los métodos para proporcionar nuevos conocimientos a partir del análisis riguroso de *big data*, integrando conceptos y métodos de disciplinas estadísticas, ingenieriles, computacionales y espaciales. El flujo de trabajo se asemeja a un proceso iterativo de importación y procesamiento de datos, seguido de limpieza, transformación, visualización, modelado y finalmente de comunicación de resultados. La ciencia de datos espaciales es un campo en formación centrado en métodos para procesar, administrar, analizar y visualizar grandes bases de datos espaciales, tiene la ventaja de obtener información dinámica de fenómenos espaciales complejos en diferentes escalas espaciotemporales (S. Wang, 2016).

A medida que las bases de datos espaciales crecen en volumen, variedad y complejidad, su análisis exige herramientas aún más especializadas que permitan interpretar relaciones y prever dinámicas espaciales complejas. La Inteligencia Artificial responde a la necesidad de integrar algoritmos capaces de aprender patrones espacio temporales complejos, automatizar tareas analíticas y generar predicciones con alto nivel de precisión.

1.5.3 Inteligencia Artificial

En las últimas décadas, la inteligencia artificial ha emergido como una nueva revolución industrial, proporcionando soluciones y respuestas a necesidades que demanda la sociedad. En la década de 1950, John McCarthy y Marvin Minsky introdujeron por primera vez el término Inteligencia Artificial, por lo que son considerados los padres fundadores de la IA (Torres, 2020). Debido a sus características de integración, procesamiento y análisis de los datos se han adoptado diferentes conceptos de la IA donde cada ciencia ha aportado

conocimientos y técnicas para avanzar en la creación de sistemas capaces de aprender de manera autónoma. Estos avances han traspasado numerosos aspectos de la sociedad, desde la medicina, el transporte, las finanzas hasta la toma de decisiones. La IA tiene herramientas capaces de organizar, procesar y analizar grandes bases de datos de manera autónoma brindando mayor precisión y eficiencia al tratamiento de datos (León et al., 2022)

Hoy en día muchos aspectos de la vida cotidiana están generando datos que son almacenados en los registros de gobiernos, negocios, sistemas de salud, e incluso los dispositivos móviles registran y reportan todo tipo de información, llevándolos a la era del *Big Data*. Los datos generados son más complejos y en mayor cantidad, por lo cual los algoritmos que procesan y usan estos datos de tal modo que las maquinas aprendan de ellos hasta llegar a tomar decisiones. En la era del *Big Data*, el análisis y el uso practico de la información requiere de enfoques computacionales personalizados como el aprendizaje automático (*machine learning*) y el Aprendizaje Profundo (*deep learning*) (Pierdicca & Paolanti, 2022).

Dentro de la Inteligencia Artificial, es posible identificar dos enfoques que han transformado la forma en que se procesan y analizan grandes volúmenes de datos, el aprendizaje automático (*Machine Learning*) y el aprendizaje profundo (*Deep Learning*). Ambos comparten el principio de construir conocimiento a partir de los datos, sin necesidad de programación explícita para cada tarea, pero difieren en su nivel de complejidad y tipo de información que son capaces de procesar. El primero se basa en algoritmos capaces de aprender patrones a partir de datos estructurados; el segundo, simula la arquitectura del cerebro humano para el análisis de datos no estructurados de forma más abstracta y profunda.

Aprendizaje automático (*Machine Learning*)

El aprendizaje automático es una rama de la inteligencia artificial, donde los métodos y algoritmos pueden aprender a realizar una tarea mediante el entrenamiento. Utiliza probabilidades y técnicas estadísticas para abordar problemas con incertidumbre, se basa en métodos y técnicas de optimización para crear modelos a partir de datos, evitando la programación explícita. Se divide en tres tipos principales: aprendizaje supervisado (entrenado con datos etiquetados), aprendizaje no supervisado (identifica patrones de datos no etiquetados) y aprendizaje reforzado (no requiere datos etiquetados, necesita

condicionantes para ayudar al modelo computacional). Las tareas que realiza el aprendizaje automático se categorizan en objetivos que están en función de tareas de clasificación, agrupación, predicción y otras, como detección de anomalías y generalización de datos. Algunos de los modelos más conocidos e implementados son regresiones, árbol de decisión, bosque aleatorio, máquina de vectores de soporte (SVM), clasificador bayesiano, modelo oculto de Márkov y Redes Neuronales Artificiales (Sarker, 2021).

Aprendizaje profundo (*Deep Learning*)

Se define como una subárea del *machine learning* que incorpora a las redes neuronales en capas sucesivas para aprender de los datos de manera iterativa. Es especialmente útil cuando se trata de aprender de patrones de datos no estructurados. Las redes neuronales complejas de *deep learning* están diseñadas para emular cómo funciona el cerebro humano, así que las computadoras pueden ser diseñadas para lidiar con abstracciones y problemas mal definidos. Utiliza modelos profundos, se encarga del análisis y modelación de bases de datos complejas (Lecun et al., 2015). Algunas de las aplicaciones que ha tenido el *deep learning* en la geografía ha sido por medio de redes neuronales convolucionales: se han utilizado para el geoprocusamiento de imágenes de satélite extrayendo características abstractas usando filtros convolucionales y las redes neuronales recurrentes se ha implementado para el procesamiento de secuencia de datos por ejemplo trayectorias de movimiento o secuencias de ubicaciones. El impacto del aprendizaje profundo ha llegado a diversos campos de aplicación como son las ciencias de la tierra para dar solución a problemas datos no etiquetados en investigaciones de teledetección, en particular en la extracción, procesamiento de imágenes satelitales, drones y sensores terrestres para la detección, clasificación y segmentación de objetos (Lunga et al., 2021).

A partir del uso generalizado de la Inteligencia Artificial en múltiples disciplinas, su adaptación al análisis espacial ha dado paso a una nueva especialización la Inteligencia Artificial Geoespacial. Este enfoque no solo incorpora algoritmos de aprendizaje avanzados, donde la localización no es una variable más, es el eje que estructura las dinámicas sociales, ambientales y de salud. Así, la IA se vuelve aún más potente al integrarse con el análisis espacial, permitiendo interpretar fenómenos territoriales con mayor precisión en diferentes escalas de análisis.

1.5.4 Inteligencia Artificial Geoespacial

La incorporación de la inteligencia artificial en el campo de la geografía ofrece nuevas herramientas para abordar problemáticas espaciales complejas de carácter territorial, con alto nivel de detalle y eficiencia que supera las capacidades de los métodos tradicionales.

Es una ciencia emergente que utiliza métodos y técnicas computacionales de alto rendimiento para aplicar tecnologías de Inteligencia Artificial particularmente de aprendizaje automático y minería de datos para extraer información de grandes bases de datos geoespaciales. De acuerdo con Vopham et al., (2018) es un campo especializado dentro de la geografía que tiene como base la ciencia de datos espaciales y los Sistemas de información Geográfica (SIG) que permite la automatización de tareas, optimización de rutas y la generación de mapas.

Janowicz et al., (2020) afirma que la inteligencia artificial geoespacial utiliza avances en técnicas de ciencia de datos para apoyar la creación de mapas más precisos con información inteligente apoyado de métodos, sistemas y servicios que permitan el desarrollo de tareas y análisis posteriores, es decir, los conjuntos de datos geoespaciales pueden convertirse en recursos útiles para desarrollar futuros modelos de GeoAI. En el contexto de la geografía se ha adoptado la inteligencia artificial para aprovechar el alto potencial de cálculo y el procesamiento de grandes volúmenes de datos que contiene información georreferenciada, por ejemplo, análisis de imágenes satelitales de alta resolución, reconstrucción 3D, trayectorias de GPS, teledetección, redes sociales, huellas espaciales de edificios, carreteras, localización de bienes y servicios, entre otros (Mai et al., 2022). En particular los modelos de IA necesitan sintetizar datos heterogéneos de diferentes fuentes, mientras que la ubicación geográfica es un factor que vincula tales heterogeneidades en los conjuntos de datos (Hu et al., 2019).

La GeoIA requiere de conjuntos de datos geoespaciales de alta calidad, conocimiento de la teoría de inteligencia artificial, las prácticas de programación y computación, así como el conocimiento y dominio del espacio geográfico (Gao, 2021).

Dados los avances tecnológicos que se han realizado durante los últimos años la inteligencia artificial geoespacial se puede aplicar específicamente a la geografía de la salud

y en particular a la pandemia por COVID-19. Esto se traduce en la capacidad de utilizar técnicas y algoritmos avanzados para la detección de casos de contagio, pronósticos de actividad y propagación de enfermedades.

El *machine learning* en la ciencia geográfica ha sido una herramienta central en el análisis espacial para el agrupamiento y predicción de fenómenos geográficos. El *deep learning* se ha implementado para la extracción automática de información de imágenes de satélite, detección de objetos, y la segmentación de instancias. En este sentido la inteligencia artificial, ML y DL en conjunto con la geografía es ampliamente conocida como “Inteligencia Artificial Geoespacial” (Pierdicca & Paolanti, 2022)

1.5.5 XGBoost

El modelo XGBoost es un algoritmo de aprendizaje supervisado basado en árboles de decisión optimizados. Este algoritmo se basa en el principio del boosting por gradiente, el cual construye modelos secuenciales donde cada nuevo árbol intenta corregir los errores del anterior (Chen & Guestrin, 2016). A diferencia de los modelos lineales, XGBoost puede capturar relaciones complejas y no lineales entre las variables predictoras y la variable objetivo.

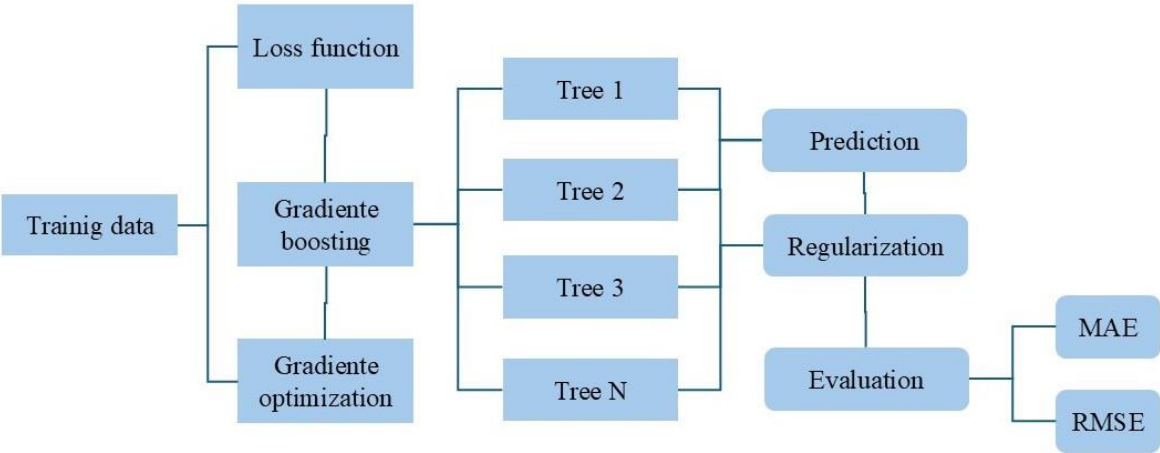
XGBoost emplea funciones de pérdida regularizadas y optimización por gradiente para minimizar el error de predicción, incorporando penalizaciones que evitan el sobreajuste. Este enfoque resulta particularmente eficaz para datos tabulares con alta dimensionalidad, como los conjuntos multivariados que integran variables ambientales, epidemiológicas y socioeconómicas. Su capacidad para calcular la importancia relativa de cada variable permite construir interpretaciones causales robustas (Lundberg & Lee, 2017).

En la Figura 1, se muestra la arquitectura base del algoritmo XGBoost se estructura a partir de un conjunto de datos de entrenamiento, una función de pérdida y un proceso de optimización por gradiente que permite construir secuencialmente múltiples árboles de decisión. A través de esta arquitectura, el modelo ajusta de manera iterativa sus predicciones, incorporando regularización y evaluando su desempeño mediante métricas como el Error Absoluto Medio (MAE, por sus siglas en inglés Mean Absolute Error) y la Raíz del Error Cuadrático Medio (RMSE, por sus siglas en inglés Root Mean Square Error).

En el contexto del COVID-19, se utilizó para analizar la incidencia de factores ambientales como temperatura, humedad, y contaminantes atmosféricos (PM₁₀, PM_{2.5}, NO₂, O₃, CO) en la propagación del virus. XGBoost permitió cuantificar la influencia de estas variables utilizando herramientas como SHAP, lo que proporcionó evidencia robusta para vincular condiciones ambientales con picos de contagio. Asimismo, se empleó para simular escenarios alternativos y apoyar la formulación de políticas de mitigación basadas en evidencia científica. Su validación se realizó mediante técnicas de cross-validation y métricas como MAE y RMSE.

Un ejemplo destacado fue el municipio de Azcapotzalco, donde el modelo de XGBoost mostró mejor capacidad de generalización (MAE=108.96, RMSE=175.57), menor complejidad computacional y mayor robustez interpretativa. Las variables más influyentes fueron PM_{2.5}, O₃ y NOX, corroborando la hipótesis de que la contaminación del aire influye significativamente en los contagios de COVID-19.

Figura 1 Arquitectura interna del modelo XGBoost



Fuente: Elaboración propia con base en Lundberg & Lee (2017)

1.5.6 Modelo híbrido CNN+LSTM (Convolutional Neural Network + Long Short-Term Memory)

El análisis de series de tiempo tiene una larga tradición en el estudio de fenómenos naturales, sociales y económicos. Desde la antigüedad, figuras como Aristóteles registraron patrones meteorológicos, pero fue hasta el siglo XIX que se consolidó como disciplina

cuantitativa. En 1850, Robert FitzRoy introdujo el término "pronóstico del tiempo" al publicar predicciones meteorológicas en medios como The Times de Londres (Nielsen, 2019). La sistematización moderna inició con Udney Yule, quien en la década de 1920 aplicó modelos autorregresivos a datos solares, formalizando los primeros modelos estadísticos para series temporales (Nielsen, 2019).

Las series de tiempo constituyen secuencias de datos recogidos a intervalos regulares, permitiendo identificar tendencias, estacionalidades y patrones cíclicos o aleatorios. Su aplicación se ha extendido a diversas escalas espaciales y temporales, desde el ámbito local hasta el global. Se clasifican en series univariantes, cuando analizan una sola variable, y multivariantes, cuando incorporan simultáneamente varias dimensiones (Tableau from Salesforce, 2024). El análisis de estos datos implica retos como la limpieza de registros, el tratamiento de escalas temporales heterogéneas y la identificación de ruido.

Modelos predictivos en series temporales

Los modelos de series de tiempo tradicionales, como *ARIMA Autoregressive Integrated Moving Average* (Media Móvil Integrada Autoregresiva) y su extensión *SARIMA Modelo Autorregresivo Integrado de Media Móvil Estacional (Seasonal Autoregressive Integrated Moving Average)*, permiten modelar patrones lineales y estacionales; mientras que librerías más recientes como *Prophet* introducen ajustes automáticos para eventos atípicos. Sin embargo, la naturaleza no lineal y disruptiva de eventos como la pandemia por COVID-19 exige la aplicación de modelos más sofisticados capaces de capturar dependencias temporales complejas. Entre ellos destacan las redes neuronales recurrentes (RNN), y particularmente su variante LSTM (*Long Short-Term Memory*), diseñada para superar el problema del desvanecimiento del gradiente mediante un sistema de compuertas (olvido, entrada, salida) y una celda de memoria persistente (Hochreiter & Schmidhuber, 1997).

El modelo LSTM permite modelar relaciones de largo plazo y ha demostrado eficacia en la predicción de fenómenos con estacionalidades irregulares y datos ruidosos. Su arquitectura es especialmente adecuada para series de contagios diarios, donde las dependencias temporales son fundamentales. Derivado de sus fortalezas, este modelo se combinó con redes neuronales convolucionales (CNN), dando origen al modelo híbrido CNN+LSTM.

Modelo híbrido CNN+LSTM


El modelo CNN+LSTM integra las ventajas de las redes convolucionales para detectar patrones locales en los datos y de las LSTM para modelar secuencias temporales prolongadas. Las CNN aplicadas en 1D son capaces de identificar regularidades en ventanas de tiempo, mientras que las LSTM permiten proyectar su evolución a futuro. Esta combinación ha sido utilizada con éxito para predecir contagios de COVID-19 a nivel delegacional, aprovechando variables altamente dinámicas como la serie de casos diarios y la calidad del aire (Kiranyaz et al., 2021; Li et al., 2021).

Teóricamente, este modelo se fundamenta en la capacidad de las CNN para extraer características significativas a partir de secuencias unidimensionales, aplicando filtros convolucionales que capturan patrones de corto plazo en los datos. Estos patrones son luego transferidos a las celdas LSTM, que procesan dichas características como secuencias temporales, permitiendo que el modelo mantenga y actualice una "memoria" de eventos pasados que influyen el presente. La arquitectura CNN+LSTM es, por tanto, idónea para capturar la dinámica espacio-temporal no lineal de epidemias, especialmente cuando se dispone de datos diarios, heterogéneos y con estacionalidades atípicas.

El algoritmo de predicción del modelo CNN+LSTM opera en tres fases principales que se muestran en la figura 2: (1) extracción de patrones locales mediante convoluciones 1D aplicadas sobre secuencias temporales; (2) transferencia de estas características a una red LSTM, que mantiene una representación de estado actualizada para cada secuencia temporal; y (3) generación de la predicción final mediante una capa densa conectada a la salida de la red LSTM. Este enfoque combina la eficiencia computacional de las CNN con la capacidad de memoria a largo plazo de las LSTM, lo que permite anticipar la evolución de los contagios con una ventana de predicción de hasta dos semanas.

El modelo CNN+LSTM fue seleccionado por su rendimiento superior, con un MAE de 7.43. Aunque su capacidad predictiva es alta, presenta una limitación importante: su interpretabilidad. Es decir, no permite identificar directamente cuáles factores externos influyen en la predicción, lo que limita su utilidad para diseño de políticas públicas basadas en causas específicas.

Figura 2 Esquema funcional del modelo híbrido CNN+LSTM



Fuente: Elaboración propia, 2025

Propuesta Modelo teórico – conceptual para el estudio de la dinámica de la pandemia por COVID-19, a partir de la geografía y modelos espaciales de Inteligencia Artificial.

La geografía, concebida como la ciencia que estudia la distribución e interacción de los fenómenos físicos y sociales sobre la superficie terrestre, constituye un marco analítico clave para abordar problemáticas complejas como la pandemia por COVID-19. A través de sus principios fundamentales localización, causalidad, evolución, correlación y correlación, permite la comprensión de la dimensión espaciotemporal de los procesos sociales y ambientales, así como sus implicaciones sanitarias. Estos principios responden interrogantes relacionadas con la propagación territorial del virus, las condiciones que la agravan y las regiones más vulnerables.

En este sentido el pensamiento geográfico ha evolucionado a través de distintos paradigmas que han dotado de profundidad epistemológica y metodológica a la geografía de la salud. Que a partir de sus diferentes etapas de evolución han permitido llegar a análisis complejos facilitando el análisis automatizado, la visualización precisa y la modelación de escenarios, especialmente útiles en crisis sanitarias como la pandemia por COVID-19 donde el análisis cuantitativo es el insumo principal para predecir donde, cuando y evolución de una pandemia.

En la geografía de la salud se han incorporado múltiples referentes teóricos provenientes de disciplinas como la epidemiología, la medicina y la sociología, es importante señalar que no existen teorías clásicas que, por sí solas, expliquen de manera integral los fenómenos sanitarios en su dimensión territorial. Los enfoques tradicionales suelen omitir la

variable espacial y se limitan a analizar los procesos desde sus campos disciplinares, sin considerar cómo el territorio configura y condiciona los patrones de salud y enfermedad.

En este contexto, la geografía de la salud ha recurrido a teorías complementarias tales como la teoría de Lerner, Omran y Frenk (Bolaños, 2000; Hernández Bernal & Santana Juárez, 2022) que son adoptadas como marcos de referencia que permiten articular categorías analíticas relevantes, como la transición epidemiológica, la desigualdad sanitaria o la polarización de la morbilidad, las cuales complementan y enriquecen el enfoque espacial propio de la geografía.

Autores como Ana Olivera han sido pioneros en señalar la influencia de los factores geográficos y ambientales sobre la salud, abriendo camino hacia una comprensión espacial más profunda del fenómeno. De manera más reciente, Buzai, G., & Santana Juárez, M. V. (2018) han aportado un marco conceptual más cercano a una visión integral, al proponer la noción de condicionantes socioespaciales de la salud, entendidos como los contextos territoriales que influyen, pero no determinan de manera absoluta la situación sanitaria de la población. Esta perspectiva reconoce la existencia de un margen de incertidumbre, vinculado a las respuestas individuales y a las particularidades del entorno, lo cual impide generalizaciones deterministas.

En este contexto, se propone un modelo teórico–conceptual de la dinámica espaciotemporal de la pandemia por COVID-19 y una reconceptualización de la geointercalación epidemiológica, que en conjunto articulan el pensamiento geográfico con los condicionantes socioespaciales y las geotecnologías emergentes de análisis predictivo como es la Inteligencia Artificial. Este enfoque parte de la necesidad de construir modelos más integrales que expliquen cómo condiciones entrelazadas inciden en eventos pandémicos.

La geointercalación epidemiológica se refiere a la superposición e interacción de múltiples condicionantes socioespaciales de la salud, que se expresan simultáneamente en un mismo territorio y en un mismo tiempo, y que generan condiciones de vulnerabilidad ante la presencia de un evento epidémico.

Permite entender que las condiciones de salud no son estáticas ni unidimensionales, sino que emergen de una red compleja de relaciones territoriales.

Esta propuesta parte del reconocimiento de los aportes realizados por modelos clásicos de transición epidemiológica, como los propuestos por Omran (1971), Lerner y Frenk (1991), los cuales han permitido establecer marcos interpretativos sólidos sobre los cambios en los patrones de morbilidad y mortalidad vinculados a procesos de modernización social, económica y demográfica.

No obstante, dichos modelos, al estar asociados a contextos históricos y estructurales particulares, presentan limitaciones para abordar las realidades complejas, dinámicas y heterogéneas que caracterizan al territorio mexicano contemporáneo. En espacios urbanos como la Ciudad de México, donde convergen múltiples condiciones de vulnerabilidad social, ambiental, económica y de salud de forma simultánea y acumulada, se vuelve necesario avanzar hacia modelos teóricos conceptuales más integrales, capaces de analizar territorialmente la superposición de condicionantes socioespaciales de la salud que configuran escenarios de riesgo diferenciados frente a eventos epidémicos.

En este enfoque, es opuesto a la idea de que las poblaciones transitan linealmente de una enfermedad a otra, el modelo parte de que muchas comunidades viven de forma constante bajo estados vulnerabilidad y desventaja epidemiológica. Es decir, una misma población puede presentar de forma simultánea enfermedades crónicas degenerativas como diabetes o hipertensión, padecimientos de salud mental como la depresión, vivir en condiciones de marginación, estar expuesta a contaminación ambiental y carecer de acceso servicios de salud de calidad. Para ello no se trata de transiciones aisladas ni de una progresión secuencial, sino de realidades geográficamente sobreposicionadas que aumentan la posibilidad de complicaciones o muerte cuando ocurre una crisis sanitaria como la pandemia por COVID-19.

Estos territorios saturados por desigualdades no solo enfrentan mayores riesgos de contagio, sino que también cuentan con menos recursos para responder ante ellos. Las personas no enfrentan la pandemia desde condiciones de neutralidad, sino desde desventajas que las obligan a sobrevivir en contextos de informalidad laboral, hacinamiento habitacional, carencias alimentarias y exclusión social, de los cuales también pueden ser abordados desde un enfoque de la geografía cualitativa, desde un enfoque del lugar donde se analizan las realidades de la población. En ese sentido, cuando un evento epidémico irrumpe, no solo

desencadena una crisis de salud, sino que expone crudamente las capas de vulnerabilidad preexistentes.

Por ello, el modelo de la dinámica espacio temporal de la pandemia por covid -19 y la reconceptualización de la geointercalación epidemiológica plantea que estas condiciones deben analizarse de manera integrada y contextualizada en el espacio y el tiempo, reconociendo que los factores sociales, económicos, ambientales y de salud no operan de manera aislada. Se requiere una perspectiva geográfica compleja, con capacidad para representar las realidades epidemiológicas de una nación y para construir herramientas predictivas que puedan anticipar futuros brotes en función de estas configuraciones.

Para anticipar y mitigar este tipo de crisis, el modelo propuesto plantea el uso de herramientas tecnológicas avanzadas como la inteligencia artificial, que permite construir modelos cartográficos y predictivos complejos. En particular, los algoritmos de Machine Learning y Deep Learning ofrecen la capacidad de analizar grandes volúmenes de datos en poco tiempo, identificar patrones complejos y aprender de series temporales. En esta investigación, se emplearon modelos híbridos basados en redes neuronales profundas y técnicas de predicción multivariada, entrenadas con datos geoespaciales, climáticos y epidemiológicos.

Este modelo es adaptable a diversos espacios y enfermedades. En el caso del COVID-19, se priorizaron variables como la calidad del aire, la temperatura, y la prevalencia de comorbilidades respiratorias, enfermedades crónicas degenerativas. Sin embargo, en el análisis de otras enfermedades como las transmitidas por vectores, las gastrointestinales o las crónicas el modelo puede ajustarse incorporando variables relevantes como humedad, cuerpos de agua, condiciones de saneamiento, nutrición o hábitos de movilidad, etcétera.

Consideraciones

La pandemia por COVID-19 evidenció que los fenómenos de salud pública no pueden seguir analizándose desde enfoques fragmentados ni modelos que omiten la complejidad del territorio. Las realidades socioespaciales en países como México y particularmente en

ciudades como la Ciudad de México demandan nuevas formas de comprensión que superen las explicaciones lineales y unidimensionales.

Más que una teoría cerrada, esta propuesta es un llamado a construir modelos integrales, territoriales y dinámicos, donde la geografía de la salud es una herramienta analítica poderosa para anticipar, comprender y prevenir eventos epidemiológicos. Apostar por vinculación entre geografía, salud e inteligencia artificial es hoy más que una innovación metodológica es una necesidad ética y humanitaria frente a un presente desigual y un futuro incierto en la salud.

Capítulo II

Metodología

Capítulo II. Metodología

2.1 Zona de estudio

La propagación de la enfermedad por coronavirus 2019 (COVID-19), causada por el SARS-CoV2, ha emergido como un desafío de la salud pública de envergadura internacional. En mayo de 2020, la Organización Mundial de la Salud (OMS) reportó un acumulado de 350,027 casos confirmados y 50,480 defunciones a nivel global. La transmisión del virus se intensificó a una velocidad alarmante, particularmente en áreas densamente pobladas, lo cual subrayó la importancia de comprender su dinámica de propagación en tales contextos.

La emergencia sanitaria por COVID-19 reveló una geografía desigual de la pandemia donde México se consolidó como uno de los principales países con mayor número de contagio y defunciones a nivel internacional alineándose con naciones como la India, Estados Unidos, Rusia, Italia, Brasil, Indonesia, Pakistán, Brasil, Chile, Ecuador, Guatemala y Perú (WHO, 2020).

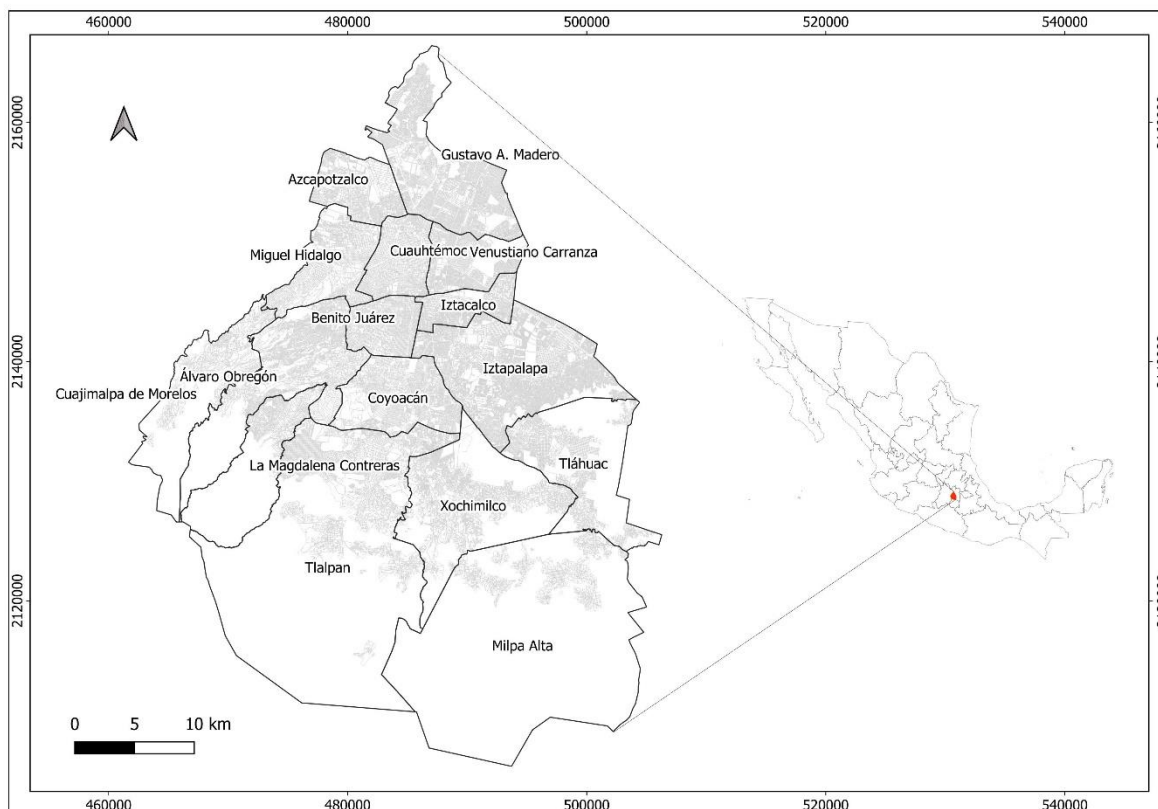
A nivel nacional, la Ciudad de México desempeñó un papel crítico en la expansión del COVID-19. Esta condición respondió a una serie de factores estructurales e intrínsecos. Destacan su ubicación geográfica estratégica y la elevada concentración de actividades terciarias, entre ellas los servicios administrativos gubernamentales, educativos y corporativos. Estos factores favorecieron a una intensa movilidad poblacional, la cual incidió directamente en la dinámica de transmisión del virus.

Dicha centralidad funcional se explica también por sus características territoriales y demográficas. La Ciudad de México se localiza en la región centro del país y se conforma por 16 alcaldías. Su superficie abarca aproximadamente 1,494.3 km² (Figura 3). De acuerdo con el Instituto Nacional de Estadística y Geografía (INEGI, 2020), su población residente en 2020 fue de 9,209,944 habitantes.

En 2020, concentró el 7.3 % de la población nacional. Su densidad demográfica fue de 6,163.3 habitantes por kilómetro cuadrado. El promedio de ocupantes por vivienda particular habitada se situó en 3.3 personas. Además, el 72.6 % de sus residentes contaba con acceso a servicios de salud. La infraestructura sanitaria incluía 93 hospitales públicos (INEGI, 2020), lo que evidencia su complejidad socioespacial.

En 2021, la capital del país concentró el 14 % del total nacional de médicos generales y especialistas, el 18 % de enfermeras generales, el 11 % de enfermeras auxiliares y el 18 % del personal técnico en salud (Secretaría de Salud, 2021). Este capital humano fue clave desde las primeras etapas de la pandemia, al encabezar la respuesta sanitaria frente a la emergencia provocada por el COVID-19.

Figura 3 Localización de la Ciudad de México



Fuente: Elaboración propia con base en INEGI (2021).

2.2 Tipo de estudio

Este estudio es de tipo longitudinal y analítico, con enfoque cuantitativo. La metodología longitudinal permite registrar variables en intervalos definidos, lo que facilita el seguimiento sistemático de los fenómenos observados. Esta estrategia resulta adecuada para analizar cambios a lo largo del tiempo, así como transiciones entre estados de salud y enfermedad (Delgado Rodríguez y Llorca Díaz, 2004).

Desde un enfoque analítico, se busca la identificación entre factores de riesgo de exposición a contaminantes atmosféricos, variación térmica, morbilidades, comorbilidades, así como desigualdades sociales en relación con la probabilidad de contagio de algún virus como el SARSCoV-2 en la Ciudad de México. De acuerdo con Veiga et al., (2008), los estudios analíticos establecen relaciones causales entre fenómenos. En el campo de la salud esta aproximación posibilita la correlación entre agentes de contagio de enfermedades en un espacio y tiempo específico, ofreciendo un panorama de inicio, desarrollo y conclusión de una enfermedad.

Los estudios ecológicos en epidemiología espacial se centran en la relación entre variables geográficas y covariables que inciden en la salud de la población (Lawson, 2006). Este tipo de estudios permite la evaluación hipótesis que asocian la aparición de patologías con factores ambientales. Además, permiten la identificación de regiones con incidencias significativamente elevadas o reducidas (Arsenault et al., 2013; Elliott & Wartenberg, 2004).

Actualmente, las enfermedades transmisibles son un tema prioritario en países de ingresos limitados (Rosenberg, 2016). Ante este panorama, se ha intensificado la demanda de investigaciones cuantitativas que empleen modelos cuantitativos avanzados para la validación de hipótesis que ofrezcan una descripción más precisa de la dinámica espaciotemporal de las enfermedades.

2.3 Fuentes de información

Las fuentes de información empleadas en esta investigación provienen de registros oficiales generados por instituciones del gobierno federal y de la Ciudad de México. Dichas fuentes comprenden bases de datos institucionales, y plataformas de acceso público que ofrecen información validada, sistematizada y actualizada para el estudio

1. Red Automática de Monitoreo Atmosférico (RAMA) de la Ciudad de México. Esta fuente proporciona información sistemática sobre calidad del aire, temperatura, humedad relativa, precipitaciones y presión atmosférica. Estas variables se utilizaron para análisis de las relaciones espaciotemporales entre las condiciones atmosféricas y la incidencia de casos por COVID-19.

2. Instituto Nacional de Estadística y Geografía (INEGI), a partir de los datos vectoriales del Marco Geoestadístico Nacional, edición 2020, y los datos demográficos actualizados del censo 2020. Estos proporcionan la localización precisa de las delegaciones de la Ciudad de México y posibilitan el análisis del perfil socioeconómico de los habitantes afectados por la pandemia. La densidad de población, los usos del suelo y las actividades económicas se consideraron únicamente para el análisis contextual de la Ciudad de México, sin incorporarse en el modelo predictivo.
3. La Dirección General de Epidemiología y la Dirección General de Vigilancia Epidemiológica de la Secretaría de Salud (SS) proporciona información sobre personas afectadas por COVID-19, por alcaldía de residencia. A partir de esta base de datos, se analizaron los casos confirmados de contagio, la presencia de comorbilidades, la distribución por grupos etarios y variables clínicas.

2.4 Métodos de investigación

El método inició con una fase de recopilación bibliográfica, basada en una revisión sistemática de literatura especializada. Esta incluyó artículos científicos, tesis doctorales y otras fuentes académicas relevantes, con el objetivo de sustentar teórica y metodológicamente el desarrollo del estudio.

El diseño de la investigación se fundamenta en los estudios realizados por Kianfar et al., (2022) y Mansour et al., (2022), los cuales destacan la importancia de una preparación rigurosa de los datos relacionados a factores y condiciones georreferenciados que incidieron en los casos de contagio por COVID-19, como un elemento central para el desarrollo de un modelo basado en inteligencia artificial geoespacial.

Los procedimientos de manejo de datos implementados en esta investigación se ajustan a estándares de análisis estadístico avanzado y constituyen una base sólida para las etapas de modelado y análisis mediante inteligencia artificial geoespacial. Esta estructura metodológica permite obtener resultados con alto grado de precisión y solidez técnica.

2.4.1 Hardware

El procesamiento de datos se realizó en un equipo de cómputo equipado con un microprocesador Intel® Xeon CPU E5-2689 @ 2.60 GHz, 16 GB de memoria RAM, unidad de estado sólido (SSD) de 1 TB y una tarjeta gráfica NVIDIA GeForce GT 730.

2.4.1 Software

Para el procesamiento, integración, análisis y predicción de los datos se utilizó el lenguaje de programación Python. La elaboración y análisis de cartografía se llevó a cabo mediante el software de código abierto QGIS.

2.5 Variables e indicadores

Variable dependiente

- 1) Total de casos de contagio por COVID-19: corresponde al número total de casos confirmados de COVID-19 reportados por fecha de ingreso y alcaldía de residencia. Refleja la incidencia acumulada de la enfermedad en el territorio analizado. Su dinámica permite identificar patrones temporales y espaciales de propagación del virus. Los datos fueron obtenidos de la Dirección General de Epidemiología de la Secretaría de Salud.

Se utilizó una serie de tiempo diaria, que abarca desde el año 2020 hasta septiembre de 2023. Esta base sirvió para construir un modelo predictivo orientado a estimar la incidencia futura de contagios por alcaldía.

Dimensión epidemiológica

- 1) Tasa de prevalencia por COVID-19

La tasa de prevalencia presenta una medida estática que indica la proporción de personas dentro de una población que presentan una determinada enfermedad o condición de salud en un momento en específico. Refleja la posibilidad de encontrar una persona afectada en el instante de la observación. No obstante, este valor no permite inferir la probabilidad de que alguien sano desarrolle afección con el tiempo, se calcula de la siguiente manera:

Tasa de prevalencia =

$$\frac{\text{Número de casos existentes de COVID-19 por alcaldía}}{\text{Número total de personas de la población en el mismo lugar y tiempo}} * 1,000$$

2) Tasa de prevalencia por género de COVID-19

Indica la prevalencia por género de COVID-19, la proporción de personas diagnosticadas con esta enfermedad en un momento determinado, diferenciado entre hombres y mujeres dentro de una población específica.

Tasa de prevalencia por género

$$= \frac{\text{Número de casos existentes de COVID - 19 en mujeres u hombres}}{\text{Población total del mismo género}} * 1,000$$

3) Contagios de COVID-19 por grupos etarios

El análisis de contagios por grupos etarios permite la identificación de patrones de distribución de enfermedad entre distintas etapas de la vida, tales como primera infancia, adolescencia, adultez o vejez, la desagregación evidencia la carga específica de COVID-19 en cada segmento poblacional, revelando patrones de vulnerabilidad o exposición diferencial.

4) Comorbilidades asociadas a COVID-19

Las comorbilidades asociadas a COVID-19 son condiciones médicas preexistentes que pueden agravar el curso clínico de la infección y aumenta el riesgo de complicaciones severas o de muerte. De acuerdo con Ganaza-Domingues et al., (2025) se demostró que los pacientes con diabetes tienen un 95% mayor riesgo de mortalidad por COVID-19, asociado a hiperglucemia persistente. El cáncer incrementa este riesgo en un 84%, mientras que las enfermedades pulmonares lo elevan en un 98% y las enfermedades hepáticas en un 56%. La obesidad, vinculada a un balance energético positivo y expansión del tejido adiposo, se asocia con un aumento del 15% en la probabilidad de desenlaces fatales.

2.5.2 Dimensión de las condiciones de salud

La dimensión epidemiológica agrupa indicadores que permiten caracterizar la dinámica del COVID-19 en términos de frecuencia, distribución e impacto sobre la población. Se incluye la morbilidad, expresada como tasa por cada 100,000 habitantes, la cual permite identificar la carga de enfermedad en distintos contextos. Las tasas de contagio tienden a ser más elevadas en poblaciones con menor nivel socioeconómico, debido a una mayor exposición y menor capacidad de resguardo (Bambra et al., 2020).

Variables independientes

Dimensión geográfica y ambiental

Considera factores del entorno físico que influyen en la propagación de enfermedades respiratorias.

1) Tipo de clima

Los climas fríos, con bajas temperaturas, elevada humedad y reducción de radiación ultravioleta, generan condiciones más estables para la supervivencia del SARS-CoV-2 (Chen et al., 2021). Además, durante las estaciones frías, las personas tienden a permanecer en espacios cerrados, lo que facilita la transmisión viral y debilita el sistema inmunológico por la reducción de vitamina D (Su et al., 2020).

2) Temperatura

La temperatura promedio diaria, así como la temperatura mínima, son indicadores relevantes, ya que han demostrado estar asociadas a mayores tasas de transmisión en entornos urbanos densamente poblados (Bashir et al., 2020). En regiones tropicales, las enfermedades respiratorias presentan una circulación persistente o con picos estacionales, mientras que en zonas templadas del hemisferio norte, su incidencia tiende a concentrarse durante los meses más fríos (Bedford et al., 2015).

3) Humedad promedio

Humedad relativa promedio diaria también constituye un factor condicionante. Los niveles bajos de humedad se han relacionado con una mayor transmisibilidad del virus de la

influenza (Dalziel et al., 2018), particularmente en temperaturas frías y templadas, lo que sugiere un comportamiento similar para el SARS-CoV-2 (Thai et al., 2015).

4) Contaminación atmosférica

Asimismo, la contaminación atmosférica, mediante el promedio de concentración de contaminantes como dióxido de nitrógeno (NO₂), material particulado (PM_{2.5}) y ozono (O₃), entre otros, representan condicionantes ambientales significativos (Fattorini y Regoli, 2020). La exposición prolongada a contaminantes del aire debilita el sistema inmunológico, agrava enfermedades respiratorias y cardiovasculares preexistentes, e incrementa el riesgo de hospitalización y muerte por infecciones virales (Bert y Stephen, 2002).

Dimensión socio-demográfica

Esta dimensión permite identificar los condicionantes sociodemográficos que contextualizan las desigualdades ante el COVID-19.

1) Grado de marginación

Variable compuesta de carácter estructural, agrupa carencias sociales que incrementan la vulnerabilidad sanitaria tales como acceso deficiente a servicios básicos, vivienda inadecuada y limitada atención médica oportuna.

2) Densidad de población

La densidad poblacional, medida como habitantes por kilómetro cuadrado, permite identificar zonas urbanas donde la proximidad física favorece la transmisión del virus (Teller, 2021).

3) Vulnerabilidad etaria

De acuerdo con Decoster et al. (2021b) los adultos mayores de 65 años, así como las personas que tienen entre 45 y 64 años, presentan mayores riesgos de contagio y complicaciones de COVID-19, especialmente en contextos de dependencia económica o institucionalización.

Si bien estas variables aportan elementos para la comprensión de la estructura social y demográfica del territorio, no fueron incorporadas al modelo predictivo. Su inclusión se

descartó debido a su carácter relativamente estático y a la escasa variación temporal en el periodo de análisis. A diferencia de factores ambientales como la contaminación, la temperatura o la humedad relativa de naturaleza altamente dinámica y sensible a cambios diarios estas variables operan más como condiciones de base. No obstante, su consideración se requiere para la interpretación del contexto estructural en el que se manifiestan los contagios y, por tanto, constituyen insumos valiosos para modelos explicativos de mayor alcance o enfoques multiescalares orientados al análisis longitudinal.

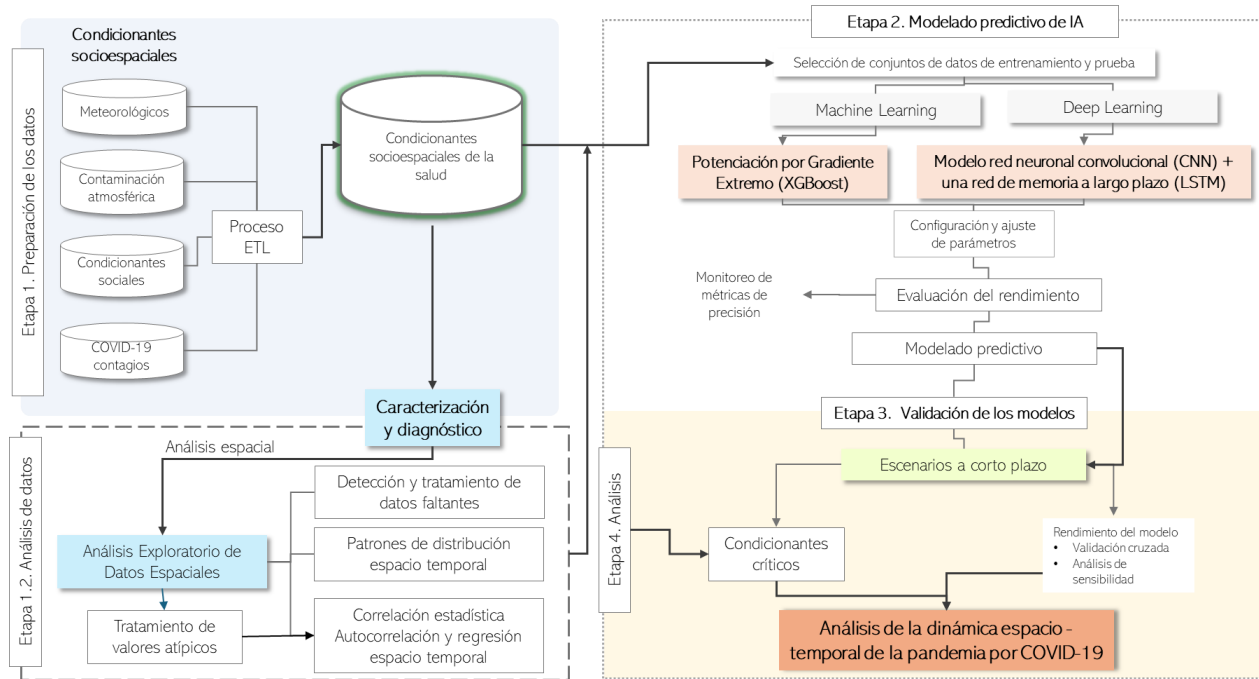
2.6 Etapas y procesos

2.6.1 Esquema metodológico

El presente apartado detalla las etapas y procesos metodológicos desarrollados para el análisis de la pandemia por COVID-19 desde una perspectiva espacio temporal. La metodología integra procedimientos de extracción y transformación de datos (ETL), análisis espacial, modelado predictivo mediante inteligencia artificial y validación estadística, con el fin de identificar los condicionantes socioespaciales que influyen en la propagación del virus como se muestra en la figura 4.

La secuencia metodológica se compone de cuatro etapas principales. Cada una de estas etapas se articula de forma complementaria para la construcción de escenarios a corto plazo, orientados a la comprensión y anticipación de la dinámica de contagios.

Figura 4 Esquema metodológico



Fuente: Elaboración propia, 2025.

Etapa 1: Preparación de los datos

Durante esta etapa se llevó a cabo la recolección, integración y procesamiento de los datos a través de un flujo de trabajo de Extracción, Transformación y Carga (por sus siglas en inglés *ETL Extract, Transform, Load*) de datos. Se incorporaron variables pertenecientes a cuatro categorías de condicionantes socioespaciales de la salud:

- Factores meteorológicos: temperatura, humedad relativa.
- Contaminación atmosférica: concentraciones diarias de PM_{2.5}, PM₁₀, NO₂, O₃ y CO.
- Condicionantes sociales: índice de marginación y densidad poblacional.
- Datos epidemiológicos: número diario de casos confirmados de COVID-19, comorbilidades, entre otros.

El resultado de esta etapa fue una base de datos consolidada que permitió la caracterización preliminar del fenómeno desde una perspectiva espacio-temporal.

Etapa 2: Exploración de datos

2.1 Entendimiento y preparación de datos (conjunto de datos espaciales de los condicionantes socioespaciales de la salud)

La segunda etapa consistió en el análisis exploratorio de los datos con énfasis en la dimensión geográfica. Se aplicaron técnicas de análisis espacial, como mapas de distribución, identificación de valores atípicos y detección de patrones espacio-temporales. Asimismo, se abordaron aspectos técnicos fundamentales como:

- Tratamiento de datos faltantes e imputación.
- Análisis de autocorrelación espacial y regresión temporal.
- Identificación de relaciones estadísticas entre variables estructurales y dinámicas.

Esta fase permitió diagnosticar la estructura de los datos y definir los parámetros adecuados para el modelado.

Etapa 3. Selección de datos de los condicionantes socioespaciales de la salud para predecir contagios por COVID-19, para ello se identificaron las siguientes variables:

3.1 Factores geográficos - ambientales

Entre los factores geográficos considerados se incluyeron elevación, temperatura, humedad relativa y velocidad del viento, mientras que los factores ambientales contemplaron contaminantes atmosféricos como dióxido de azufre (SO₂), ozono (O₃), monóxido de carbono (CO), óxidos de nitrógeno (NO_x), partículas menores a 10 micrómetros (PM₁₀) y partículas menores a 2.5 micrómetros (PM_{2.5}). Los datos fueron obtenidos del Subsistema del Sistema de Monitoreo Atmosférico de la Ciudad de México (SIMAT) y de la Red Automática de Monitoreo Atmosférico (RAMA).

Calidad de los datos:

Se realizó una exploración exhaustiva de los datos para la identificación de valores faltantes, atípicos y nulos, entre otros posibles problemas de calidad. En esta etapa de preprocesamiento, se utilizó la función *PIVOT*, la cual reorganizó los registros de factores meteorológicos y contaminantes, pasando de un formato longitudinal a uno tabular estructurado por días.

Dicha transformación permitió la detección de irregularidades en la serie de tiempo, tales como la ausencia de registros en determinados días, la existencia de datos aleatorios en algunas estaciones y la identificación de estaciones meteorológicas deshabilitadas o retiradas durante el periodo de estudio. Estas observaciones permitieron la definición de criterios de limpieza e imputación de datos en las siguientes etapas del procesamiento.

Imputación geográfica de datos:

Debido a la distribución no homogénea de las estaciones de monitoreo en la Ciudad de México, fue necesario aplicar una interpolación ponderada por el inverso de la distancia (IDW) para estimar los valores faltantes en las alcaldías que no cuentan con estaciones de monitoreo. Esta necesidad se acentúa en el suroeste de la ciudad, donde se carece de estaciones, lo que impide conocer con precisión las condiciones atmosféricas. La interpolación se realizó en QGIS utilizando Python, lo que permitió automatizar el proceso para generar interpolaciones diarias sin intervención manual. A continuación, se describe el procedimiento:

a) Configuración de parámetros base de interpolación:

- Coeficiente de distancia (DISTANCE_COEFFICIENT): Ajustado a un valor de 2, asignando mayor peso a las estaciones más cercanas.
- Extensión geográfica (EXTENT): Delimitada por las coordenadas de la Ciudad de México utilizando el sistema de referencia EPSG:4326.
- Tamaño de píxel (PIXEL_SIZE): Definido como 0.000363, garantizando una resolución espacial adecuada para el análisis urbano.

b) Generación Dinámica de Interpolaciones:

Se emplearon datos de contaminación atmosférica almacenados en un archivo vectorial en formato GeoPackage, el cual almacena mediciones (promedios, valores máximos y mínimos) históricas recolectadas por 40 estaciones de monitoreo. La capa de entrada fue filtrada dinámicamente con las siguientes condiciones:

- elemento = 'SO₂': Selección de registros específicos para cada contaminante.
- Tipo = 'Promedio': Análisis basado en valores promedio de concentración.

Los datos procesados generaron mapas ráster interpolados en formato GeoTIFF, organizados en carpetas por contaminante y factor meteorológico.

c) Proceso iterativo:

La interpolación fue automatizada para la serie de tiempo diaria (2020-2023) mediante el algoritmo `qgis:idwinterpolation`, adaptando los parámetros de interpolación en cada iteración. Esto permitió la creación eficiente de múltiples mapas interpolados.

d) Conversión de valores ráster a puntos:

Se utilizó la herramienta Point Sampling Tool de QGIS para extraer los valores interpolados de calidad del aire y meteorológicos, generando un promedio a nivel de alcaldía. Dicho proceso se aplicó para temperatura, humedad y dirección del viento.

3.2 Condicionantes socio-demográficos

Los condicionantes sociodemográficos, debido a su naturaleza estructural y a su baja variabilidad temporal, fueron considerados en el análisis de la distribución espacial de los casos de COVID-19. No obstante, no se incorporaron en la fase de modelado predictivo, la cual requería variables con alta frecuencia de cambio y sensibilidad diaria, como los factores ambientales. Indicadores como la densidad poblacional, el índice de marginación o el acceso a servicios básicos actúan como factores contextuales que configuran la vulnerabilidad territorial de fondo, pero presentan escasa dinámica durante el periodo analizado. Por ello, su utilidad en este estudio se centró en la caracterización diagnóstica del territorio.

Densidad de población:

La incorporación de la densidad de población en el análisis responde a la necesidad de contextualizar territorialmente la distribución de los contagios en la Ciudad de México. Esta variable permite identificar patrones espaciales de concentración demográfica a nivel de alcaldía, los cuales inciden en la exposición diferencial de la población ante eventos epidemiológicos. Si bien no fue utilizada como predictor en los modelos desarrollados, su análisis resulta permite comprender las condiciones estructurales del entorno urbano. Que se calcula por medio de la siguiente fórmula:

$$\text{Densidad de población} = \frac{\text{Población total}}{\text{Superficie (km}^2\text{)}} \text{Escriba aquí la ecuación.}$$

Uso de suelo:

Para identificar el uso de suelo predominante por alcaldía, se utilizaron datos proporcionados por la Secretaría de Desarrollo Urbano y Vivienda (SEDUVI). Estos datos originales se encontraban en formato de punto, representando el centroide de cada registro de uso de suelo en la dependencia.

Se seleccionaron las columnas correspondientes a alcaldía, uso de suelo, superficie y niveles de construcción. Posteriormente, los datos se agruparon por alcaldía y categoría de uso de suelo. El uso de suelo predominante en cada alcaldía fue determinado como aquel con mayor frecuencia en los registros.

3.3 Contagios por COVID-19

Los registros de contagios por COVID-19 fueron utilizados para la caracterización de la dinámica espacio-temporal de la pandemia y el análisis de distribución en el territorio. Estos datos permitieron la identificación de patrones de propagación, variaciones en la intensidad de los brotes y diferencias entre alcaldías. Asimismo, constituyeron la variable dependiente principal en los modelos predictivos, al conformar la serie temporal sobre la cual se evaluó la influencia de diversos condicionantes ambientales. Su naturaleza dinámica y alta frecuencia temporal los convierte en un insumo clave para el desarrollo de modelos de pronóstico a corto plazo.

Para el análisis de los contagios por COVID-19, se utilizaron los datos abiertos proporcionados por la Dirección General de Epidemiología. Los datos originales están organizados en una escala temporal diaria, a nivel de paciente, y desagregados por alcaldía de residencia.

Se integraron las bases de datos históricas mediante una serie de pasos orientados a la unificación de los archivos correspondientes a cada mes y año del periodo analizado. Una vez consolidada la base, se aplicó un filtro para seleccionar los registros correspondientes a

la Ciudad de México. Posteriormente, en SQL Server, se calcularon los contagios acumulados por día y por alcaldía. Además, se obtuvieron los casos acumulados de comorbilidades y se agruparon en categorías según los siguientes criterios:

- Grupos etarios: primera infancia, infancia, adolescencia, juventud, adultez y adultez mayor.
- Género: masculino y femenino.

Etapa 4. Análisis y homologación de los datos

En esta etapa se llevó a cabo la integración y homologación de los cubos de datos relacionados con temperaturas, contaminación atmosférica, casos de COVID-19, comorbilidades, datos sociales y uso de suelo. El proceso consistió en hacer un *inner join* de las bases de datos, utilizando como claves de unión la fecha y la alcaldía de residencia.

Este procedimiento permitió consolidar la información en un formato estructurado y unificado, lo que facilitó el análisis posterior al garantizar la coherencia temporal y espacial entre los diferentes conjuntos de datos.

Se generó un conjunto de datos de los condicionantes socioespaciales de la salud para la caracterización y predicción de contagios por COVID-19 a nivel de alcaldía de residencia por día de los cuales la conforman factores meteorológicos, de contaminación atmosférica, contagios COVID-19, comorbilidades, uso de suelo, densidad de población.

Etapa 5. Análisis espacial de la dinámica espaciotemporal de la pandemia por COVID-19

Factores geográficos y ambientales

Consiste en la descripción y análisis de las variables geográficas y ambientales como el clima, temperaturas, humedad, calidad del aire que pueden influir en la propagación del virus y el estado de salud de la población a través del tiempo.

Productos cartográficos

1. Mapa de tipos de clima
2. Mapa de temperatura media mensual
3. Mapa humedad relativa media mensual

4. Mapa de promedio de calidad del aire mensual
5. Mapa de índice máximo de calidad del aire mensual
6. Mapa de índice mínimo de calidad del aire mensual
7. Mapa de contaminante atmosférico predominante (Monóxido de Carbono, Dióxido de azufre, PM_{2.5}, PM₁₀, Ozono, entre otros.)

Condiciones de salud

Se analizaron los casos de contagio por COVID-19, considerando la tasa de morbilidad y la distribución demográfica de los pacientes contagiados. Esta información epidemiológica permite la comprensión de la dinámica de la enfermedad y constituye una base clave para su modelación futura.

Etapa 6. Diseño de un modelo espacial integral basado en Inteligencia Artificial


Selección de modelo predictivo

En esta etapa se evaluaron diversos modelos predictivos de *Machine Learning* y *Deep Learning* con el objetivo de determinar el más adecuado para la predicción de los posibles casos de contagio por COVID-19. El análisis se llevó a cabo utilizando una serie de tiempo diaria correspondiente al periodo de 2020 a septiembre de 2023.

Los modelos fueron implementados en *Python* y su desempeño fue evaluado mediante el cálculo del error absoluto medio (MAE, por sus siglas en inglés *Mean Absolute Error*). Entre los modelos analizados, el CNN+LSTM destacó por su alta precisión, mostrando el menor MAE y aproximándose de manera más confiable a los casos reales de contagio.

Los resultados obtenidos de cada modelo predictivo se presentan de manera detallada en la Figura 5, donde se ilustran las diferencias en su capacidad de predicción y su desempeño relativo en el periodo analizado.

Figura 5 Modelos predictivos analizados de Machine Learning y Deep Learning



Fuente: Elaboración propia, 2025.

El modelo híbrido CNN+LSTM obtuvo el menor valor de error absoluto medio (7.43), lo que lo posiciona como el enfoque más preciso y confiable dentro del conjunto de modelos evaluados para la predicción de contagios en el periodo analizado. La combinación de redes convolucionales y memoria a largo plazo permitió la captura de patrones temporales y espaciales en los datos.

Etapa 7. Predicción de casos de COVID-19

2.6.2 Modelo híbrido CNN+LSTM

Librerías en Python

El proceso analítico se inició con la integración de bibliotecas especializadas, tales como NumPy y Pandas para la manipulación y estructuración de datos, Keras Tuner para la optimización automatizada de hiperparámetros, y Plotly para la generación de visualizaciones interactivas. Asimismo, se incorporaron módulos de Keras y TensorFlow en la construcción y entrenamiento del modelo, así como herramientas de Scikit-learn destinadas al preprocesamiento de datos y a la evaluación cuantitativa del rendimiento del modelo. Esta infraestructura metodológica permitió desarrollar un esquema de modelado avanzado, orientado a optimizar la capacidad predictiva y a representar de manera precisa los escenarios potenciales de contagio por COVID-19.

Preprocesamiento de datos

Los datos se cargaron desde un archivo CSV de los condicionantes socioespaciales de la salud, se seleccionaron las columnas de fecha y total de contagios diarios. Posteriormente, se realizaron los siguientes procesos:

- Normalización: Se escala la variable objetivo a un rango entre 0 y 1 mediante *MinMaxScaler*.

Este proceso prepara los datos para su entrada en el modelo, facilitando la identificación de patrones y mejorando la eficiencia del entrenamiento.

Fijación de semilla

Se establece una semilla aleatoria mediante *numpy* y *tensorflow*. Esto asegura la replicabilidad de los resultados en futuras ejecuciones del modelo. La reproducibilidad en la investigación científica permite verificar los hallazgos obtenidos.

Creación de secuencias temporales

Se implementó una función que convierte los datos normalizados en secuencias de entrada (X) y salida (y). Cada secuencia contiene datos de 7 días consecutivos como entrada y el valor del día siguiente como salida. Este enfoque permite al modelo aprender patrones temporales relevantes para realizar predicciones precisas.

División del conjunto de datos de prueba y entrenamiento

Los datos se dividen en conjuntos de entrenamiento (80%) y prueba (20%). El conjunto de entrenamiento se utiliza para ajustar el modelo, mientras que el conjunto de prueba evalúa su desempeño. Esta división garantiza que el modelo sea validado con datos no utilizados durante su entrenamiento, probando su capacidad de generalización.

Hiperparámetros

Los hiperparámetros son configuraciones externas que se establecen antes de entrenar un modelo de aprendizaje automático y que controlan el proceso de entrenamiento.

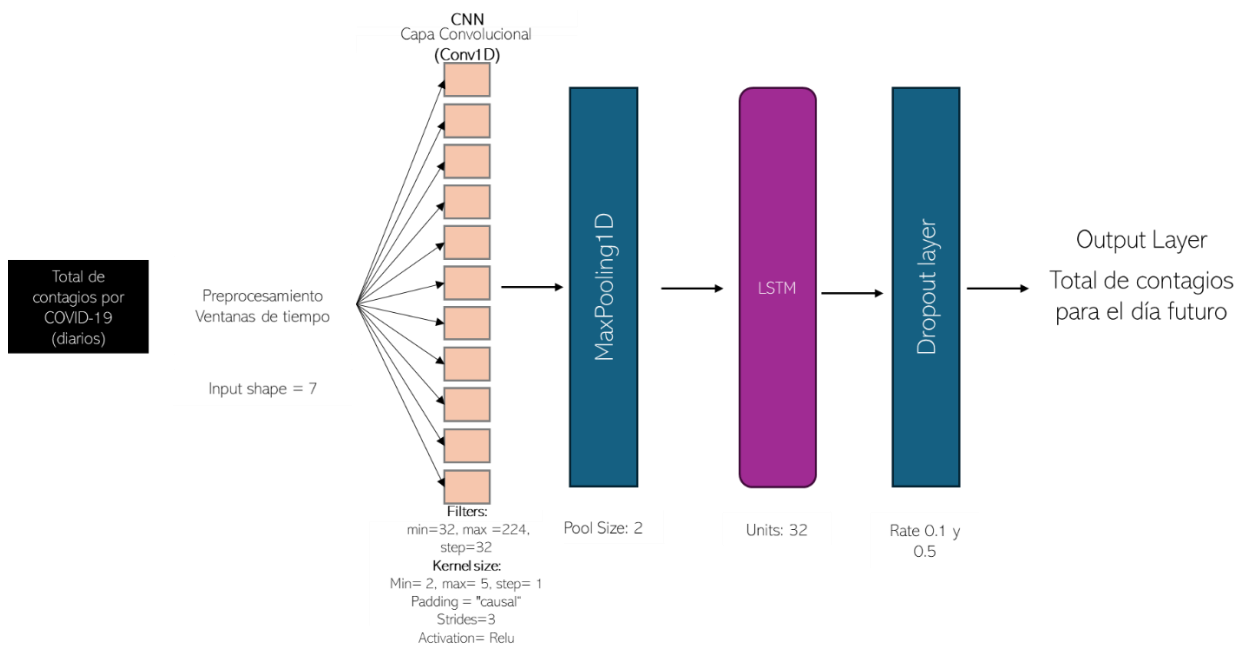
2.6.2.1 Arquitectura de modelado predictivo de CNN + LSTM

Se propone una arquitectura de red neuronal híbrida que combina una capa convolucional (CNN) y una red de memoria a largo corto plazo (LSTM) para la predicción del número total de contagios diarios de COVID-19. Este modelo está diseñado para capturar tanto patrones locales en los datos como dependencias temporales a largo plazo. La arquitectura del modelo consta de los siguientes procedimientos que se ilustra en la figura 6:

- Capa convolucional (CNN): Extrae patrones locales de las secuencias.
- MaxPooling: Reduce la dimensionalidad, mejora la eficiencia computacional y reduce el riesgo de sobreajuste al consolidar la información más importante.
- Capa LSTM: Captura relaciones temporales a largo plazo.
- Dropout: Evita el sobreajuste al introducir regularización.
- Capa densa: Predice el número total de contagios para los próximos días.

El modelo predictivo de CNN+LSTM aplicado en los contagios de COVID-19, permite aprovechar tanto las tendencias recientes como los patrones históricos, logrando una predicción precisa y robusta.

Figura 6 Arquitectura del modelo CNN + LSTM para la predicción de contagios de COVID-19 por alcaldía de la Ciudad de México



Fuente: Elaboración propia, 2025

Optimización de hiperparámetros

Se utiliza un enfoque de búsqueda Bayesiana mediante *keras tuner* para ajustar automáticamente los hiperparámetros del modelo, como:

- Número de filtros y tamaño del kernel en la capa CNN.
- Número de unidades en la capa LSTM.
- Tasa de aprendizaje del optimizador Adam.

Optimizar estos parámetros mejora el rendimiento del modelo y asegura su capacidad de aprender patrones significativos en los datos.

8. Evaluación del modelo

El modelo se evaluó utilizando el conjunto de prueba. Se calculan métricas como:

- Error Absoluto Medio (MAE)
- Error Cuadrático Medio (MSE).
- Raíz del Error Cuadrático Medio (RMSE).

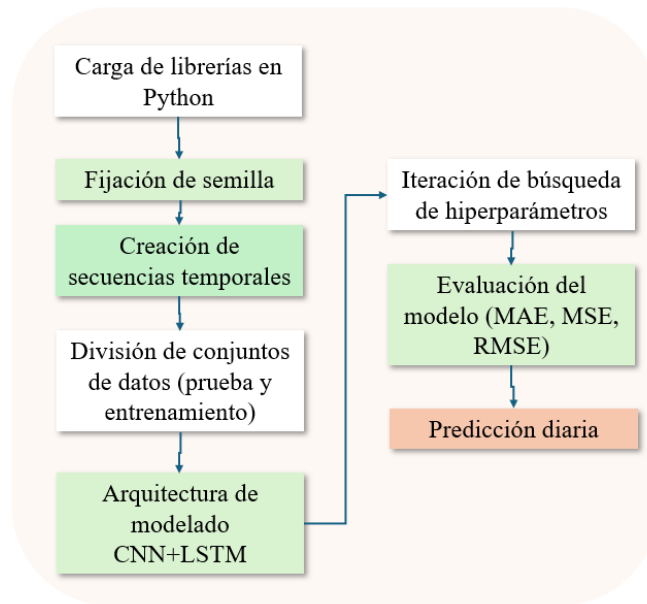
Estas métricas cuantifican la precisión del modelo al predecir los valores reales de contagios en datos no vistos.

9. Proyección a futuro

Se llevó a cabo una proyección iterativa a 20 días, donde se empleó como entrada la última secuencia disponible de la serie temporal. En cada iteración, el valor predicho fue incorporado a la secuencia como nueva entrada para el modelo, para la generación de estimaciones sucesivas de forma autorregresiva. Este procedimiento permitió la simulación de la evolución del fenómeno con base en la dinámica temporal aprendida por el modelo.

La figura 7 representa la arquitectura del modelo de aprendizaje profundo implementado para predecir el número diario de contagios por COVID-19 en la Ciudad de México.

Figura 7 Modelo híbrido CNN + LSTM para la predicción de contagios diarios por COVID-19



2.6.3 Modelo XGBoost

Carga de los datos

Se cargó un archivo de tipo CSV del conjunto de datos de condicionantes socioespaciales de la salud.

Configuración de hiperparámetros

Se definió un conjunto de hiperparámetros iniciales para la configuración del modelo XGBoost, incluyendo el número de árboles (`n_estimators`), la profundidad máxima de los mismos (`max_depth`), la tasa de aprendizaje (`learning_rate`), y parámetros de regularización como `gamma`, `reg_alpha` y `reg_lambda`. Estos valores se seleccionaron para optimizar el equilibrio entre precisión y capacidad de generalización del modelo, utilizando una búsqueda aleatoria de combinaciones.

Filtrado y segmentación por municipio

Se filtraron los datos para cada municipio, analizando únicamente aquellos con al menos 50 registros. Esto se realizó para evitar problemas derivados de un tamaño de muestra

insuficiente, que podría afectar la capacidad predictiva del modelo. Para cada municipio, se definieron:

- Las variables predictoras (X), que incluyen factores geográficos ambientales, condiciones sociales y comorbilidades.
- La variable objetivo (y), representada por el total de casos diarios de COVID-19.

Estandarización de las variables

Antes del entrenamiento del modelo, las variables predictoras fueron escaladas utilizando el método *StandardScaler*, con el objetivo de transformar los datos a una escala estándar (media igual a 0 y desviación estándar igual a 1). Esta etapa asegura que las diferencias en las magnitudes de las variables no afecten el desempeño del modelo.

División de Datos

El conjunto de datos de cada municipio fue dividido en dos subconjuntos. Conjunto de entrenamiento (80%) que es utilizado para ajustar el modelo y el conjunto de prueba (20%). Reservado para evaluar la capacidad predictiva del modelo en datos no vistos. Esta división permite medir tanto el ajuste del modelo a los datos históricos como su capacidad de generalización.

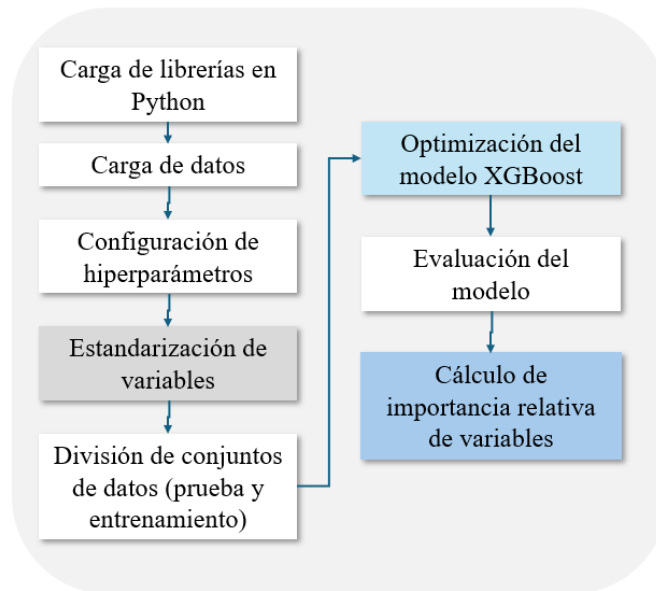
Optimización del modelo XGBoost

Se empleó el algoritmo *RandomizedSearchCV* para realizar una búsqueda aleatoria de los mejores hiperparámetros en el modelo XGBoost. Esta técnica exploró combinaciones específicas definidas previamente y evaluó el modelo mediante validación cruzada de 5 pliegues, utilizando el Error Absoluto Medio (MAE) como métrica de evaluación. Este enfoque permitió identificar la configuración óptima para cada alcaldía.

Evaluación del Modelo

El desempeño del modelo se evaluó mediante las siguientes métricas de MAE (Mean Absolute Error), RMSE (Root Mean Square Error) y R^2 . La figura 8 muestra el flujo metodológico implementado para el desarrollo del modelo de predicción mediante el algoritmo XGBoost.

Figura 8 Flujo de modelado predictivo con XGBoost para la estimación de casos diarios de COVID-19 por alcaldía



Capitulo tres

Resultados

Capítulo III Dinámica espacio – temporal de las enfermedades respiratorias infecciosas y situación de la pandemia por COVID-19

3.1 Historia de las enfermedades respiratorias transmisibles

A lo largo de la historia, las epidemias han dejado huella en las civilizaciones humanas al ofrecer una visión de cómo las crisis sanitarias han impactado a la sociedad a través de los siglos. Las epidemias se describen como el aumento inesperado de casos de enfermedad en un área geográfica específica, caracteriza por no ser exclusivamente ocasionada por una enfermedad contagiosa (Center of Disease Control and Prevention, 2012).

La OMS declara estado de pandemia cuando el crecimiento de una enfermedad es exponencial, la tasa de crecimiento de casos aumenta día a día a nivel local, nacional e internacional, que es de los casos más graves de atender y controlar, para ello los estados miembros tienen que cumplir con las medidas establecidas por el organismo internacional.

Desde las narrativas de Atenas se muestran los daños causados por enfermedades contagiosas, hasta las epidemias que azotaron la época prehispánica en México, las enfermedades que causan daños en el sistema respiratorio han desafiado constantemente la resiliencia de las civilizaciones. Durante el proceso de colonia e independencia de México las enfermedades provenientes de Europa jugaron un papel importante en la historia del país y no fueron un factor que detuviera las dinámicas sociales, comerciales y conflictos bélicos.

En el siglo XXI, la humanidad ha experimentado nuevos brotes epidemiológicos, siendo el COVID-19 un ejemplo paradigmático de la interconexión entre naciones, comercio, migraciones, servicios de salud y la eficacia de la cooperación internacional en la lucha contra las enfermedades emergentes. Estos episodios pandémicos y epidémicos han marcado la memoria colectiva de la humanidad y de la población mexicana.

En este escenario histórico, han emergido patrones recurrentes en la difusión de enfermedades, factores de riesgo identificables y consecuencias de carácter devastador que han afectado a poblaciones enteras. No obstante, las epidemias han ejercido influencia en los flujos migratorios de las comunidades, en los avances científicos, en las configuraciones sociales, espaciales y han influido en las precepciones culturales en torno a las cuestiones de salud. Esta retrospectiva histórica de las enfermedades respiratorias transmisibles brinda un

discernimiento respecto a la evolución de los padecimientos a lo largo del tiempo y el espacio que han causado epidemias, pandemias o han sido eventos epidémicos riesgo que han alertado a la población y a las autoridades sanitarias.

La peste de Atenas 428-432aC

La primera pandemia registrada en la historia fue registrada durante la guerra del Peloponeso (431-404 a.C.), Atenas experimentó un brote epidemiológico que comenzó en mayo de 430 a.C. Esta enfermedad afectó a toda la población independientemente de la edad o estatus social, caracterizó por síntomas como fiebre alta, erupciones pustulosas y diarrea. La pandemia duró aproximadamente de 4.5 a 5 años y se cree que su origen se encuentra en Etiopía, extendiéndose por Egipto, Libia, y por el Cercano Oriente antes de llegar al Pireo, El puerto de Atenas. Además, se registraron tres oleadas epidemiológicas durante este periodo: la primera en mayo del 430 a.C., la segunda oleada en verano del 428 a.C., y la tercera en invierno del 427-426 a.C. Las descripciones originales de la plaga presentaron variaciones con respecto a la terminología hipocrática a la epidemiología moderna (Littman, 2009).

La peste negra 1346

República Autónoma de Crimea (actual Feodosia, Ucrania) fue uno de los epicentros de la peste negra en 1346 de la cuenca mediterránea, siendo uno de los principales puertos mercantiles marítimos mantuvo relaciones comerciales con italianos y mongoles. En la década de 1340, Caffa se convirtió en una ciudad comercial, prospera, con población cosmopolita y con doble muralla concéntrica el muro interior albergaba 6,000 casa y la exterior a 11,000 casas. Se cree que la peste entro por el Mediterráneo desde Crimea donde viajan ratas infectadas que se reproducían e infectaban en bodegas y buques (Wheelis, 2002).

Las causas de la peste se atribuyen a una bacteria de tipo *bacillus* transmitida por roedores como la rata parda. Otros parásitos que viven en la piel humana pudieron ser la causa. Durante esta peste se presentaron tres variantes: La peste bubónica, la peste neumónica y la peste septicémica (Cartwright, 2023).

De las tres variantes que se presentaron en la peste negra de 1346, la peste neumónica ha sido una de las más letales debido a que es transmitida por el aire afectando principalmente los pulmones, con una tasa de mortalidad de 90 a 95%. (John Martin Rare Book Room, 2017)

Históricamente las pandemias se han asociado a procesos de migraciones de poblaciones, hacinamiento, condiciones de vida insalubres, se han presentado durante conflictos bélicos y conquistas de territorios. el incremento o decremento de la propagación de una enfermedad ha dependido de condiciones ambientales, densidad de población, movilidad y condiciones de higiene.

En el siglo XVI enfermedades como la viruela, sarampión, parotiditis, el tifo, tosferina, las hambrunas, la esclavitud, la explotación moral y física fueron algunos de los cambios radicales para la población prehispánica, causando miedo, incertidumbre, dolor y la muerte de la población nativa. Ante el desconocimiento de las enfermedades que se presentaban en la época los médicos nativos identificaron diferencias entre las enfermedades, en náhuatl llamaron *huezahuatl* a la viruela, *tepitonzáhuatl* al sarampión, *quechopotzahualiztli* a las paperas, *tatlaciztli* o *tos chichimeca* a la tosferina. Esos males los llamaron *cocolixtles*, que significaba enfermedad o pestilencia (Malvido & Viesca, 1985).

Las civilizaciones prehispánicas de México han sido un ejemplo de propagación de enfermedades contagiosas a partir de las migraciones y la conquista de territorios una de las principales enfermedades respiratorias que se presentaron durante la llegada de los españoles fue el catarro pestilencial.

Catarro pestilencial *Cocoliztle* 1450 – 1456

En épocas prehispánicas las enfermedades eran consideradas como castigo o voluntad de los dioses. En el código Chimalpopoca, en el año del “conejo”, 1450, en la población de Anáhuac se registraron diversos cambios atípicos en el estado del tiempo atmosférico a partir de heladas, lluvias, plagas de langostas, inundaciones, contaminación del agua por animales acuáticos. A partir de estos acontecimientos se presentó el “catarro pestilencial” que afectaba principalmente las vías respiratorias presentando síntomas similares a la influenza. Dadas las circunstancias de cambios de temperatura, la falta de lluvias y la escasez de alimentos algunos pobladores intercambiaron a sus hijos por maíz, otros vendían su libertad por alimentos,

situación que encaminó a los gobernantes de Tenochtitlan a dar permiso a los pobladores para migrar a espacios en condiciones climáticas templadas. Para 1455 empezó a llover y los alimentos dejaron de escasear, en 1456 la peste regresó e incrementó la mortalidad de la población (Weber-Chuliá et al., 2022).

La bacteria *Pertussis*, conocida como la tosferina, hizo su primera aparición en 1190. Con el transcurso del tiempo, se propagó por Europa, y los médicos la catalogaron como una enfermedad contagiosa, peligrosa y potencialmente epidémica debido a sus afectaciones en el sistema respiratorio, provocando ataques de tos frecuentes que llegaban al punto en el que los niños eran incapaces de respirar con normalidad. La tosferina solía comenzar sin fiebre, y veinte días después de los primeros síntomas, los pacientes a menudo experimentaban complicaciones graves hasta la muerte (Weston, 2012).

En Europa, la tosferina recibió diversos nombres, como "coquelicot" (amapola) debido al uso de opiáceos en su tratamiento, también se le llamaba la "quinta tos" y era comúnmente conocida como "coqueluche" debido a que las personas contagiadas solían usar capuchas (Cameron & Pimlott, 2015).

Según los relatos históricos, se cree que la tosferina surgió en Oriente y se propagó de Este a Oeste a lo largo de las rutas comerciales. Llegó al sur de Europa desde África a través de Malta, y luego se extendió hacia el norte, alcanzando Italia y España. Para el año 1510, la pandemia ya se había propagado por todos los países de Europa, afectando tanto a las ciudades como al campo, pero aún no había llegado al Nuevo Mundo (Morens et al., 2010). En agosto de ese mismo año, en Francia, las altas temperaturas llevaron a que la población pasara más tiempo al aire libre, en jardines y áreas verdes, lo que aumentó los casos de contagio y complicaciones entre los pacientes afectados por la tosferina. (Cameron & Pimlott, 2015).

Tlatlacistli o Tos Chichimeca (tosferina) 1521

Tras la caída de Tenochtitlán, la Nueva España se convirtió en uno de los lugares donde surgieron simultáneamente diversas enfermedades procedentes de las migraciones de Europa a América, induciendo inmunidad en aquellos individuos que lograron sobrevivir y, en los peores escenarios, resultando en altas tasas de mortalidad.

En el año 1562, la tosferina fue una de las enfermedades que afectaron a toda la población, resultando en una tasa de mortalidad del 80% entre sus víctimas. Esta enfermedad se caracterizaba por un período de incubación de 5 a 6 días, afectaba principalmente a las poblaciones nativas e infantiles. La consecuencia demográfica de la alta mortalidad que prevalecía durante ese período fue la aparición de las "generaciones huecas", haciendo referencia a aquellos grupos de población que perecían prematuramente debido a diversos factores, incluyendo eventos sociales como la conquista, epidemias y condiciones ambientales.

Durante el proceso de colonización, la población nativa comenzó a polarizarse de tal manera que aquellos con una mayor probabilidad de asimilación a la cultura española eran miembros de la iglesia y servían a la corona castellana. Por otro lado, las comunidades indígenas del norte, que mostraban una mayor resistencia, llegaron a ser conocidas como "chichimecas". En 1564, la tosferina también fue conocida como "Tlatlacistli", y para 1633, se le denominaba "Tos Chichimeca", un sinónimo de rebelión (Malvido, 2003).

Huey Cocoliztli 1576

La aparición de "cocolixtle" se produjo en agosto de 1576 en la Nueva España, dando lugar a graves afecciones entre la población prehispánica, afectando todo el organismo y manifestándose con fiebres elevadas, dolor abdominal y sangrado nasal purulento. Los casos más graves se caracterizaban por la presencia de abscesos detrás de las orejas. En Tlatelolco, la enfermedad cobró la vida de 10 a 80 personas diariamente durante su inicio, afectando principalmente a la población joven y ocasionalmente a los ancianos. Con el tiempo, su impacto se extendió a toda la población, llevando finalmente a la despoblación de ciertas regiones. Algunos autores la denominaron como la "fiebre recia", marcada por un intenso dolor abdominal que a menudo resultaba fatal en un período de 5 a 6 días.

La enfermedad se atribuyó a un castigo divino por la idolatría, la conjunción de planetas y la aparición de cometas. Además, se relacionó con el calor del verano, la falta de lluvia y las bruscas fluctuaciones de temperatura, pasando de un frío extremo a un calor excesivo en cortos periodos de tiempo. En náhuatl, la enfermedad se conocía como "hueycocoliztli" (gran enfermedad), "matlazahuatl" (llagas que parecían una red), "ezalahuacque" o "etzahualaque", que se traduce literalmente como "flema de sangre".

Es destacable que esta pestilencia no se limitó únicamente a la Nueva España; fue un problema global que comenzó en 1570 en África y posteriormente se extendió a Sicilia, Venecia y España, antes de propagarse por todo el continente europeo. En esa misma época, una plaga similar también surgió en China (Malvido & Viesca, 1985).

Influenza planetaria 1580

La influenza planetaria es considerada como una de las primeras pandemias globales por influenza, se originó en Asia, expandiéndose por África y Europa. Roma fue una de las ciudades más afectadas, donde se registraron 8,000 personas (Kılıç, 2020). En Italia fue conocida como la “influenza planetaria”, se le asignó ese nombre debido a que el brote epidemiológico se presentó después de la aparición de ciertos fenómenos astronómicos (Instituto Nacional de Salud Pública, 2016). Los primeros brotes epidemiológicos se presentaron durante los meses más cálidos, durante ese periodo toda Europa fue afectada en seis semanas, de acuerdo con las descripciones que se registraron la influenza presentó los mismos síntomas de la influenza que actualmente se conoce (Youri Ghendon, 1994)

Gripe rusa asiática 1889 – 1890

Los primeros casos de contagio se registraron en mayo de 1889 en Bukhara, Turkeistán a mediados de octubre del mismo año se extendió por el imperio ruso donde presentó el pico más alto de contagios el 01 de diciembre en San Petersburgo, la primera oleada duró cinco semanas dejando 180,000 víctimas. La gripe se expandió por puertos del Báltico llegando a Estocolmo y el resto de Suecia; en el Imperio Alemán afectó a Poznań, Varsovia, y Lodz. Fue una pandemia que principalmente afectó a ciudades capitales como París, Londres, Viena, Madrid, Roma y Ginebra.

Ante el aumento de los casos de contagio en Europa las autoridades sanitarias optaron por medidas más oportunas como el cierre de escuelas, colegios, universidades, servicios públicos, transporte, y fábricas. Para diciembre de 1889 la pandemia cruzó el Atlántico, presentando sus primeros casos en Estados Unidos. La propagación del virus se debe a la constante expansión de ferrocarriles en Europa (Berche, 2022).

La gripe rusa fue más común en hombres adultos mayores, en pacientes con comorbilidades como tisis, cardiopatías, enfermedades cerebrales y nefritis, causando la muerte de un millón de personas (Huerta López, 2014).

En 1902 en México durante el despliegue de tropas surgieron enfermedades y las ya existentes se agudizaron por hambrunas y desastres naturales como el temblor de 17 de junio de 1911 en la actual Ciudad de México. Algunas enfermedades que llegaron principalmente a la región fronteriza del norte del país, las costas y las grandes ciudades de México fue la fiebre amarilla, la viruela, el tifo y la influenza española. Las revueltas revolucionarias de la época, el movimiento de población y de tropas hizo que el control de epidemias como la viruela se interrumpieran en distintas regiones del país. el caso de la viruela en México es uno de los antecedentes mundiales de las enfermedades epidémicas que se lograron erradicar, haciéndolo oficial el 16 de junio de 1952 como el primer país en lograrlo. Tifo epidémico o también conocido como tifo exantemático, aunque no es catalogado como una enfermedad respiratoria ha estado presente desde épocas prehispánicas con el nombre de matlazahuatl, enfermedad que presenta síntomas como fiebre alta, escalofríos, tos y fiebre superior a 40°C que puede durar hasta por dos semanas y presentar complicaciones en las vías respiratorias causando neumonía (Sanfilippo-Borrás, 2010)

La peste blanca 1915

Tras el termino de las líneas ferroviarias de 1880 en El Paso, Texas en los meses de otoño comenzaron a llegar personas infectadas de tuberculosis con la esperanza de que la cura climática las condiciones áridas, y las altitudes elevadas del desierto de suroeste mejorará el estado de salud de las personas, en lugares alejados de la civilización; esta situación provocó que colonos angloamericanos se convirtieran en “inválidos esperanzados” haciendo de la búsqueda de salud el segundo factor más importante, después del deseo de tierra, para motivar nuevos asentamientos.

A finales del siglo XIX la tuberculosis se convirtió en una de las enfermedades que se asociaba a inmigrantes procedentes de Europa, judíos, africanos, estadounidenses y personas marginadas de espacios urbanos. Se le conoció como “consumo”, “tisis”, o “la peste blanca”. Para esa época se creía que la tuberculosis era una enfermedad que solo se presentaba en mujeres de color de piel blanca, y de clase media. Además, se creía que era el resultado del

aumento de la civilización, la urbanización, viviendas y espacios laborales abarrotados de personas. Con el paso del tiempo mexicanos comenzaron a enfermarse de tuberculosis situación que provocó preocupación por las familias poderosas del norte de México, se insinuó que los anglos de la ciudad eran responsables de la introducción de la tuberculosis y de crear condiciones de pobreza y hacinamiento que facilitaron su propagación. Entre 1910 y 1930, las mujeres mexicanas en El Paso tenían una tasa de mortalidad por tuberculosis un 50% mayor que la de los hombres mexicanos. Esto se atribuyó a su mayor proximidad a personas enfermas debido a roles como cuidadoras y a pasar más tiempo en interiores que los hombres. Esto se respaldó con evidencia de un estrecho contacto frecuente con personas enfermas por parte de las mujeres mexicanas (Sinclair, 2016).

La tuberculosis se destaca por su alta capacidad de transmisión de persona a persona, principalmente cuando un individuo infectado tose, estornuda o escupe, liberando bacilos tuberculosos al ambiente. Una vez que alguien se contagia, los síntomas comunes incluyen tos con expectoración, dolor en el pecho, pérdida de peso, fiebre, debilidad y sudoración excesiva durante la noche (Instituto Nacional de Salud Pública, 2020).

Gripe Española 1918

La gripe española originalmente fue identificada por primera vez en Italia en 1878, en 1918 fue conocida en Europa como la gripe española o la madre de las pandemias (Casillas et al., 2008).

La denominación de "gripe española" se origina debido a que España fue uno de los territorios que experimentó un significativo aumento en los casos de contagio y defunciones durante la pandemia. Esta denominación, sin embargo, no guarda una relación directa con el lugar de origen del virus o su expansión inicial. En el contexto posterior a la Primera Guerra Mundial, resulta relevante destacar que tanto Estados Unidos como Francia optaron por mantener en confidencialidad la existencia de la epidemia de gripe. Contrariamente, España, en calidad de país neutral en el conflicto, disfrutaba de libertad de prensa y fue la primera nación en comunicar públicamente la presencia del brote epidemiológico. Esta particularidad contribuyó a la percepción errónea de que la pandemia había surgido en España, cuando en realidad su origen no estaba necesariamente vinculado a dicho país (Ceberio, 2021)

La epidemia de influenza española de 1918 inició en mayo en Funston, Kansas, evidenciando una mortalidad moderada en ese momento. La propagación del virus fue propiciada principalmente por la alta movilidad de los soldados infectados que se trasladaban a diferentes centros de reclutamiento militares. Esta enfermedad desencadenó cuadros respiratorios agudos y cianosis, imponiendo una significativa presión sobre el sistema de salud en Estados Unidos, lo que resultó en la ocupación de gimnasios y salones de reuniones para la atención de pacientes. En junio y julio, la situación se deterioró aún más cuando los soldados infectados fueron enviados a Francia, generando una segunda oleada de la epidemia con una elevada tasa de mortalidad (Ceberio, 2021; García-García & Ramos, 2006)

Durante esta segunda fase epidemiológica, se observó un patrón inusual en los pacientes, quienes durante el día mantenían una aparente estabilidad clínica, pero experimentaban un agravamiento de su estado por las tardes, con un lamentable número de defunciones nocturnas. La epidemia se caracterizó por tres brotes epidemiológicos en total, concluyendo en octubre de 1919.

Se atribuye el origen de esta devastadora epidemia a una fuente aviaria, con la probabilidad de una evolución del virus en un período de 5 a 10 años, lo que habría permitido su transmisión eficiente a los seres humanos. Esta pandemia, ocasionada por el subtipo H1N1 del virus de la gripe A, tuvo un impacto humano sumamente significativo, superando incluso el número de víctimas de la Primera y Segunda Guerra Mundial en conjunto a nivel mundial afectó a un tercio de la población dejando aproximadamente 100 millones de personas sin vida (Casillas et al., 2008; García-García & Ramos, 2006).

La gripe o influenza española de 1918 ingresó a México a través de un barco de la compañía Trasatlántica Española que arribó en el puerto de Veracruz. En dicho barco, se encontraban algunos pasajeros afectados por la influenza, lo que propició una rápida propagación del virus en diversas ciudades mexicanas, como Torreón, Gómez Palacios y San Pedro de las Colinas, donde se registraron alarmantes cifras de hasta 300 defunciones diarias. En la Ciudad de México, la situación se tornó aún más crítica, llegándose a reportar hasta 800 casos diarios de enfermos en el hospital general. Este desbordamiento de enfermos sobrepasó la capacidad del sistema de salud, resultando en un colapso hospitalario y el cierre de servicios funerarios, como el Panteón de Dolores, debido a la insuficiencia de espacios

para las inhumaciones. Cabe destacar que, durante esta epidemia, se produjo una innovación significativa: el invento de la mascarilla o cubrebocas, atribuido al doctor Takabatake (Sanfilippo-Borrás, 2010).

Durante la pandemia de la gripe española, se identificó que la población vulnerable incluía a mujeres embarazadas que pertenecían a estratos socioeconómicos menos favorecidos. Además, las tasas de alta mortalidad se observaron predominantemente en adultos mayores y, ocasionalmente, en niños (Snacken et al., 1999).

La gripe española tuvo un impacto duradero en múltiples aspectos de la sociedad, la medicina y la cultura, y dejó lecciones importantes sobre la importancia de la preparación y la respuesta a las pandemias.

Gripe asiática de 1957 (H2N2)

Precediendo a esta pandemia, se registraron 13 epidemias de tipo A entre 1934 y 1963. En 1957-1958, surgió la "influenza estacional", resultado de una "deriva" genética del virus, que se distinguió por un cambio significativo en el carácter genético del virus, lo que resultó en una disminución de la inmunidad residual en la población (Henderson et al., 2009). La pandemia de la gripe asiática de 1957-1958, fue causante de un estimado de 1 a 2 millones de muertes, tuvo su origen en un virus de tipo aviar del subtipo H2N2 (García-García & Ramos, 2006).

La propagación de la gripe asiática se inició en febrero de 1957 en el sur de China y se extendió durante tres meses a Singapur, Hong Kong y Japón. En octubre de 1957, alcanzó al Reino Unido y Estados Unidos, y en enero de 1958, se detectó una segunda ola (Al Hajjar & McIntosh, 2010; García-García & Ramos, 2006). Las bases militares estadounidenses en Corea y Japón experimentaron brotes del virus asiático en abril y mayo de 1957, mientras que los casos en Estados Unidos se produjeron en campamentos militares en el Este y el Oeste (Henderson et al., 2009).

Posteriormente, se observaron brotes localizados en entornos institucionales, como centros de conferencias, campamentos para niños y bares para trabajadores inmigrantes. Aunque se notificaron algunos casos en zonas urbanas, la transmisión a nivel comunitario fue limitada. El pico del brote se alcanzó a finales de julio y mediados de agosto. La influenza

generó un aumento en el ausentismo escolar, pero las escuelas solo se cerraban si el número de estudiantes o el número de docentes era insuficiente para mantener su funcionamiento (Al Hajjar & McIntosh, 2010).

Gripe de Hong Kong o pandemia de 1968 (H3N2)

La pandemia de gripe de Hong Kong de 1968-1969 fue una secuela del virus aviar H2N2 que había infectado previamente a los humanos. Esta pandemia se originó en julio de 1968 en Hong Kong para finales de ese mes, ya se habían reportado brotes extensos en Vietnam y Singapur. Caracterizó por dos oleadas epidemiológicas. La primera oleada registró una alta morbilidad, mientras que la segunda oleada, que se presentó 12 meses después, resultó en aproximadamente 4 millones de defunciones (García-García & Ramos, 2006; Sino Biological, 2023). El predominio del virus H3N2 en la población humana llevó a la desaparición del virus H2N2.

La pandemia se expandió a la India, Filipinas, el norte de Australia y Europa en septiembre de 1968. En ese mismo mes, el virus llegó a California por las tropas procedentes de la guerra de Vietnam, no se generalizó en Estados Unidos hasta diciembre de 1968. La pandemia se intensificó durante el período de vacaciones escolares de invierno, lo que limitó la propagación en las escuelas. La atención médica brindó un apoyo vital a los pacientes más enfermos, y la disponibilidad de antibióticos más eficaces contra las infecciones bacterianas secundarias también contribuyó a un menor número de defunciones (Al Hajjar & McIntosh, 2010).

Cabe destacar que la enfermedad epidémica de la gripe es causada por los virus de la influenza tipo A y B. La influenza tipo A tiene la capacidad de infectar tanto a humanos como a aves y, lo que es más importante, puede convertirse en un virus pandémico. Por otro lado, los virus de la influenza tipo C causan enfermedades leves y esporádicas, similares a la influenza, en los niños (Al Hajjar & McIntosh, 2010).

Pandemia de 1977 gripe rusa

El 1 de noviembre de 1977 un hombre de 22 años presentó el primer caso de influenza en Moscú (Gregg et al., 1978), por primera vez fue anunciada por la URSS; este virus presentó similitudes a la pandemia de 1950 de influenza H1N1. Surgen sospechas

fundamentadas en varios elementos. La Unión Soviética mantenía un programa activo de armas biológicas con numerosos científicos involucrados, y se tenía registro de un incidente previo en 1979 en el que se liberó ántrax en aerosol en Sverdlovsk, lo que evidenciaba fallos en la seguridad de dicho programa. Se plantea la hipótesis de que la gripe pudo haber sido empleada como un agente incapacitante, particularmente efectivo debido a la falta de inmunidad en personas jóvenes, ya que la población militar en servicio activo predominaba en el rango de edad de 26 años o menos. En conjunto, esta información sugiere la posibilidad de que la epidemia de gripe de 1977 podría haber sido el resultado de una liberación deliberada del virus de la influenza con fines de guerra biológica (Rozo & Gronvall, 2015). Esta epidemia afectó principalmente a academias militares en la URSS, Inglaterra y Estados Unidos que tenían matrícula de cadetes que se encontraban en un rango de edad de 26 años, colocándose como la población vulnerable ante el virus

Actualmente, se atribuye con mayor frecuencia el resurgimiento de la cepa del virus de la influenza H1N1 en 1977-1978 a una presunta falla de bioseguridad en un laboratorio de investigación. Este punto de vista es respaldado por investigadores académicos tanto de la Unión Soviética como de China, quienes han señalado que los laboratorios involucrados no habían conservado el virus H1N1 o no habían estado trabajando con él durante un período considerable. Este debate sobre el origen de la pandemia varía y es influenciada por consideraciones políticas que sirven como advertencia para posibles accidentes de laboratorio (Gregg et al., 1978; Rozo & Gronvall, 2015).

Influenza aviar en México H5N2 (1994)

En 1994, se identificó el virus H5N2 de baja patogenicidad en aves a nivel mundial, en México la infección se extendió en la región avícola (Aguascalientes, Distrito Federal, Guanajuato, Guerrero, Hidalgo, Jalisco, México, Morelos, Puebla, Querétaro, Sonora y Veracruz) causando efectos económicos en los productores. En diciembre de 1994, se registraron casos de alta patogenicidad en los estados de Puebla y Querétaro, lo que activó medidas de control y de eliminación del virus. El virus tenía similitudes con un brote de H5N2 en Estados Unidos, lo que generó varias teorías sobre su llegada a México, como a través de aves migratorias o el contrabando de aves infectadas. En 1994, el virus mutó a alta patogenicidad y se propagó por todo el país y llegó a Guatemala y El Salvador en 2000.

Aunque afectó a las aves, no se observó la transmisión de la influenza aviar a humanos en México (García-García & Ramos, 2006).

Se implementaron medidas de vigilancia activa, se mejoraron las medidas de bioseguridad y se restringieron los traslados de aves vivas, productos avícolas, subproductos y materiales infecciosos, en México se implementó un programa de vacunación masiva de aves (Food and Agriculture Organization of the United Nations, 2012).

Gripe Aviar 1997 H5N1

La gripe aviar H5N1 se originó en la provincia de Guangdong, China. En marzo de 1997, se detectaron los primeros signos de problemas en Hong Kong cuando pollos en granjas de Yuen Long comenzaron a morir debido a una enfermedad que más tarde se identificó como gripe aviar del subtipo H5N1 (Ching, 2018). Este brote afectó a varias granjas avícolas en la región durante marzo y abril de 1997, resultando en la muerte de miles de pollos. El virus H5N1 se originó en aves silvestres y domésticas y se caracterizó por la recombinación de tres virus diferentes (Snacken et al., 1999).

En mayo de 1997, un niño de 3 años en Hong Kong contrajo una enfermedad similar a la gripe, que resultó en su muerte con complicaciones que sugirieron el síndrome de Reye. Se aisló un virus de la influenza tipo A, que más tarde se identificó como A/Hong Kong/156/97 (H5N1), relacionado con un aislado de pollo. A finales de diciembre, se confirmaron 17 casos nuevos, de los cuales 5 fueron mortales, con tasas de letalidad del 18% en niños y del 57% en adultos mayores de 17 años. Como medida preventiva, se sacrificaron más de 1.6 millones de pollos en Hong Kong, lo que detuvo la cría de pollos en la región. La Organización Mundial de la Salud (OMS) inició investigaciones y evaluaciones técnicas en Hong Kong con el apoyo de organizaciones de Estados Unidos y Japón para evaluar la situación y los riesgos asociados con el virus H5N1 (Snacken et al., 1999).

En diciembre de 1997, se identificaron tres casos de influenza aviar en humanos en Hong Kong, principalmente en mercados de aves vivas y uno en granjas. Ante esta situación, el gobierno tomó la decisión de sacrificar más de 1.5 millones de aves comerciales como medida preventiva (García-García & Ramos, 2006).

La gripe humana se transmite principalmente a través de la inhalación de gotitas y núcleos infecciosos, el contacto directo e indirecto (como el contacto con el vómito). Los virus de la gripe tienen su principal reservorio en aves acuáticas salvajes, especialmente patos y gansos, que tienen receptores específicos en su intestino para las partículas del virus aviar. Estos ambientes, como humedales, lagos y ríos donde estas aves son comunes, facilitan la exposición a las partículas virales. La gripe puede afectar varios órganos, incluyendo los pulmones y el intestino. Los síntomas típicos incluyen fiebre, tos, dolor de cabeza, mialgias, malestar general y rinitis, así como conjuntivitis e infección conjuntival. Se han reportado casos humanos con alta exposición a aves de corral enfermas, con síntomas graves como neumonía, diarrea, vómitos, dolor abdominal, dolor pleurítico y epistaxis. Muchos pacientes desarrollaron fallo respiratorio y síndrome de distrés respiratorio agudo (SDRA), y la población afectada principalmente se encontraba entre los 9.5 y 22 años. (Casillas et al., 2008).

SARS-CoV Guangdong, China 2002-2003

El brote de SARS-CoV, que se originó en Guangdong, China, en noviembre de 2002 y se extendió hasta 2003, marcó el surgimiento de la primera enfermedad grave y altamente transmisible del siglo XXI (World Health Organization, 2023b). Los primeros casos de SARS fueron detectados en noviembre de 2002 en la provincia de Guangdong, China. No obstante, la Organización Mundial de la Salud (OMS) recibió el primer informe oficial sobre un brote de neumonía atípica vinculada al SARS el 11 de febrero de 2003, cuando ya se habían registrado 305 casos y 5 defunciones en la mencionada región.

La propagación de esta enfermedad se debió en gran parte a los viajes globales aéreos, lo que facilitó su diseminación a nivel internacional. Se logró controlar el brote aproximadamente 7 meses después de su aparición (Fang et al., 2009; Yuan et al., 2006). En marzo de 2003, se identificó la causa del SARS como un nuevo coronavirus, el SARS-CoV, que pertenece a la familia Coronaviridae de virus de ARN de cadena positiva envueltos y que tienen una amplia gama de huéspedes. Los virus de ARN, como el SARS-CoV, poseen una alta tasa de mutación genética, lo que puede llevar a la evolución de nuevas cepas virales y la capacidad de los virus para evadir las defensas del huésped (Ruan et al., 2003). Los

síntomas iniciales del SARS son similares a los de la gripe, incluyendo fiebre, escalofríos, dolores musculares, dolor de cabeza y ocasionalmente diarrea (R. Xu et al., 2004)

Hong Kong Síndrome Respiratorio Agudo (SARS) 2003

En noviembre de 2002, el Síndrome Respiratorio Agudo Severo (SARS) tuvo su origen en la provincia de Guangdong, China (Ching, 2018). Para febrero de 2003, un individuo de 48 años, tras un viaje a Hong Kong, propagó el virus al personal médico de un hospital en Hanoi, Vietnam. Aunque inicialmente se denominó "neumonía atípica" en China, la Organización Mundial de la Salud (OMS) lo oficializó como Síndrome Respiratorio Agudo Severo (SARS) el 12 de marzo de 2003, lanzando una alerta global.

Un importante hallazgo derivado de investigaciones posteriores fue la identificación de 134 personas que se hospedaron en el hotel Metropol de Hong Kong durante el mismo período. Muchos de ellos realizaron viajes internacionales a Canadá, Singapur, Estados Unidos y Vietnam, lo que contribuyó a la propagación del virus a nivel mundial. Los síntomas predominantes entre los afectados incluyeron fiebre superior a 38°C, escalofríos, cefalea, malestar general y mialgias. Tras un período de 3-7 días, se inició una fase respiratoria inferior, caracterizada por una tos seca. Un aspecto destacado de esta epidemia fue la identificación de "supercontagiadores", individuos que tenían la capacidad de infectar a una cantidad significativa de personas. Su transmisión se produce a partir del aire, mediante la dispersión de pequeñas gotas respiratorias que contienen el virus y el contacto directo con secreciones. Esto contribuyó en gran medida a la rápida propagación del SARS, especialmente entre la población de adultos mayores, que se mostró particularmente vulnerable a la enfermedad (World Health Organization, 2003).

Epidemia de influenza aviar en Asia 2003-febrero de 2006

En agosto de 2003, se desencadenó una epidemia de influenza aviar caracterizada por su rápida propagación, la cual se atribuyó en gran parte al comercio insalubre de aves domésticas. El brote se originó en Corea del Sur debido a la alta mortalidad observada en aves de corral comerciales. A partir de enero de 2004, se registraron casos de influenza aviar en seres humanos, afectando a más de 3 millones de aves. Esta epidemia, denominada "gripe del pollo," cobró tres vidas en Hanoi, Vietnam, y se expandió a 32 provincias, convirtiendo

a las aves en la principal fuente de infección para los humanos. La gripe aviar se propagó rápidamente por Camboya, Hong Kong, la República Democrática Popular de Laos y China, impactando gravemente a este último país, con daños a más de 13 millones de aves de traspatio en zonas rurales. Además, otras especies animales, como leopardos, tigres y aves silvestres no acuáticas, se vieron afectadas. A pesar de los esfuerzos por controlarla, la epidemia se extendió por el norte de Asia, el Medio Oriente, Europa y África, causando 113 muertes y 205 casos de contagio en seres humanos hasta el 1 de marzo de 2006 (García-García & Ramos, 2006).

Influenza aviar en Holanda, Bélgica y Alemania marzo 2003 H7N7

En marzo de 2003, se detectó el primer caso de gripe aviar en una gallina de postura en Holanda, siendo causada por el subtipo H7N7 del virus. Este brote se extendió a Bélgica y Alemania, algunos individuos afectados experimentaron síntomas que iban desde conjuntivitis hasta problemas respiratorios similares a la influenza. Lamentablemente, un especialista en aves falleció debido a bronconeumonía intersticial bilateral aguda, una complicación derivada de la infección por el virus H7N7. (García-García & Ramos, 2006)

Coronavirus HCoV-NL63 (NetherLand 63) 2004

El HCoV-NL63, también conocido como NetherLand 63, es un coronavirus que se aisló por primera vez a partir del aspirado de un bebé de 7 meses con bronquiolitis en 2004 (W. Liu et al., 2022). Este virus se detectó inicialmente en un niño que presentaba bronquitis en los Países Bajos en el mismo año.

Los coronavirus HCoV-NL63 se asocia principalmente con infecciones del tracto respiratorio humano, afectando tanto las vías respiratorias superiores e inferiores. Este virus se ha identificado como un posible patógeno respiratorio que afecta especialmente a bebés y ancianos (Cui et al., 2011). Su capacidad para causar infecciones respiratorias en estos grupos de población hace que sea importante monitorear y estudiar este coronavirus para comprender mejor su epidemiología y su impacto en la salud pública.

Coronavirus HCoV-HKU1 2005

El coronavirus HCoV-HKU1, su nombre deriva de la Universidad de Hong Kong, fue identificado por primera vez en Hong Kong, China, en 2004, aunque sus orígenes se

remontan a Brasil en 1995. Este virus se detectó inicialmente en un hombre de 71 años que regresaba a Hong Kong, China, desde la ciudad de Shenzhen, provincia de Guangdong. (W. Liu et al., 2022).

El HCoV-HKU1 se aisló de un paciente de Hong Kong que presentaba neumonía en 2005, así como de un adulto con enfermedad pulmonar crónica en la misma región. Los síntomas clínicos de la infección por HCoV-HKU1 incluyen rinorrea, tos, congestión nasal, fiebre, esputo, dolor de garganta, escalofríos, secreción nasal e hipertrofia amigdalina. Esta infección es relativamente frecuente en adultos y se observa con mayor frecuencia en la primavera y el verano (D. X. Liu et al., 2020). Es importante destacar que el HCoV-HKU1 puede causar una variedad de síntomas respiratorios, tanto en el tracto respiratorio superior como en el inferior, con fiebre, tos y disnea como síntomas comunes (Woo et al., 2009).

Influenza H1N1, 2009

El virus por influenza se ha conocido desde tiempos antiguos, ha sido un acompañante de la historia de la humanidad, dando lugar a episodios significativos de pandemias y epidemias. Este agente patógeno caracteriza por su capacidad de mutación, lo que lo convierte en una de las enfermedades más contagiosas y difíciles de controlar. La influenza afecta a grupos específicos de población, principalmente en individuos menores de 5 años y población adulta mayor. Sin embargo, su alcance no se limita solo a ciertos grupos etarios, ya que también es una amenaza significativa para individuos con condiciones médicas subyacentes, como asma, inmunodeficiencias, enfermedades crónico-degenerativas como el cáncer (Huerta López, 2014). Es importante destacar que la influenza también puede afectar a personas aparentemente saludables sin importar el grupo de edad al que pertenezca, esto estará condicionado por factores individuales y estilo de vida, como la falta de sueño, tabaquismo, el consumo excesivo de alcohol y el estrés crónico.

En el caso de México se han observado picos estacionales de influenza, principalmente tienden a presentarse en los meses de mayo y noviembre, lo que requiere de una vigilancia epidemiológica constante y la implementación de medidas preventivas para minimizar su impacto en la salud pública.

COVID-19 Wuhan, China 2019

La pandemia por coronavirus no ha sido un fenómeno aislado, ha sido el resultado histórico de diversas problemáticas de salud, sociales, económicas, de estilos de vida, educativas, ambientales, de movilidad, de empleo que se estaban viviendo a nivel mundial y local, situación que cobró la vida de millones de personas con alta vulnerabilidad ante el virus SARS-CoV2.

El primer caso de contagio por SARSCoV2 fue detectado en Wuhan, China, el 31 de diciembre de 2019. Los primeros pacientes enfermos estuvieron relacionados con el mercado de Wuhan debido a su alta infectividad y patogenicidad, la enfermedad se propagó rápidamente por diferentes provincias de China y otros países (World Health Organization, 2020b).

El 11 de marzo de 2020 el director General de la Organización Mundial de la Salud, declaró situación de pandemia mundial por la enfermedad SARS-CoV2 (COVID-19) debido a que se registraron más de 11,800 casos de contagio en 114 países y 4,291 personas que perdieron la vida (World Health Organization, 2020a). Esta situación causó preocupación en la comunidad internacional debido a los altos niveles de propagación y gravedad. El doctor Tedros Alhanom Ghenreyesus destacó que anteriormente no se había visto una pandemia provocada por coronavirus y tampoco se había visto que una pandemia pudiera ser controlada al mismo tiempo (Organización Panamericana de la Salud, 2020). Destacó que al principio de la pandemia 90% de los pacientes contagiados se concentraban principalmente en China, Corea del Sur, Italia e Irán. Las medidas sanitarias que emplearon los países con mayor número de pacientes infectados que, en primera instancia consistió en la detección, aplicación de tratamientos médicos, aislamiento, y rastreo efectivo para evitar que estos casos provoquen la transmisión comunitaria.

El COVID-19, causado por el virus SARS-CoV2, ha experimentado variabilidad genética que ha llevado a la propagación de 5 cepas o variantes desde su primera aparición

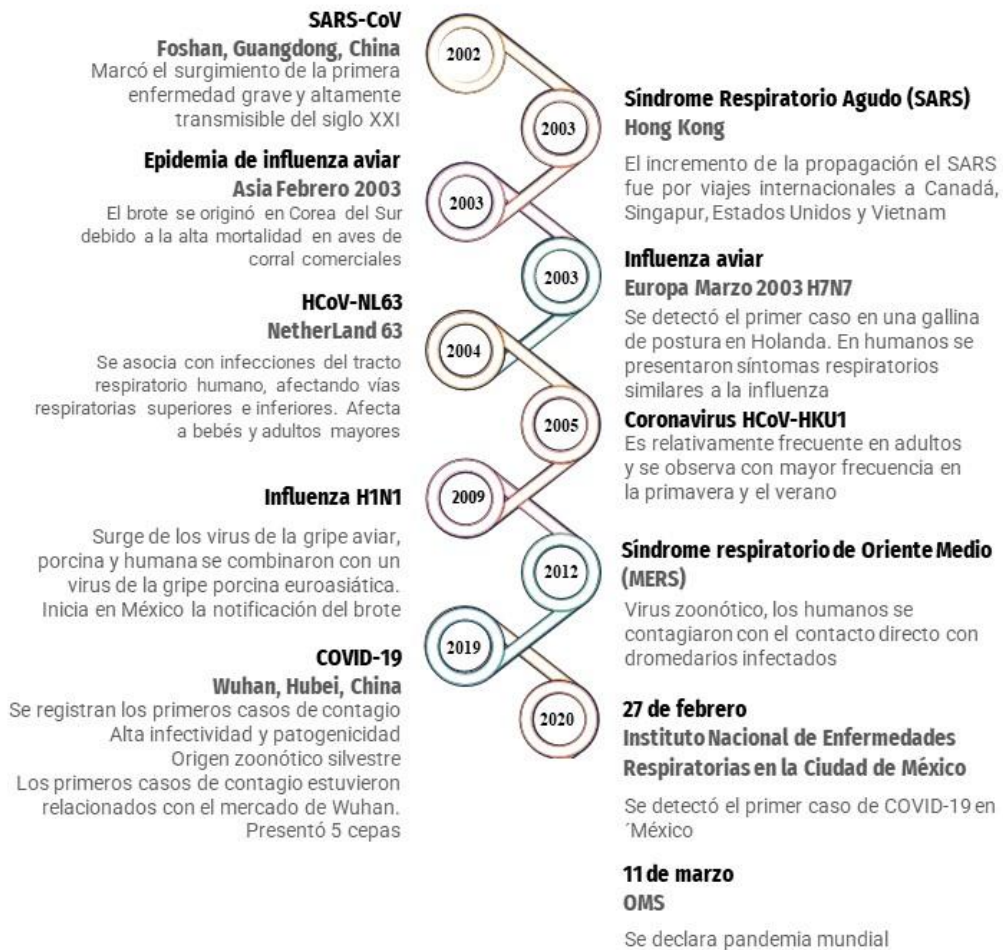
1. Alfa, Reino Unido septiembre, 2020
2. Beta, Sudáfrica mayo, 2020
3. Gamma, Brasil enero 2021

4. Delta, India y Reino Unido octubre 2021
5. Ómicron, Guateng, Sudáfrica 26 de noviembre 2021 (Petersen et al., 2022; Zárata et al., 2022)

Para el caso de México el 11 de marzo de 2020 se identificó el primer caso confirmado en el estado de Querétaro, importado de España. También se reportó el segundo y tercer caso en la Ciudad de México con síntomas leves y antecedentes de viaje en España, el cuarto caso confirmado fue una mujer de 61 años que viajó a Estados Unidos y el quinto caso se reportó como asintomático en la ciudad de Puebla (Secretaría de Salud, 2020). Dadas las condiciones de propagación de coronavirus el 30 de marzo de 2020 a través del Diario Oficial de la Federación el Poder Ejecutivo Consejo de Salubridad General se publica el acuerdo por el que se declara como emergencia sanitaria por causa de fuerza mayor, la epidemia de enfermedad generada por el virus SARS-CoV2 (COVID-19) donde se estipula que la Secretaría de Salud determinará las acciones que resulten necesarias para entender la emergencia sanitaria (Consejería Jurídica del Ejecutivo Federal, 2020).

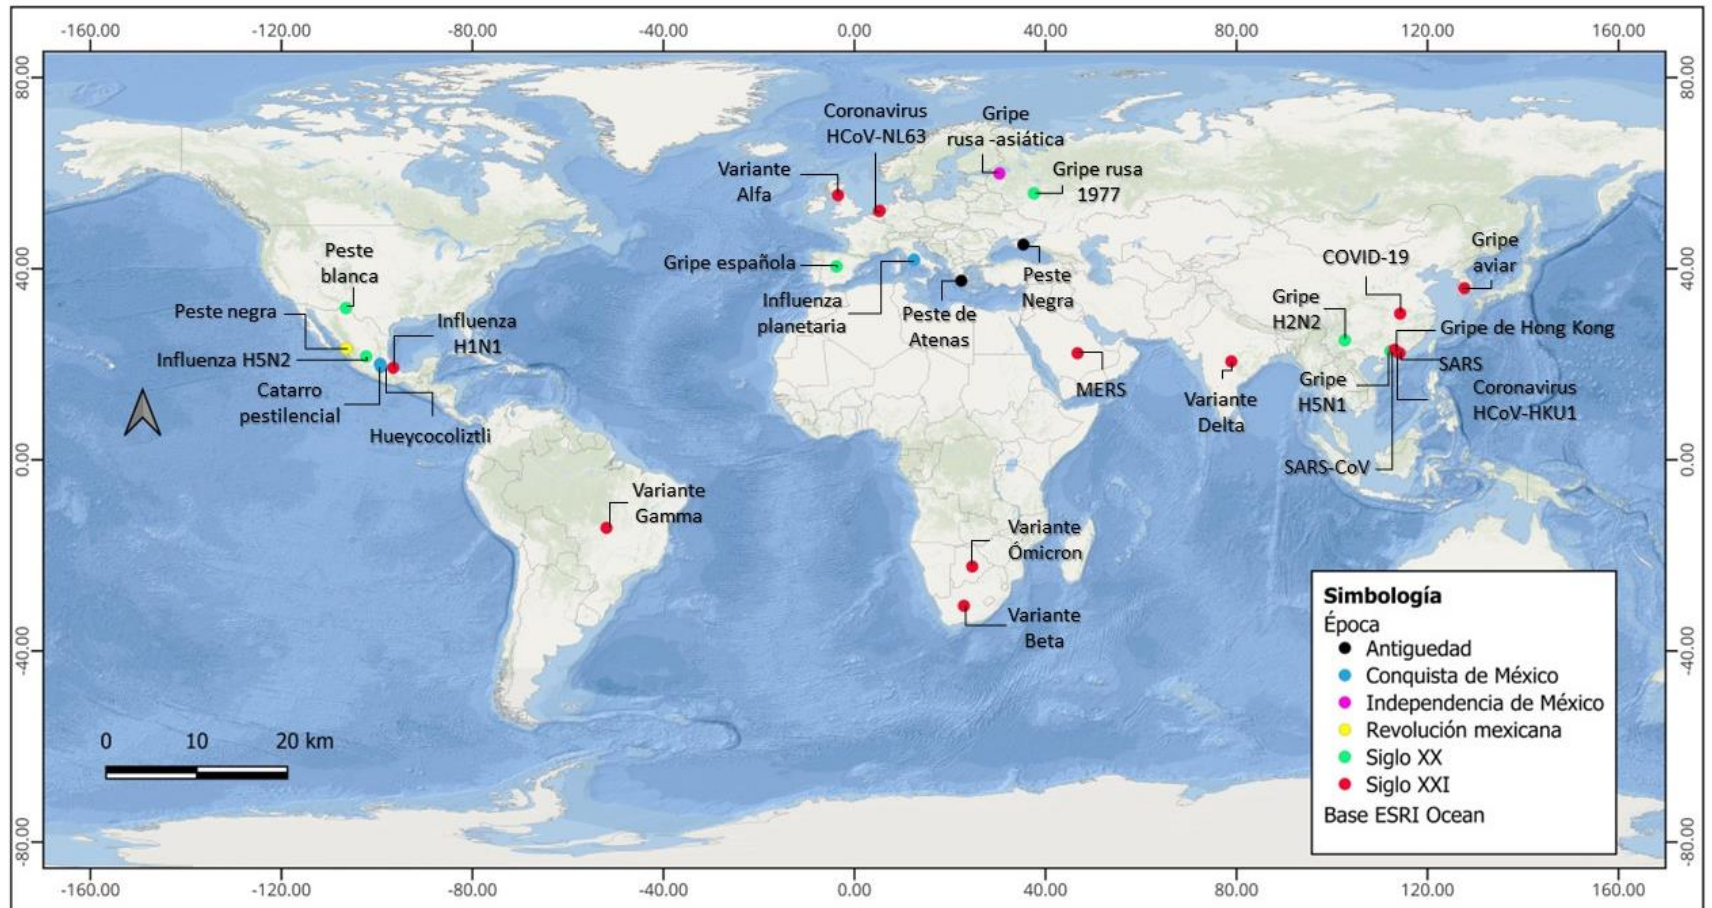
Figura 9 Línea del tiempo de las enfermedades respiratorias





Fuente: Elaboración propia con base en: (Al Hajjar & McIntosh, 2010; Berche, 2022; Cameron & Pimlott, 2015; Cartwright, 2023; Casillas et al., 2008; Ceberio, 2021; Ching, 2018; Cui et al., 2011; Fang et al., 2009; Food and Agriculture Organization of the United Nations, 2012; García-García & Ramos, 2006; Gregg et al., 1978; Henderson et al., 2009; Huerta López, 2014; John Martin Rare Book Room, 2017; Kılıç, 2020; Littman, 2009; W. Liu et al., 2022; Malvido, 2003; Malvido & Viesca, 1985; Roza & Gronvall, 2015; Ruan et al., 2003; Sanfilippo-Borrás, 2010; Sinclair, 2016; Sino Biological, 2023; Snacken et al., 1999; Weber-Chuliá et al., 2022; Weston, 2012; Wheelis, 2002; Woo et al., 2009; R. Xu et al., 2004)

Figura 10 Localización de pandemias y epidemias de enfermedades respiratorias transmisibles



Fuente: Elaboración propia, 2025

Tabla 4 Línea del tiempo de las enfermedades infecciosas respiratorias

Lugar	Nombre	Temporalidad	Políticas de salud	Origen	Población vulnerable	Síntomas	Etapas patogénicas	Número de defunciones
Península del Peloponeso	Peste de Atenas	Mayo 428 - 432aC	Debido al alto índice de defunciones numerosos cadáveres no pudieron ser enterrados y fueron abandonados en el lugar donde murieron	Pudo ser fiebre tifoidea, viruela, influenza, o ébola	Población hacinada de la ciudad de Atenas	Dolores de cabeza extrema, ojos rojos, dificultad para respirar, tos, vómito, entre otros		100,000 entre las que se encontraba Pericles, el constructor del Partenón
Caffa, República Autónoma de Crimea	Peste negra	1346	Las viviendas fueron sanitizadas y algunas incendiadas, se implementaron tratamientos de mitigación de defunciones *En México se implementaron protocolos de aislamiento y se exterminaron las ratas	El ejército mongol arrojó los cadáveres infectados con catapultas al exterior del territorio de Caffa, las ratas y pulgas se contagiaron del virus e infectaron a la población	Población urbana y comerciantes	Inflamación en los nódulos del sistema linfático, supuraciones, fiebres altas con escalofríos y delirios. El ganglio linfático se inflamaba con variantes que presentaban manchas oscuras en la piel	3 y 5 días	70% de la población falleció
Actual Feodosia, Ucrania		Variantes	Peste septicémica	Sin dato		El contagio pasaba a la sangre, presentaba manchas oscuras en la piel		
			Peste neumónica o pulmonar	Historiadores suponen que fue la más letal y propagación acelerada debido a que la vía de transmisión fue por medio del aire		Afectaba el sistema respiratorio provocando tos expectorante que era vía de transmisión por medio del aire	Horas o un día como máximo	
Epidemias en la época prehispánica en México								
Tenochtitlan y en el reino de Tula	Catarro pestilencial Cocoliztli	1450 y 1456	Los emperadores Moctezuma, Nezahualcóyotl y Totoquihuatzin	Nevadas atípicas en el Valle de México Se creía que la cabeza de un ser maligno se		Afecciones en vías respiratorias similares a la influenza epidémica		90 por ciento de la población falleció

			repartieron alimentos a grupos marginados	depositó en una barranca y durante su estado de descomposición contaminó a toda la población		No se conocen características sintomáticas		
La nueva España	Cocoluche Tos chichimeca (Tosferina)	1521	La población comenzó a dividirse en miembros de la iglesia, servidores de la corona, y los grupos de la resistencia fueron denominados chichimecas		Población joven y Grupos indígenas	Resfriado común hasta llegar a episodios de tos, rinorrea, fiebre superior a 38.9°C y diarrea	15-20 días	
Tlatelolco, La Nueva España	Huey cocoliztli,	1576	Ante el aumento de defunciones optaron por hacer grandes fosas donde depositaban los cuerpos de niños y adultos que habían sido víctimas de la enfermedad	Altos índices de desnutrición Se creía que la conjunción de Marte y Saturno ejercían efectos malévolos en la salud Los grupos originarios atribuían el incremento de contagios y defunciones en españoles por un cometa (Halley) en 1577.	Población joven y Grupos indígenas	Fiebres contagiosas, sed intensa, orina color verde y negro, taquicardias, ojos y cuerpo con coloración amarilla, delirios, convulsiones, postemas detrás de las orejas, dolor de corazón, pecho y vientre. Algunos casos con gangrena, sangrado nasal,	5 ó 6 días	1 a 2 millones de indígenas y
Roma, Italia	Pandemia de Influenza planetaria	1580		Se creía que una serie de fenómenos astrales habían causado la enfermedad		Fiebre, escalofríos, tos, dolor de garganta, mucosidad nasal o nariz tapada, dolor muscular, y de cabeza, fatiga		8,000 personas
	Gran epidemia de la influenza	1806				Durante la primavera incrementó el número de defunciones		
Rusia	Gripe rusa asiática	1889-1890	Las autoridades sanitarias recomendaron ventilar los espacios	Posible H2N2 que fue encontrado en aves	Adultos mayores y jóvenes	Se presentaba a partir de cuatro formas clínicas: 1)		1 millón de defunciones

			cerrados, desinfectar los lugares públicos y los lugares donde había pacientes contagiados, prohibición de reuniones públicas y aislamiento en casa				respiratorios leves y fiebre que aumentaba en 48 horas, 2) gastrointestinal con síntomas gástricos moderados, fiebre postración, 3) de forma catarral poco común y una forma nerviosa con intenso dolor neurálgico
--	--	--	---	--	--	--	--

Epidemias en la época de la independencia de México

Llegó a Mazatlán	Brote de la Peste negra o Peste bubónica	1902	http://meyibo.tij.uabc.mx/index.php/rmeyibo/article/view/211				
-------------------------	--	------	---	--	--	--	--

Epidemias en la época revolucionaria

El Paso, Texas Se extendió por Ciudad Juárez, México	Peste blanca Tuberculosis	1915	Se realizaron intentos por remitir a pacientes a diferentes condiciones climáticas para mejorar el estado de salud, dicha estrategia falló y optaron por realizar un diagnóstico temprano, trasladarse a espacios de paz y tener una alimentación adecuada. Se impuso a los enfermos abandonar sus comunidades de origen. Inspección médica rigurosa.	Enfermedad bacteriana infecciosa causada por <i>Mycobacterium tuberculosis</i> , que afecta principalmente a los pulmones	Inmigrantes procedentes de comunidades étnicas de México	Palidez extrema, pérdida de peso	800,000 defunciones de mexicanos
Estados Unidos (Primeros casos de contagio en el mundo)	Gripe o influenza española	1918-1919	España fue el primer país en comunicar por medio de periódicos la dinámica de mortalidad a causa de la gripe	Migración de soldados estadounidenses a Europa en condiciones de insalubres y de hacinamiento	Adultos sanos y fuertes	Fiebre alta, tos seca, dolor de oídos, cansancio corporal, dificultad respiratoria, marcas	3 días 21 millones de vidas a nivel mundial, en México 500,000

*En México se los primeros casos se presentaron en abril de 1918 en el Cuartel de Zapadores y en la Escuela del Estado Mayor de la Ciudad de México							cianóticas en pómulos y pies,
	Tuberculosis		Se realizaron chequeos constantes a la población en el periodo revolucionario no se lograron grandes resultados		Población de comunidades rurales que fallecían por la falta de atención médica		Se desconoce el dato
China (Singapur)	Gripe asiática A H2N2	1951-1958	Programas de vacunación a grupos vulnerables Se implementaron medidas para medir las tendencias epidemiológicas en países como Estados Unidos, uso de informes telegráficos semanales de defunciones. A fin de reducir la transmisión a la población vulnerable entró en cuarentena, se cancelaron y pospusieron reuniones masivas, evitar viajes.	Fue un brote pandémico de influenza aviar de categoría 2. Se originó en patos salvajes y la combinación con una cepa humana preexistente. Desapareció en 1968, los individuos que nacieron después de ese año carecen de inmunidad de las células B al H2	Alta mortalidad en niños en edad escolar hasta adultos jóvenes y con el paso del tiempo adultos mayores	Fiebre alta, malestar general, dolor de cabeza, mialgia generalizada, dolor de garganta, tos, náuseas, falta de apetito y vómitos	2 millones a nivel mundial
Hong Kong	Gripe de Hong Kong	1968-1969		Fue causada por una cepa H3N2 de la influenza A. descendiente de H2N2 a	Adultos mayores		4-5 días 1 millón

	Influenza del subtipo H3N2			través de un cambio de antigénico				
Sur de Rusia	Influenza Rusa H1N1	1977		Se atribuye a un accidente de laboratorio, una fuga de una prueba de vacuna viva o una liberación del virus como arma biológica	Población menor a 20 años en servicio militar activo			1 millón
Región Avícola de México	Influenza aviar en México H5N2	Mayo 1994	El gobierno federal implementó un programa de eliminación de aves en rastros autorizados con el propósito de evitar la venta de aves provenientes de granjas infectadas	Origen aviar	No se identificó la transmisión a humanos	No se identificó la transmisión a humanos		
Hong Kong	Influenza aviar (H5N1)	1997	Brotos de aves de corral que causaron efectos económicos y de comercio internacional	Los casos humanos de asociaron al consumo de platillos elaborados con sangre cruda y contaminada de aves de corral	Niños (9.5 años) y adultos (22años) principalmente avicultores	Fiebre, tos, dolor de garganta, dolores musculares y conjuntivitis. En los casos más graves dificultad respiratoria y neumonía	5 días	400 hasta el 2013 a nivel mundial
Epidemias del Siglo XXI								
Guangdong, China	SARS-CoV	Noviembre 2002	Lavado de manos, uso de guantes desechables, mascarilla quirúrgica, desinfectar superficies	Probable origen animal	Empleados de la salud, adultos de 25 a 70 años	Fiebre superior a 38°C, dificultad respiratoria, escalofríos, mialgias, cefaleas y malestar general		774 defunciones 8,096 casos
Hong Kong	Síndrome Respiratorio Agudo (SARS)	2003	Aislamiento de los casos, cuarentenas y restricciones de viajes. Los medios de comunicación promovieron el monitoreo de la	En la actualidad se desconoce su origen, tiene comportamientos similares a otras enfermedades respiratorias de origen viral que pueden presentarse en	La mayoría de los enfermos fueron adultos de 25 a 70 años, con baja incidencia en población infantil	Fiebre alta, tos seca, mialgia (dolor muscular y tendones), dolor de garganta leve, dificultad respiratoria	15 días	916

			temperatura corporal de la población	condiciones de bajas temperaturas				
Corea del Sur	Epidemia de influenza aviar en Asia H5N1	Agosto 2003	Se sacrificaron parvadas infectadas en Japón y la República de Corea, China implementó programas nacionales de vacunación en aves	Origen aviar	Avicultores	Sin dato		113 defunciones 205 casos
Holanda	Influenza aviar H7N7	Marzo 2003	Sacrificaron más 1 de 20 millones de aves, se iniciaron campañas de vigilancia en granjas comerciales	Origen aviar	Avicultores	Conjuntivitis y síntomas similares a influenza		
Hong Kong, China	Coronavirus humano HCoV-HKU1	2004			Adultos	Rinorrea, tos, congestión nasal, fiebre, esputo, dolor de garganta, escalofríos, secreción posnasal e hipertrofia amigdalina		
Canadá	Influenza por H7N3	Febrero 2004	Las autoridades gubernamentales decidieron sacrificar y eliminar las aves de 42 granjas comerciales	Origen aviar	Avicultores	Conjuntivitis y síntomas similares a influenza		57 casos sospechosos
Estados Unidos presenta los primeros casos * Inicia en México la notificación del brote	Gripe H1N1	2009-2010		Surge de los virus de la gripe aviar, porcina y humana se combinaron con un virus de la gripe porcina euroasiática	Menores de 5 años, adultos mayores, personas con asma bronquial severa, enfermedad obstructiva pulmonar crónica, diabetes mellitus, enfermedades por inmunodeficiencias, autoinmunidad, enfermedades crónico-degenerativas	Fiebre superior a 38 °, tos, dolor de garganta, aparente gripe, diarrea, Adultos: dolor en pecho y abdomen, dificultad respiratoria, episodios de mareos repentinos vomito intenso o continuo, confusión Niños: Dificultad para respirar, cambio de color de piel gris o azul,	10 días	730,000 en todo el mundo

						ingesta inadecuada de líquidos orales, vómito intenso o continuo, irritabilidad o sin capacidad de despertar	
Arabia Saudita	Síndrome respiratorio de Oriente Medio (MERS)	2012 ...	Aun se sigue desarrollando una vacuna. Adoptar medidas de higiene de manos antes y después de tocar a los animales, así como evitar el contacto con animales enfermos. Para evitar un cuadro grave de la enfermedad evitar beber leche, carne, orina de camello	Es un virus zoonótico, los humanos se contagiaron con el contacto directo con dromedarios infectados (no se conoce la vía exacta de transmisión)	Población adulta mayor o con sistemas inmunitarios débiles, personas con enfermedades crónicas como cáncer, neumopatías crónicas, hipertensión arterial, enfermedades cardiovasculares y diabetes	Fiebre, tos, dificultad respiratoria y en algunos casos neumonía, síntomas gastrointestinales, *Ausencia de síntomas	935 defunciones de las cuales 854 fueron en las ciudades centrales de Arabia Saudita
Wuhan, Hubei, China	COVID-19	2019 ...	La OMS declara pandemia mundial Se recomienda el uso de mascarilla, confinamiento, lavado de manos, se restringieron las reuniones masivas, viajes	Origen zoonótico silvestre por murciélagos	Población adulta mayor, personas con enfermedad pulmonar crónica, asma moderada o leve, afecciones cardíacas, o con sistema inmunitario deprimido, población con obesidad grave, diabetes, enfermedad hepática, VIH	Comunes: fiebre escalofríos, dolor de garganta Menos comunes: dolor muscular, fatiga, secreción nasal, dolor de cabeza, ocular, mareo, tos persistente, opresión o dolor de pecho, dificultad respiratoria, voz ronca, brazos y piernas pesadas, entumecimiento, náuseas, vómitos, dolor abdominal, dolor de vientre o diarrea, pérdida de apetito, pérdida del	Octubre 2023 Casos 695,781,740 Defunciones 6,919,573 Recuperados: 627,110,498

Elaboración propia 2023 con base en (Al Hajjar & McIntosh, 2010; Berche, 2022; Cameron & Pimlott, 2015; Cartwright, 2023; Casillas et al., 2008; Ceberio, 2021; Ching, 2018; Cui et al., 2011; Fang et al., 2009; Food and Agriculture Organization of the United Nations, 2012; García-García & Ramos, 2006; Gregg et al., 1978; Henderson et al., 2009; Huerta López, 2014; John Martin Rare Book Room, 2017; Kılıç, 2020; Littman, 2009; W. Liu et al., 2022; Malvido, 2003; Malvido & Viesca, 1985; Rozo & Gronvall, 2015; Ruan et al., 2003; Sanfilippo-Borrás, 2010; Sinclair, 2016; Sino Biological, 2023; Snacken et al., 1999; Weber-Chuliá et al., 2022; Weston, 2012; Wheelis, 2002; Woo et al., 2009; R. Xu et al., 2004).

Consideraciones

Históricamente las epidemias y pandemias de enfermedades respiratorias han estado influenciadas por diversos factores y condiciones sociales que han afectado la salud pública. Entre los factores predominantes en la propagación de enfermedades transmisibles se encuentra la movilidad humana, manifestada en flujos migratorios, desplazamientos internacionales y dinámicas comerciales. Además, la urbanización acelerada ha llevado a la concentración de grandes poblaciones en espacios urbanos con viviendas y establecimientos concurridos, potenciando la transmisión de enfermedades. Es imperativo mencionar que conflictos armados y conquistas territoriales han representado un riesgo sanitario, debido a la interrupción de sistemas alimentarios y de salud pública.

El cambio climático ejerce una influencia significativa en la aparición y distribución de enfermedades respiratorias. Variables como el aumento o descenso de la temperatura, las variaciones en la humedad relativa y el deterioro de la calidad del aire, en conjunto, crean condiciones favorables para la proliferación de patógenos respiratorios. La interacción entre humanos y animales, especialmente en contextos de agricultura intensiva y comercio en mercados, incrementa el riesgo de aparición y transmisión de enfermedades de origen zoonótico.

Las regiones del hemisferio norte han mostrado mayor vulnerabilidad ante brotes de enfermedades respiratorias. Países como China y naciones europeas han fungido históricamente como epicentros recurrentes, registrando brotes epidemiológicos de enfermedades respiratorias infecciosas y la aparición de variantes que han provocado millones de decesos a nivel mundial. De manera notable, estos focos de alta transmisión se han ubicado en zonas estratégicas como puertos, regiones costeras, capitales y centros comerciales, lo que pone de relieve la estrecha relación entre la movilidad, el comercio y la propagación de dichas enfermedades.

3.2 Enfermedades respiratorias infecciosas (2009-2019)

El análisis de los casos acumulados de enfermedades respiratorias infecciosas durante el periodo 2009–2019, previo al inicio de la pandemia por COVID-19, permitió la identificación de la dinámica estacional de los contagios en la Ciudad de México. En abril de 2009, México se convirtió en epicentro de la epidemia por el virus de influenza A (H1N1), lo que marcó un hito en la vigilancia epidemiológica del país.

A pesar de la emergencia sanitaria de 2009, los registros correspondientes a otras enfermedades respiratorias infecciosas no crónicas, clasificadas conforme a la CIE-10 (por ejemplo: infecciones agudas de las vías respiratorias superiores, bronquitis aguda, laringitis y traqueítis agudas, entre otras), se mantuvieron en niveles bajos dentro de la entidad.

En septiembre de 2011 se observó un incremento sostenido en los contagios, con un punto crítico alcanzado en noviembre del mismo año, cuando se registraron 75 ingresos hospitalarios relacionados con este tipo de enfermedades. Este valor representa el pico más alto de contagios en todo el periodo analizado.

Los datos presentados en la figura 11 evidencia que los contagios por enfermedades respiratorias infecciosas presentan una dinámica cíclica, con repuntes sistemáticos durante los meses invernales (diciembre, enero y febrero), cuando las condiciones meteorológicas frías favorecen la propagación de agentes virales. Esta relación se mantiene constante a lo largo de la década, con variaciones más marcadas en los inviernos de 2010, 2013 y 2015.

Durante todo el periodo analizado, los meses con menor incidencia de contagios correspondieron a las estaciones de primavera y verano, cuando las temperaturas son más cálidas y las condiciones ambientales resultan menos propicias para la propagación de virus respiratorios.

En la figura 11 se presenta una comparativa entre la incidencia de ingresos hospitalarios en hombres y mujeres frente a las fluctuaciones de la temperatura media mensual del periodo 2009-2019.

A lo largo del período analizado previo a la pandemia de COVID-19, se observa que los hombres presentan una mayor susceptibilidad a las enfermedades infecciosas, con un

número elevado de ingresos hospitalarios en comparación con las mujeres. La tendencia se acentúa con la presencia de temperaturas frías, donde la población masculina fue más vulnerable a los cambios de temperatura en cuanto al riesgo de enfermedad infecciosa.

Un incremento notable en la incidencia de hospitalizaciones masculinas se detecta en abril de 2009, coincidiendo con la declaración de la epidemia de H1N1, a pesar de que la temperatura media se mantenía relativamente templados 19.6°C. Este hecho podría indicar que otros factores, como la variante del virus, la marginación, el empleo, la densidad poblacional, desempeñaron un rol más predominante que las condiciones climáticas en la incidencia de la enfermedad.

Además, se registró otro incremento significativo de hospitalizaciones en hombres durante el mes de noviembre de 2009, cuando las temperaturas medias descendieron a 14.9°C. Por el contrario, en este mismo período, no se observó un incremento en las admisiones hospitalarias entre la población femenina.


El mes más crítico para ingresos hospitalarios de mujeres fue diciembre de 2012, en hombres, se ha identificado que octubre de 2013 fue el periodo de máxima incidencia. Este mes destacó por un aumento significativo en la cantidad de casos, lo que señala la posibilidad de una circunstancia de salud excepcional, como podría ser un rebrote de enfermedad específica o la circulación de un virus contagioso.

Con la llegada de la primavera y el verano y el constante aumento de las temperaturas, se identifica una disminución notable en los ingresos hospitalarios para ambos géneros, sugiriendo una correlación inversa entre la temperatura y la incidencia de enfermedades infecciosas.

En mayo de 2019 registró las temperaturas medias mensuales más elevadas del periodo analizado, con un promedio de 21.04 °C, no se observó en este mes un incremento en los ingresos hospitalarios por enfermedades infecciosas para ninguno de los géneros. Este patrón es consistente con las expectativas comunes de que las enfermedades respiratorias infecciosas disminuyan con el aumento de las temperaturas. Por tanto, la relación entre las temperaturas más cálidas y la disminución de hospitalizaciones se mantiene.

Durante la década, los puntos de mínima incidencia de hospitalizaciones coinciden con los meses más cálidos, mientras que los puntos de máxima incidencia se asocian con los meses más fríos, reafirmando la influencia de la estacionalidad en las enfermedades infecciosas. Esta relación estacional es un elemento de alerta para el diseño de estrategias de salud pública que busquen prevenir y controlar la incidencia de enfermedades respiratorias infecciosas.

Figura 11 Casos acumulados de enfermedades respiratorias infecciosas en la Ciudad de México (2009–2019)



Fuente: Elaboración propia con base en datos del INSP, 2024.

Entre 2016 y 2019 se mantuvo una tendencia descendente en los contagios, lo que reflejó una fase de relativa estabilidad en la incidencia de enfermedades respiratorias infecciosas en la Ciudad de México. No obstante, en el último trimestre de 2019, a partir de octubre, se registró un aumento progresivo en los casos. Esta variación marcó el inicio de una nueva fase de crecimiento sostenido que se intensificó durante los meses siguientes y culminó en el escenario epidémico observado en 2020.

3.1 Enfermedades respiratorias infecciosas por grupo de edad

En la figura 12 se presenta la evolución mensual de los casos de enfermedades respiratorias infecciosas (ERI) entre enero de 2009 y diciembre de 2019, desagregados por

grupo etario. El análisis de esta serie temporal permite la identificación de diferencias en la magnitud, recurrencia y estacionalidad de los casos entre los distintos grupos de edad, revelando patrones epidemiológicos con implicaciones para la vigilancia y la planificación en salud pública.

El grupo de primera infancia (niñas y niños menores de cinco años) concentra la mayor cantidad de casos en todo el periodo. Destacan picos pronunciados y recurrentes, durante los meses de invierno, lo que sugiere una fuerte influencia estacional. El mayor repunte registrado corresponde a enero de 2013, con un total de 328 casos, cifra significativamente superior al resto. Estos patrones estacionales cíclicos apuntan a una mayor susceptibilidad inmunológica en este grupo, así como a una alta exposición a espacios cerrados y compartidos como guarderías, lo que facilita la propagación de virus respiratorios.

El segundo grupo más afectado es infancia (niñas y niños en edad escolar), que, si bien presenta una menor proporción de casos, mantiene también una dinámica estacional con incrementos notables en los meses fríos. Este patrón coincide con el calendario escolar y con una posible transmisión comunitaria en ambientes escolares.

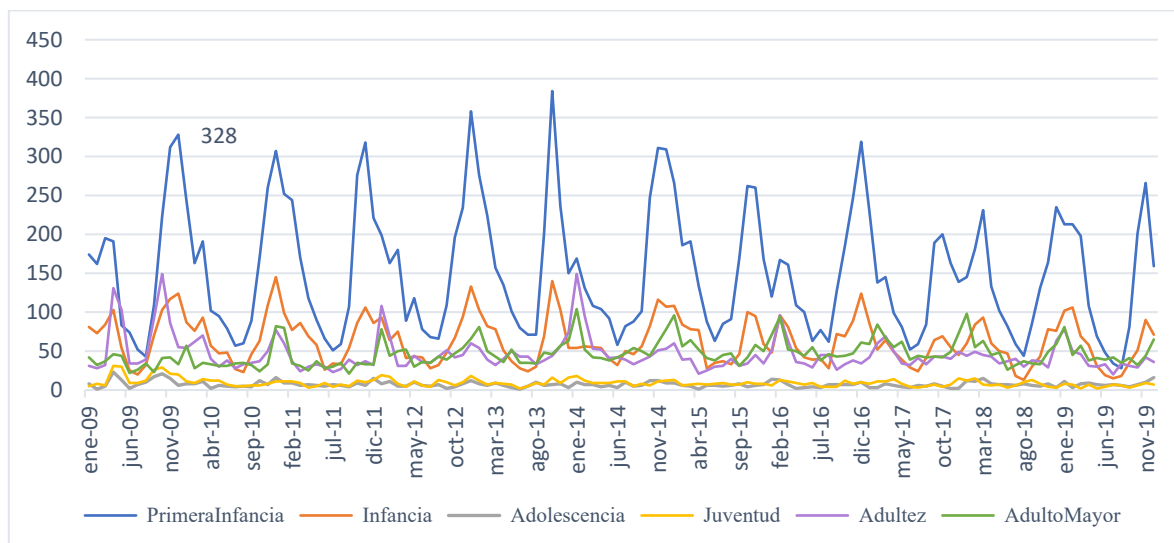
Previo a la pandemia de COVID-19 la población infantil, fue el grupo etario más afectado por enfermedades respiratorias infecciosas. De acuerdo con Huang et al. (2022) esta vulnerabilidad se debe a múltiples factores fisiológicos y ambientales los niños respiran con mayor frecuencia que los adultos, lo que incrementa el volumen de contaminantes inhalados, y sus órganos (pulmones, cerebro y sistema inmunológico) aún se encuentran en desarrollo, lo que los hace más susceptibles a los efectos nocivos del aire contaminado. En niños de mayor edad, el incremento en la actividad física al aire libre y la limitada adopción de medidas preventivas generan una mayor exposición a contaminantes atmosféricos. Según lo documentado por Song et al. (2018), esta exposición intensificada se asocia con efectos más severos en la salud respiratoria, estableciendo una relación dosis-efecto en la que un mayor nivel de exposición conlleva un riesgo proporcionalmente elevado.

El grupo de adultos mayores muestra una tendencia particular, aunque sus cifras son inferiores a las de los grupos infantiles, se observa un incremento progresivo en los picos anuales conforme avanza la serie temporal. Esta población muestra mayor vulnerabilidad a

las enfermedades respiratorias crónicas, atribuible al deterioro fisiológico asociado con la edad, como la disminución de la capacidad pulmonar y la respuesta inmunitaria.

Esta tendencia encuentra respaldo en estudios previos de Hua et al. (2022) y Xiang et al. (2024) identificaron asociación significativa entre la exposición a contaminantes atmosféricos como PM_{2.5}, PM₁₀, SO₂, NO₂ y CO y el aumento en las hospitalizaciones por enfermedades respiratorias crónicas (CRD, por sus siglas en inglés) en personas mayores de 65 años. Estos estudios, también documentaron que el promedio diario de ingresos hospitalarios en este grupo etario fue más elevado durante los días fríos, lo que coincide con mayores concentraciones de dichos contaminantes, lo que sugiere una interacción entre factores ambientales y estacionales que agrava el riesgo respiratorio en esta población. En particular, el clima seco y la baja velocidad del viento en la temporada fría contribuyen a la acumulación de contaminantes atmosféricos. Los grupos correspondientes a adolescencia, juventud y adultez presentan una evolución relativamente estable, con variaciones menos marcadas y sin picos estacionales evidentes. La curva de estos grupos es plana en comparación con los anteriores, lo que puede explicarse por una menor vulnerabilidad inmunológica y una exposición diferente a los factores de contagio. No obstante, es importante considerar la posibilidad de subregistro o de casos no atendidos en el sistema de salud, especialmente si los síntomas son leves o autolimitados.

Figura 12 Enfermedades respiratorias infecciosas por grupo de edad de la Ciudad de México (2009-2019)



Fuente: Elaboración propia con base en datos del INSP, 2024.

3.4 Correlaciones de contaminación y enfermedades respiratorias

El análisis realizado permite identificar que los contaminantes asociados principalmente al tráfico vehicular, tales como el monóxido de carbono (CO), el óxido nítrico (NO) y los óxidos de nitrógeno (NOX), presentan las correlaciones positivas inmediatas más elevadas con el total de ingresos hospitalarios. Esta dinámica indica que las emisiones provenientes de la combustión de combustibles fósiles inciden de manera directa en la carga hospitalaria por enfermedades respiratorias y cardiovasculares.

Por su parte, las partículas PM₁₀ muestran una correlación moderada, lo que resulta coherente con su mecanismo de afectación aguda en vías respiratorias, especialmente ante exposiciones intensas y de corta duración. En contraste, las partículas PM_{2.5} demuestran una correlación inmediata débil, lo que concuerda con estudios previos (Macintyre et al., 2016; Mebrahtu et al., 2023), los cuales documentan que el impacto en la salud de las partículas finas es más notorio tras exposiciones prolongadas, acumulándose en el organismo hasta alcanzar niveles críticos de daño.

Respecto al ozono (O₃), el análisis muestra una correlación negativa, fenómeno que podría explicarse debido a que su formación depende de procesos fotoquímicos impulsados por radiación solar intensa, condiciones que, en el corto plazo, podrían coincidir con una disminución de enfermedades respiratorias agudas atribuibles a otros factores ambientales.

La baja magnitud general de las correlaciones encontradas indica que los efectos de la contaminación atmosférica sobre la salud no se manifiestan de manera inmediata, sino que responden a dinámicas más complejas de exposición acumulada y procesos fisiopatológicos retardados. Esta evidencia subraya la necesidad de emplear modelos analíticos más avanzados, que consideren el rezago temporal y las interacciones multifactoriales entre contaminantes, para una comprensión más precisa de la relación entre calidad del aire y salud pública.

Consideraciones

Quienes en 2009 pertenecían al grupo de Primera Infancia (0 a 4 años), para el año 2020 durante la pandemia por COVID-19 tenían entre 11 y 15 años, es decir, se ubicaban principalmente en los grupos de Adolescencia y Juventud temprana. Esta cohorte poblacional

creció expuesta de forma continua y acumulativa a altos niveles de contaminación atmosférica, urbana y social, especialmente en entornos con condiciones ambientales degradadas. A lo largo de su desarrollo, estos individuos enfrentaron una carga persistente de exposición a contaminantes como partículas finas (PM2.5, PM10), ozono, dióxido de nitrógeno y compuestos volátiles, lo que probablemente influyó en la maduración de su sistema inmunológico y respiratorio.

Durante la pandemia por COVID-19, dicha población, aunque no fue la más afectada en términos de letalidad mostró indicios de efectos acumulativos de dicha exposición temprana. Este fenómeno plantea la hipótesis de una posible memoria ambiental o vulnerabilidad condicionada por trayectorias de exposición crónica, en la que los efectos no se manifiestan de forma aguda en la infancia, sino que emergen en etapas posteriores del ciclo de vida, especialmente ante eventos de alta carga viral o estrés inmunológico sistémico, como lo fue la infección por SARS-CoV-2.

3.4 Dinámica espacio – temporal de las enfermedades respiratorias infecciosas y situación de la pandemia por COVID-19

3.3 Factores geográfico – ambientales

3.3.1 Climas

De acuerdo con la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO, 1998), la Ciudad de México presenta una diversidad climática significativa en su territorio. Los climas predominantes se clasifican principalmente en tres categorías: C(wo), C(w1), y C(w2), correspondientes a climas templados y subhúmedos. Estos climas caracterizan por tener una temperatura media anual que oscila entre 12°C y 18°C, con temperaturas en el mes más frío que varían desde -3°C hasta 18°C, y temperaturas en el mes más caliente que no superan los 22°C.

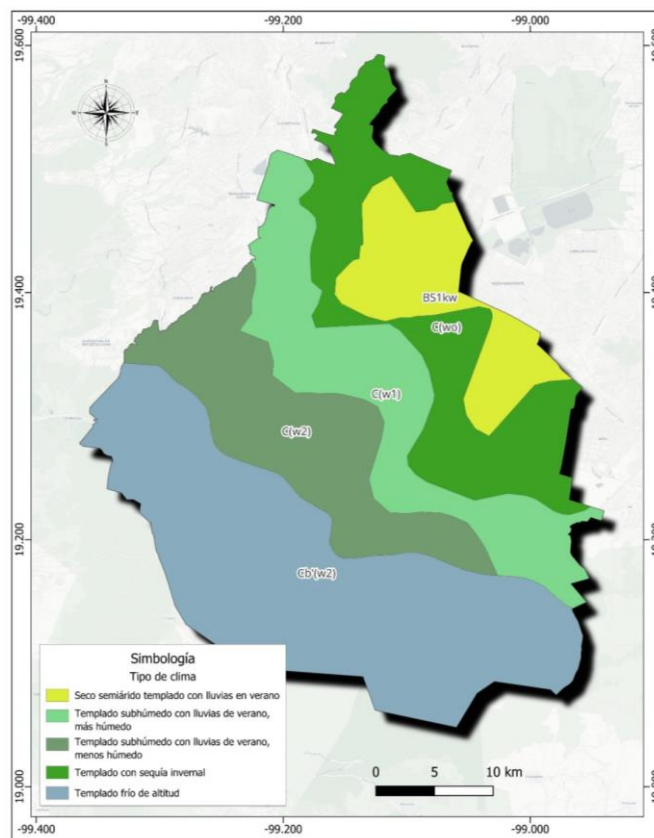
En la figura 13 se muestra la distribución climática, estos se encuentran principalmente en la zona norte, centro y este de la Ciudad, abarcando delegaciones como Gustavo A. Madero, Cuauhtémoc, Benito Juárez, Iztapalapa, Tláhuac y el norte de Xochimilco. Investigaciones recientes, como la de Coria Lorenzo et al. (2020), señala que estas condiciones han sido ideales para la propagación de casos de influenza desde el año 2009 hasta el 2018.

El clima Cb'(w2), se clasifica como semifrío y subhúmedo con veranos frescos y prolongados, predomina en las zonas sur de la ciudad, incluyendo delegaciones como Milpa Alta, Tlalpan, Magdalena Contreras, Álvaro Obregón y el sur de Cuajimalpa. Este clima se caracteriza por tener una temperatura media anual entre 5°C y 12°C, y también por presentar precipitaciones en el mes más seco menores de 40 mm.

Este clima es característico de zonas boscosas y áreas con mayor altitud, por ejemplo, Tláloc y el Ajusco. Las condiciones de estas regiones generan temperaturas más bajas y vientos fríos en invierno.

El clima semiárido templado, clasificado como BS1kw, forma parte de la diversidad climática de la Ciudad de México. Este clima mantiene una temperatura media anual entre 12°C y 18°C, con lluvias concentradas en el verano y un porcentaje de lluvia invernal que representa entre el 5% y el 10.2% del total anual.

Figura 13 Tipos de clima en la Ciudad de México



3.3.2 Temperatura

De acuerdo con los datos del Gobierno de la Ciudad de México (s/f), previo a la pandemia de COVID-19, se observaron variaciones significativas en las temperaturas medias mensuales en la Ciudad de México durante el periodo comprendido entre 2009-2020


En 2009, en el contexto de la epidemia de influenza por el virus H1N1, se registró una temperatura media anual de 17.24 °C. A partir de ese momento, la temperatura se estabilizó en valores cercanos a los 16 °C, hasta que en 2019 se documentó un ascenso significativo, alcanzando una media anual de 17.45 °C como se muestra en la figura 14.

En los meses de abril y mayo de toda la serie de tiempo se identificaron periodos con temperaturas más elevadas. En julio de 2011 destacó como el mes más cálido de todo el periodo analizado. Las alcaldías de Venustiano Carranza y Gustavo A. Madero presentaron las mayores temperaturas, mientras que Cuajimalpa se caracterizó de forma recurrente por registrar los valores más bajos. Esta distribución térmica evidencia la influencia de variables

geográficas y topográficas particulares, entre las que sobresalen la altitud, el grado de urbanización y la presencia de zonas con cobertura vegetal, elementos que modulan de manera significativa los patrones climáticos locales.

De acuerdo con Patz et al. (2003), la variabilidad de las temperaturas es un factor condicionante en la transmisión y variabilidad de los patógenos respiratorios. Estas alteraciones meteorológicas se reflejan directamente en la incidencia y gravedad de las enfermedades respiratorias, aumentando de manera indirecta la exposición a factores de riesgo que pueden comprometer la salud respiratoria de la población.

Figura 14 Serie de tiempo de temperaturas máximas, medias, mínimas y humedad media mensual de la Ciudad de México (2009-2021)



Fuente Elaboración propia con base en datos del Sistema de Monitoreo Atmosférico de la Ciudad de México (2024)

En el periodo de 2009 y 2019, la temperatura promedio fue de 16.8°C en la Ciudad de México. La alcaldía de Tlalpan fue una de las que presentó temperaturas medias bajas, durante el mes de enero de 2018, presentó la temperatura mensual promedio más baja registrada en toda la serie analizada, con un valor de 9.65 °C, acompañada de una humedad relativa promedio del 57.2%, una velocidad del viento de 2.27 m/s, y una dirección predominante de 168.76°, lo que indica la influencia de flujos del sureste, asociados a corrientes descendentes en zonas montañosas.

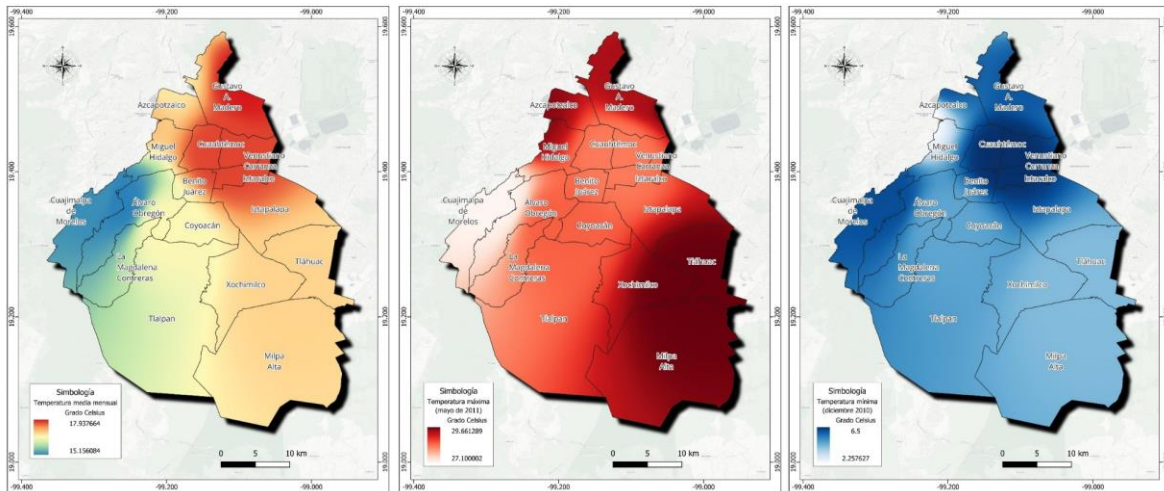
La temperatura mensual promedio más alta se observó en la alcaldía de Gustavo A. Madero durante mayo de 2011, alcanzando los 22.07 °C. En este caso, la humedad relativa fue más baja (37.4 %), con una velocidad del viento de 2.00 m/s y una dirección dominante de 196.38°, lo cual podría vincularse con flujos cálidos provenientes del suroeste.

Durante los meses de primavera y verano, la Ciudad de México experimenta los niveles más altos de carga térmica. En este contexto, mayo de 2011 destacó por registrar temperaturas más elevadas del periodo 2009–2019. Las zonas noreste y sur de la ciudad concentraron las temperaturas más altas que oscilaron en 29.6 °C, mientras que las alcaldías Cuajimalpa y Álvaro Obregón conservaron temperaturas más bajas de 27.1°C en comparación con el resto del territorio. Esta diferencia térmica evidencia que la interacción entre altitud, cobertura vegetal y nivel de urbanización influye directamente en la dinámica térmica urbana. En particular, las zonas con escasa vegetación y elevada densificación construida tienden a registrar temperaturas más altas, mientras que aquellas con mayor cobertura forestal y menor grado de urbanización conservan condiciones térmicas más frescas.

Las temperaturas más bajas se observaron de manera recurrente al oriente, particularmente en las alcaldías de Cuajimalpa y sectores de Álvaro Obregón, áreas caracterizadas por mayores altitudes, y cobertura forestal. Estas condiciones actúan como reguladores térmicos locales, que favorecen a microclimas más frescos.

La dirección predominante del viento durante el periodo analizado mostró un patrón de desplazamiento hacia el sur, lo que indica un flujo atmosférico desde las zonas urbanizadas más cálidas hacia las regiones montañosas del suroeste. Esta dinámica incide en la modulación térmica y en la dispersión de contaminantes atmosféricos, con implicaciones relevantes para la salud pública y la planificación ambiental en entornos urbanos densamente poblados.

Figura 15 Distribución espacio-temporal de la temperatura media mensual, máxima y mínima en la Ciudad de México (2009-2019)



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

3.3.3 Condiciones meteorológicas durante la pandemia por COVID-19 (2020-2023)

Durante la pandemia de COVID-19 se observaron patrones térmicos cíclicos comparables a los registrados entre 2009 y 2019. En particular, los meses correspondientes a la primavera concentraron las temperaturas medias mensuales más elevadas del periodo 2020–2023. En esta fase estacional, los valores oscilaron entre 22.2 °C y 16.67 °C, mientras que en los meses de otoño e invierno se registraron temperaturas medias más bajas, con un rango comprendido entre 17.9 °C y 12.81 °C. Esta dinámica térmica indicó la permanencia de una dinámica estacional marcada, incluso en contextos epidemiológicos excepcionales como el vivido durante la pandemia.

Sin embargo, los picos de contagio y la intensidad de las diferentes olas epidemiológicas no mostraron una coincidencia sistemática con estos ciclos térmicos. La dinámica de los casos positivos en la Ciudad de México respondió, en mayor medida, a la propagación de distintas variantes del virus SARS-CoV-2 que presentaron patrones de transmisión propios, con independencia de las condiciones climáticas. El incremento en los contagios no puede atribuirse exclusivamente a temperaturas extremas altas o bajas, dado que las sucesivas olas epidémicas ocurrieron en diversos momentos del año. Esta observación sugiere que la propagación del virus estuvo determinada principalmente por el tipo de variante, más que por variaciones en la temperatura ambiente.


El aumento de la temperatura ambiental se correlaciona con la disminución de la humedad relativa (HR). Durante la pandemia de COVID-19, la humedad relativa media mensual en la Ciudad de México osciló entre 69.5 % y 28.8 % en los meses correspondientes a primavera y verano. En la figura 16 los registros de marzo de 2020, febrero, marzo y abril de 2021, así como marzo y mayo de 2022 y marzo de 2023, presentaron niveles de humedad relativa inferiores al umbral considerado óptimo (40–60 %).

En marzo de 2020, los niveles reducidos de humedad relativa (<40 %) coincidieron con el inicio del brote epidémico y con un aumento significativo en los casos de contagio de COVID-19. Durante enero de 2021 se alcanzó el pico de la primera ola, seguido por una fase de descenso en marzo y abril del mismo año. De forma similar, entre marzo y mayo de 2022 se observó la fase decreciente de la tercera ola epidemiológica. En marzo de 2023, los registros indicaron una baja incidencia, con menos de diez casos confirmados por mes.

Guarnieri et al. (2023) y Wolkoff et al. (2021) han documentado que niveles bajos de humedad relativa pueden inducir sequedad e irritación en el tracto respiratorio y en la piel, condiciones que aumentan la susceptibilidad a infecciones virales. Además, se ha señalado que una HR inferior al 40 % favorece la acumulación de ozono en espacios interiores, el cual genera efectos irritantes sobre las mucosas oculares, nasales, faríngeas y respiratorias. A pesar de las medidas de confinamiento implementadas durante la pandemia, este fenómeno pudo haber afectado la salud respiratoria de la población expuesta en interiores mal ventilados.

Durante los meses de otoño e invierno, la humedad relativa mensual se mantuvo en un rango de 71.6 % a 32.39 %. De acuerdo con Sterling & Arundel (1985) los valores que se encuentran fuera del intervalo óptimo de 40–60 % generan repercusiones importantes en la salud de la población, al facilitar la propagación de agentes infecciosos y agravar enfermedades respiratorias preexistentes. Una humedad excesiva crea ambientes propicios para el crecimiento de microorganismos patógenos, como mohos, bacterias y virus. Por ejemplo, virus respiratorios como los de la influenza, parainfluenza, resfriado común, y adenovirus muestran una mayor persistencia y transmisión cuando la humedad relativa se sitúa por debajo del 50 % o por encima del 70 %.

Figura 16 Temperatura y humedad relativa media mensual (2020-2023)



Fuente: Elaboración propia con base en datos de la Red Meteorológica de la Ciudad de México, 2025

3.3.4 Contaminación atmosférica

La exposición prolongada a contaminantes atmosféricos constituye una amenaza significativa para la salud pública, al estar asociada con un aumento en la incidencia de enfermedades respiratorias, cardiovasculares y con un mayor riesgo de mortalidad prematura. En entornos urbanos, la distribución espacial de dichos contaminantes no es homogénea y presenta variaciones tanto temporales como estacionales, con fluctuaciones diarias, mensuales, estacionales y anuales.

Las concentraciones de contaminantes en la atmósfera están determinadas por una multiplicidad de factores, entre los que destacan el volumen de emisiones provenientes de fuentes fijas y móviles, la intensidad del consumo de bienes y servicios por parte de la población, los patrones de demanda energética, la configuración geográfica del territorio y las condiciones meteorológicas locales. Estos elementos interactúan de forma compleja, modulando la dispersión, acumulación y persistencia de contaminantes en el aire urbano.

De acuerdo con la Organización Mundial de la Salud en septiembre de 2016 se estimó que aproximadamente el 92 % de la población mundial vivía en regiones donde la calidad del aire excedía los límites recomendados para la concentración de contaminantes

atmosféricos. Para abril de 2022, esta proporción se elevó al 99 %, reflejando una tendencia preocupante en la exposición global a ambientes insalubres. Este incremento ha sido vinculado con un mayor riesgo de enfermedades cardiovasculares, cerebrovasculares y respiratorias, lo que evidencia la creciente carga sanitaria asociada a la contaminación del aire (OMS, 2022).

3.3.5 Ozono (O₃)

Previo a la pandemia de COVID-19 la Comisión Ambiental Metropolitana registró eventos de precontingencia relacionadas con la concentración de ozono (O₃) en la atmósfera de la Ciudad de México. De acuerdo con el reporte de SEDEMA (2011), en 2002 se identificaron diez precontingencias por ozono, de las cuales dos fueron activadas. En 2003, se registraron dos, seguidas por tres eventos fase uno de ozono en 2007 y dos en 2008. El año 2010 mostró tres sucesos de precontingencia, mientras que en 2011 se contabilizaron cuatro.

La tendencia continuó en años posteriores, con reportes adicionales que destacaron una constante de eventos relacionados con el ozono. En 2016, se documentaron diez eventos en fase 1 por ozono (SEDEMA, 2016). Los años siguientes mostraron una disminución en la frecuencia de estas fases, con dos eventos reportados en 2017, uno en 2018, y cuatro en 2019, de los cuales uno correspondió a una fase extraordinaria y tres a fase 1. En 2020, se registró un único evento de activación en fase 1 (SEDEMA, 2020).

En la Ciudad de México, la dinámica del ozono (O₃) está vinculada a patrones específicos de movimiento del viento y condiciones atmosféricas. El viento predominante se desplaza desde el norte hacia el sur y suroeste de la Ciudad, lo cual influye en la distribución del ozono a través de la zona metropolitana (SEDEMA, 2021).

El ozono troposférico presenta un comportamiento fuertemente influenciado por la radiación solar, con un patrón diurno claramente definido. Según datos de la Secretaría del Medio Ambiente (SEDEMA, 2021), las concentraciones más elevadas de este contaminante se registran generalmente entre las 12:00 y las 14:00 horas, las cuales coinciden con el máximo de radiación ultravioleta. Esta dinámica responde a la naturaleza fotoquímica del ozono, cuya formación resulta de la interacción entre óxidos de nitrógeno (NO_x) y

compuestos orgánicos volátiles (COV) en presencia de luz solar. En ausencia de radiación, como ocurre durante las horas nocturnas, las concentraciones disminuyen de manera considerable por a la interrupción de los procesos de radiación.

La primavera ha sido identificada como la estación con mayor prevalencia de ozono, debido a que presenta un conjunto de condiciones atmosféricas que favorecen su formación y acumulación. Durante este periodo, la baja humedad relativa, la escasa cobertura nubosa y la reducida velocidad del viento contribuyen a la estabilidad de la atmósfera y a la permanencia del ozono en niveles elevados. Asimismo, la mayor inestabilidad térmica y convectiva propia de esta estación puede generar variaciones diarias significativas en los niveles registrados, reforzando su carácter dinámico y sensible a los factores meteorológicos predominantes (SEDEMA, 2021).


En la Ciudad de México, las concentraciones más elevadas de ozono troposférico (O_3) se han registrado de forma recurrente durante los meses de marzo, abril y mayo, evidenciando un patrón estacional consistente a lo largo del tiempo. Esta tendencia se ha presentado mediante episodios críticos ocurridos en mayo de 2010 y 2011, marzo de 2012, abril y mayo de 2013, mayo de 2015, marzo de 2016, así como en mayo de 2017 y 2018, abril de 2019 tal como se ilustra en la Figura 17.

Durante los meses con temperaturas más altas, la dinámica del ozono mostró una relación inversa respecto al comportamiento de las enfermedades respiratorias. En particular, se identificó que los incrementos en los niveles de ozono coincidieron con una disminución en los contagios acumulados, mientras que las reducciones en su concentración se asociaron con un repunte en los casos registrados. Esta correlación inversa sugiere que, aunque el ozono representa un contaminante atmosférico de relevancia sanitaria, su efecto sobre la incidencia de enfermedades respiratorias no sigue un patrón lineal. En cambio, podría estar condicionado por una interacción multifactorial en la que intervienen variables como la humedad ambiental, el tiempo de exposición, la susceptibilidad inmunológica de la población o incluso el comportamiento social durante distintas fases de la pandemia.

Esta estacionalidad en los niveles de ozono se asocia con la disminución de las precipitaciones durante la primavera, lo cual limita el lavado atmosférico y favorece la acumulación del contaminante. Además, la mayor irradiación solar, las condiciones de

estabilidad atmosférica y la baja humedad relativa propias de esta estación configuran un entorno propicio para los procesos fotoquímicos que generan ozono en el ambiente urbano. En cuanto a la distribución espacial, áreas específicas de la ciudad como El Pedregal en la alcaldía Álvaro Obregón registraron consistentemente altas concentraciones de O₃. En 2019, SEDEMA reportó un total de 389 horas con concentraciones elevadas de ozono en esta zona, un factor que contribuyó a la activación de la fase 1 de contingencia ambiental en la Ciudad de México. Además, los fines de semana, específicamente los sábados y domingos, se han identificado como los días con mayor concentración de O₃.

Figura 17 Promedios mensuales de temperatura y ozono y su relación con contagios respiratorios acumulados (2009–2019)




Fuente: Elaboración propia con base en el Sistema de Monitoreo Atmosférico de la Ciudad de México (2024)

Durante los meses de confinamiento asociados a la fase inicial de la pandemia por COVID-19, se observó una reducción significativa en los niveles generales de contaminación atmosférica en la Ciudad de México, atribuida a la drástica disminución de la movilidad urbana y a la suspensión temporal de diversas actividades económicas. Sin embargo, en marzo de 2020, los niveles de ozono troposférico también disminuyeron.

Posteriormente, en abril de 2021, se registraron concentraciones de ozono con valores que oscilaron por debajo de las 30 partes por billón (ppb), a pesar de que aún persistían ciertas restricciones sanitarias. Con el retorno paulatino a la actividad social y económica bajo el

esquema de nueva normalidad en mayo de 2022, las concentraciones promedio mensuales de ozono alcanzaron los 41.21 ppb, lo que reflejó un repunte asociado al restablecimiento del tráfico vehicular y a la reactivación de las fuentes móviles y fijas de emisión, como se muestra en la figura 18.

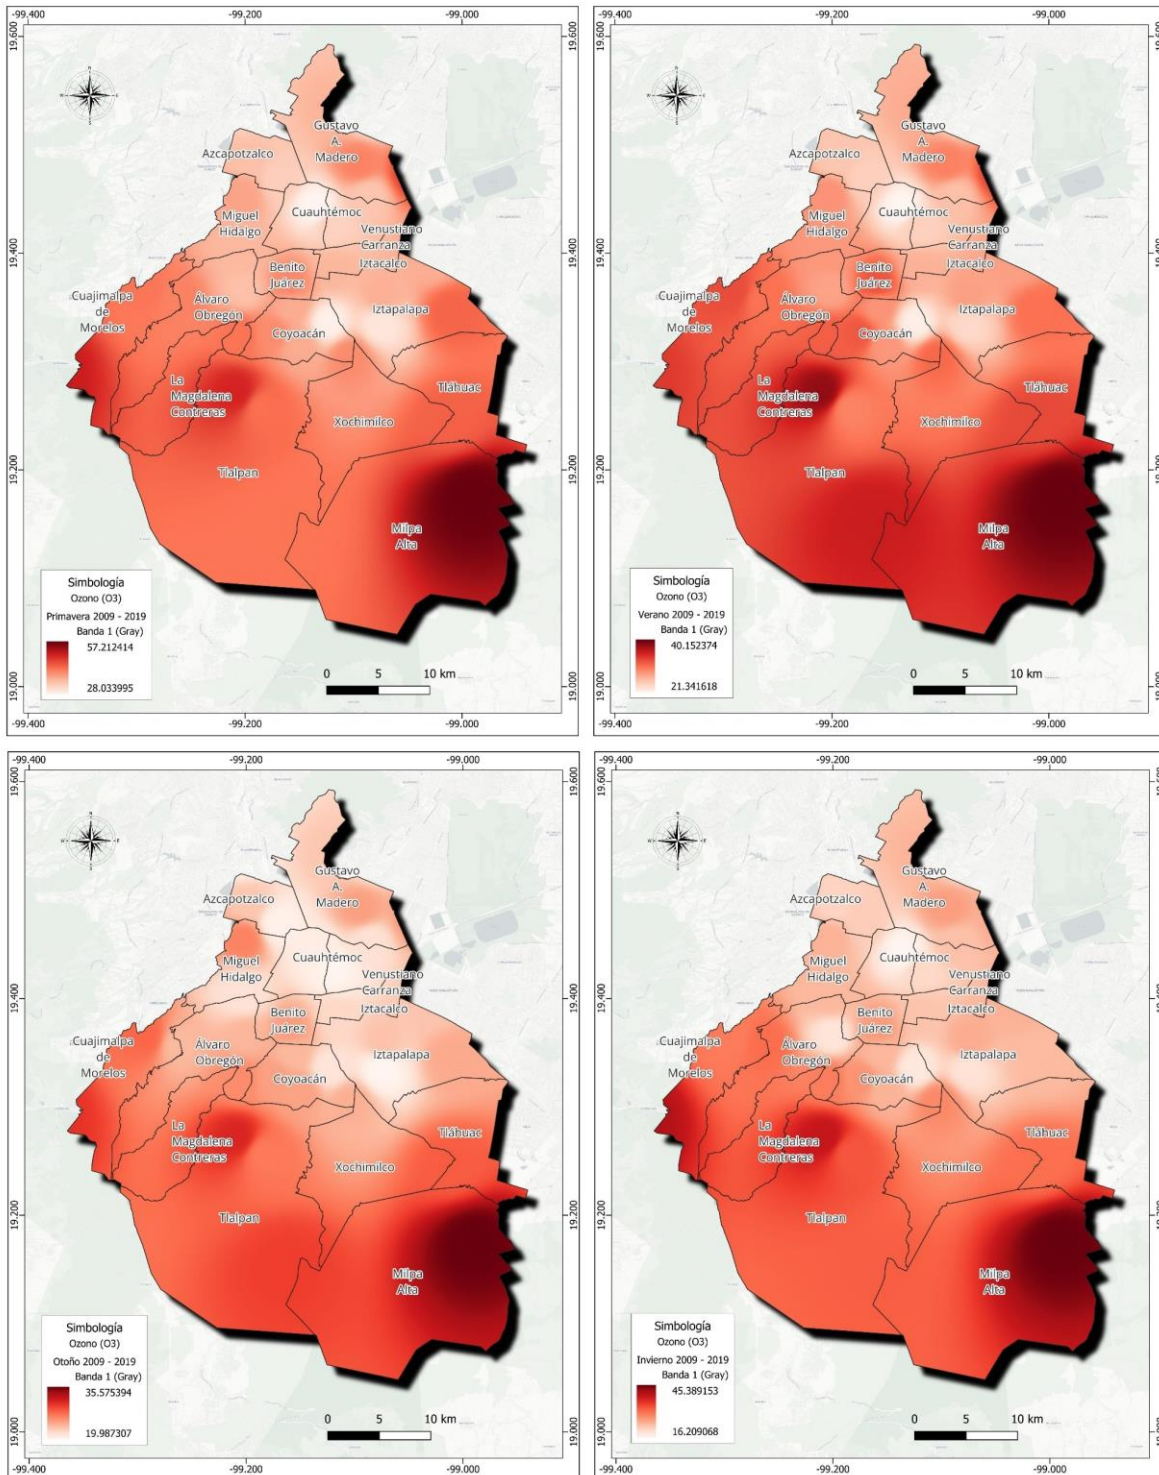
Figura 18 distribución de ozono en la Ciudad de México



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

En la Figura 19 se observa que las alcaldías Milpa Alta, Tlalpan, La Magdalena Contreras y Álvaro Obregón presentan las mayores concentraciones promedio de ozono (O_3) en todas las estaciones del año, siendo la primavera el periodo con los valores más elevados. Este patrón espacial indica que el sur y suroeste de la Ciudad de México concentra las zonas más afectadas por este contaminante, lo cual puede atribuirse a factores topográficos, condiciones de irradiación solar y escasa ventilación atmosférica que favorecen la acumulación de ozono troposférico.

Figura 19 Distribución promedio estacional de Ozono (O₃) entre 2009 y 2019



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

Se ha demostrado que solo se requiere de 1 día de exposición a altos niveles de contaminación por cada aumento de $10 \mu\text{g}/\text{m}^3$ por encima de lo que establece la OMS en NO_2 , $\text{PM}_{2.5}$ en un solo día, los ingresos hospitalarios por enfermedades respiratorias pueden aumentar de 6 a 9% en un día afectando el sistema respiratorio de forma aguda. Se observaron efectos retardados después de la exposición a altos niveles de contaminación que puede ser de 1 a 5 días después. La exposición acumulada en los siguientes días. En los meses de diciembre los niveles de contaminación llegan hasta $80 \mu\text{g}/\text{m}^3$ para $\text{PM}_{2.5}$ y PM_{10} , hasta 5 veces más que el límite de la OMS para $\text{PM}_{2.5}$ hasta casi 2 veces el límite para PM_{10} .

Según Mebrahtu et al., (2023), se identificó un retraso en la aparición de síntomas tras la exposición a contaminantes atmosféricos. En el caso del dióxido de nitrógeno (NO_2), las personas comenzaron a presentar afectaciones respiratorias aproximadamente 55 días después de la exposición; para $\text{PM}_{2.5}$, el efecto se manifestó en promedio a los 100 días, y en el caso de PM_{10} , a los 35 días. Además, por cada incremento de $10 \mu\text{g}/\text{m}^3$ por encima del umbral establecido por la OMS, el riesgo relativo de enfermarse se incrementa de manera significativa: 1.4 veces más con NO_2 (equivalente a un aumento del 49 %), 5.26 veces más con $\text{PM}_{2.5}$ (más del 400 %) y 2.32 veces más con PM_{10} (incremento del 132 %).

3.3.6 Partículas menores a $10 \mu\text{m}^3$ (PM_{10}) y Partículas menores a $2.5 \mu\text{m}^3$ ($\text{PM}_{2.5}$)

Durante el periodo observado, las concentraciones máximas mensuales de PM_{10} superaron de forma recurrente los $200 \mu\text{g}/\text{m}^3$, con picos que llegaron hasta $400 \mu\text{g}/\text{m}^3$ en los años 2010 y 2013. No obstante, aunque las concentraciones absolutas de $\text{PM}_{2.5}$ fueron menores, este contaminante implica un riesgo sanitario más elevado por su capacidad de penetrar en las vías respiratorias profundas y alcanzar el torrente sanguíneo.

Macintyre et al. (2016) y Mebrahtu et al. (2023) identificaron que una exposición a concentraciones de $\text{PM}_{2.5}$ que triplicaron los valores recomendados por la Organización Mundial de la Salud puede desencadenar efectos adversos significativos en la salud respiratoria. Esta condición se ha asociado con un aumento en la incidencia de enfermedades respiratorias infecciosas y, en escenarios de exposición prolongada incluso tan breves como diez días con un mayor riesgo de mortalidad prematura. Asimismo, estos niveles elevados de partículas finas contribuyen al incremento de los ingresos hospitalarios por causas respiratorias, particularmente entre las poblaciones más vulnerables.

De acuerdo con el análisis de exposición a contaminantes atmosféricos, los materiales particulados $PM_{2.5}$ y PM_{10} representaron los principales agentes de riesgo para la población de la Ciudad de México. Estos contaminantes mostraron niveles de concentración clasificados como altos y muy altos, según los estándares establecidos por la Organización Mundial de la Salud (OMS) en sus guías actualizadas de calidad del aire (2021).

EL material particulado fino ($PM_{2.5}$) registró una elevada frecuencia de exposición, alcanzando hasta 1,248 días por encima del umbral recomendado en la alcaldía Benito Juárez, que resultó ser la más afectada en la Ciudad de México.

Otras alcaldías presentaron también niveles altos de exposición a partículas finas $PM_{2.5}$, aunque con menor intensidad que Benito Juárez, se identificaron entre 951 y 997 días de exposición elevada a partículas finas $PM_{2.5}$ en diversas alcaldías de la Ciudad de México, entre ellas Milpa Alta, La Magdalena Contreras, Tlalpan, Azcapotzalco, Xochimilco y Miguel Hidalgo, como se ilustra en la figura 13. Esta exposición prolongada, registrada entre 2009 y 2019, implicó un riesgo sostenido para la salud respiratoria de la población. No obstante, sus efectos pueden variar en función de factores individuales, como los hábitos de vida y la acumulación de contaminantes en espacios interiores.

Dentro del rango de exposición muy alta a partículas finas $PM_{2.5}$, la alcaldía más afectada durante el periodo analizado fue Cuajimalpa, con un total de 1,120 días registrados por encima del umbral establecido por la OMS. Le siguieron Benito Juárez con 1,077 días, Álvaro Obregón con 1,032 y Tláhuac con 1,014 días. Esto evidencia una susceptibilidad estructural más profunda de la población frente a las consecuencias nocivas de la degradación atmosférica en contextos donde la exposición prolongada opera como una forma invisible de desigualdad en salud.

Previo a la pandemia el sistema respiratorio de la población ya experimentaba un deterioro progresivo, inducido por factores ambientales que trascienden fronteras territoriales, distinciones etarias, condiciones socioeconómicas o diferencias de género. La exposición continua a un ambiente contaminado generó un impacto silencioso y constante en la salud, evidenciando que la presencia en espacios urbanos afectados bastaba para comprometer, de forma paulatina, la función pulmonar.

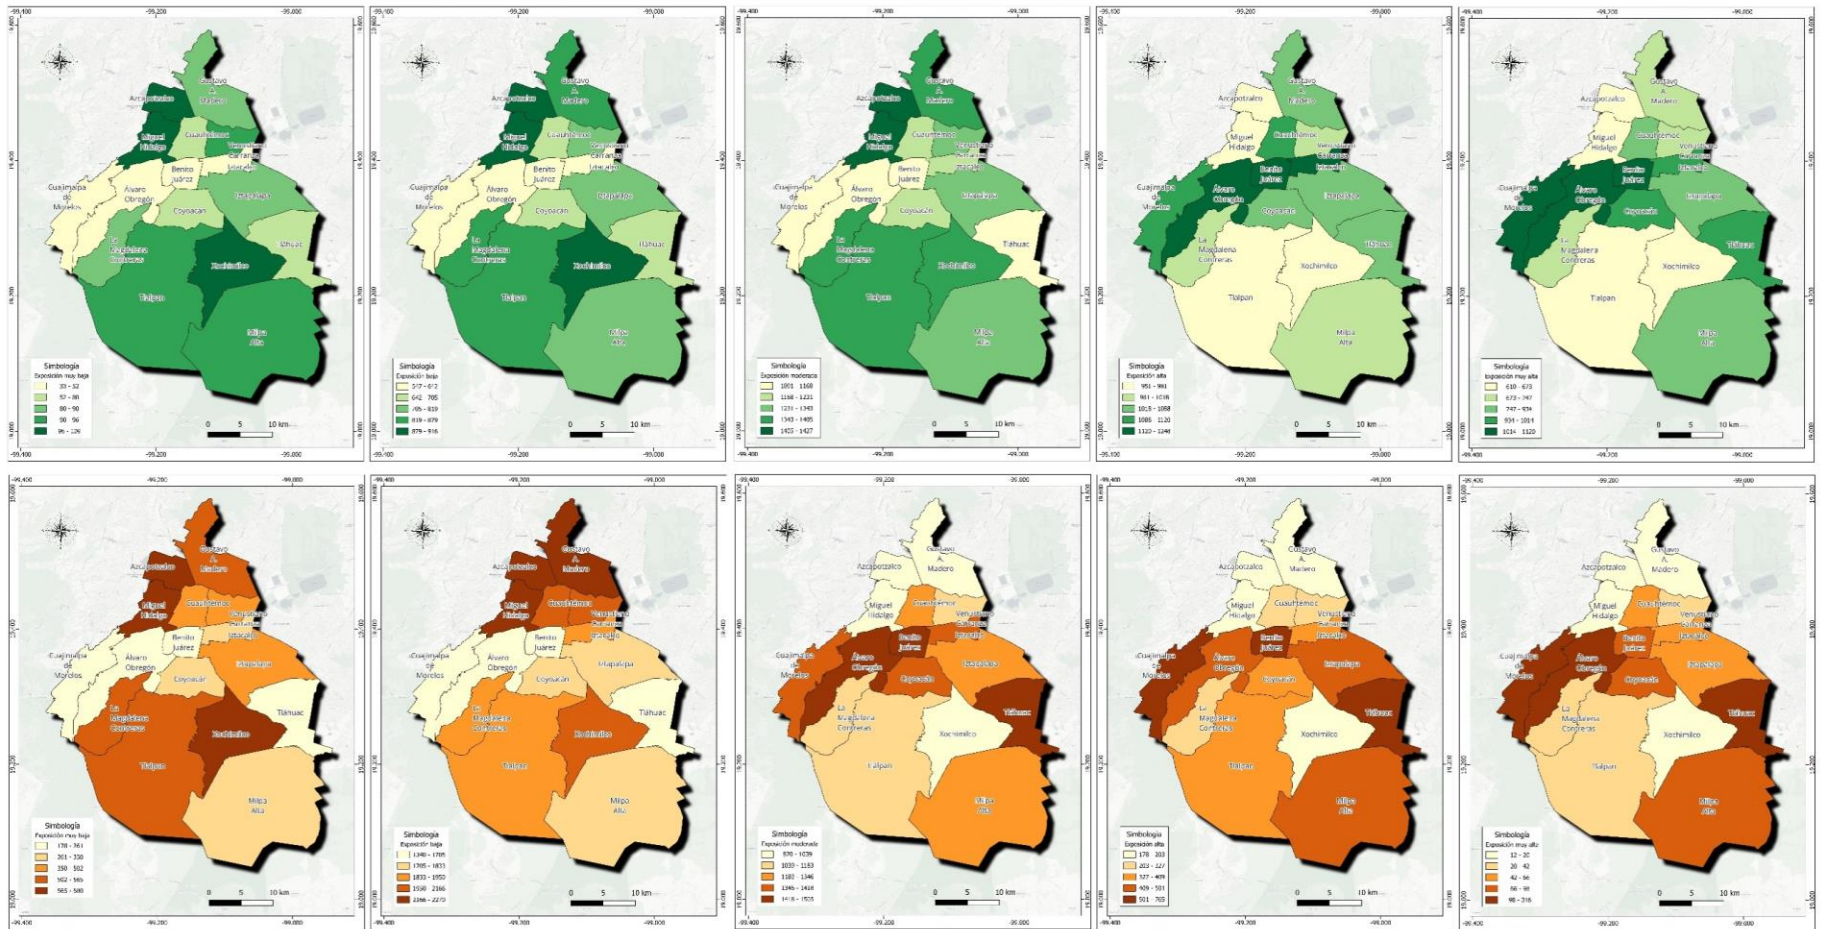
En la figura 20 se identificó una concentración constante de altos niveles de exposición a partículas de $PM_{2.5}$ en las alcaldías del poniente y sur de la Ciudad de México. Estas zonas registraron de forma sistemática un mayor número de días con concentraciones críticas, asociadas con su ubicación geográfica, características topográficas y circulación y dirección de los vientos desfavorable para la dispersión de contaminantes. En contraste, alcaldías como Álvaro Obregón, Benito Juárez y Miguel Hidalgo presentaron una frecuencia reducida de exposición, lo cual sugiere una diferenciación espacial en la carga de contaminantes finos.

A diferencia de la dinámica observada en la exposición a $PM_{2.5}$, las concentraciones muy altas de material particulado PM_{10} se registraron en menor medida a lo largo del periodo analizado. Las alcaldías que acumularon el mayor número de días de este umbral crítico fueron Cuajimalpa (316 días), Tláhuac (190 días) y Álvaro Obregón (115 días), lo que evidencia patrones específicos de acumulación asociados a su localización y dinámicas urbanas.

En el caso de Cuajimalpa, su exposición elevada a PM_{10} se asocia a su proximidad a la autopista México-Toluca, una de las principales arterias de transporte con alta densidad vehicular, particularmente de carga pesada. Además, esta zona alberga una concentración significativa de centros corporativos, lo que incrementa el flujo de automóviles privados y vehículos de servicio, generando una mayor emisión de material particulado en el entorno inmediato.

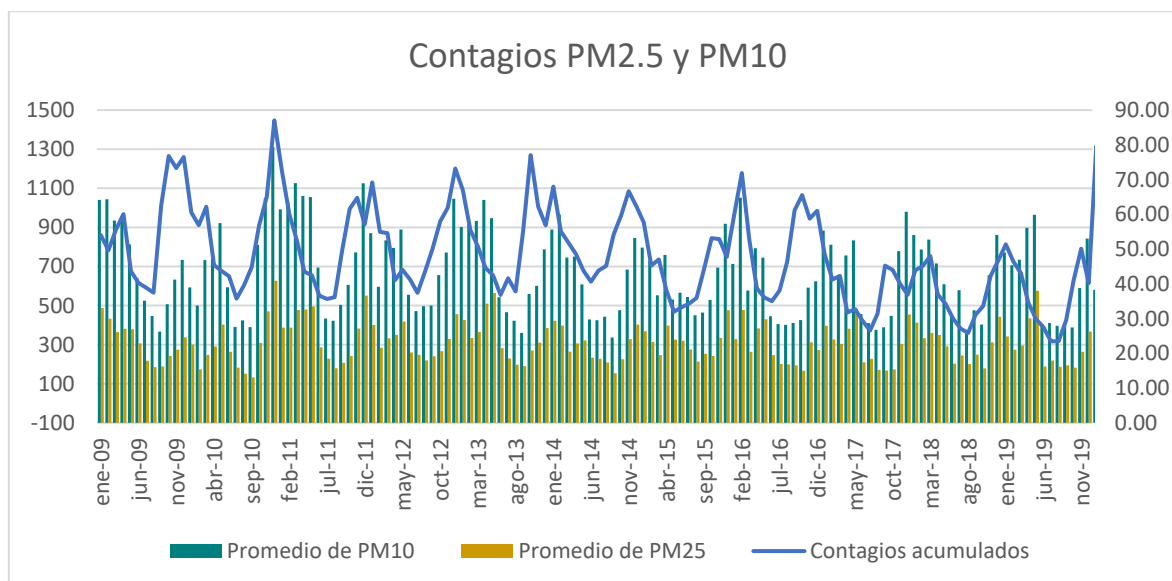
La concentración de PM_{10} en Tláhuac se asocia potencialmente con su ubicación geográfica, topografía, y dirección y velocidad del viento. Esta alcaldía se encuentra en una zona donde confluyen corrientes de aire provenientes del este y del norte, que facilitan la acumulación de contaminantes de PM_{10} .

Figura 20 Distribución espacial de días con exposición a PM_{2.5} y PM₁₀ en la Ciudad de México (2009–2019)



Fuente: Elaboración propia, 2025

Figura 21 Tendencias de PM_{2.5}, PM₁₀ y contagios respiratorios en la Ciudad de México (2009–2019)



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

Entre 2009 y 2019, la población de la Ciudad de México se mantuvo expuesta de forma continua a niveles elevados de contaminación atmosférica, en particular a concentraciones críticas de material particulado fino (PM_{2.5}) y grueso (PM₁₀). Esta exposición prolongada generó una condición de vulnerabilidad estructural que, al momento del surgimiento de la pandemia por COVID-19, ya había comprometido progresivamente la capacidad respiratoria de amplios sectores de la población. La degradación sostenida del sistema pulmonar, inducida por factores ambientales, contribuyó a una menor resiliencia inmunológica ante enfermedades respiratorias infecciosas, exacerbando los efectos del virus en un contexto urbano.

De acuerdo con (Bodor et al., 2022) las desigualdades en la calidad del aire urbano exponen de manera desproporcionada a ciertos sectores de la población a niveles elevados de contaminación, especialmente en áreas próximas a fuentes industriales. La exposición prolongada a material particulado representa un riesgo para la salud pública. Las partículas finas (PM_{2.5}), debido a sus propiedades fisicoquímicas, poseen la capacidad de atravesar las barreras respiratorias superiores, alcanzar los alvéolos pulmonares y desencadenar procesos inflamatorios que pueden evolucionar hacia enfermedades respiratorias tanto agudas como crónicas.

La evidencia indica que ciertas actividades industriales contribuyen de manera sustancial a las emisiones de PM_{2.5}. En particular, el sector de la ingeniería mecánica puede aportar hasta un 13 % del total de partículas finas en el ambiente, mientras que la industria metalúrgica ferrosa alcanza una contribución del 79 % y la no ferrosa hasta un 43 % (Krupnova et al., 2021). Estas emisiones se traducen en concentraciones de PM_{2.5} y PM₁₀ que frecuentemente superan los límites establecidos por las normas higiénicas en las áreas circundantes a complejos industriales, lo que intensifica la exposición de las poblaciones locales. Se ha demostrado que el PM_{2.5} tiene una toxicidad significativamente mayor en comparación con el PM₁₀, atribuible a su menor tamaño aerodinámico, mayor área superficial y capacidad de inducir inflamación y estrés oxidativo a nivel celular (Mebrahtu et al., 2023)


Durante la pandemia por COVID-19, las concentraciones mensuales promedio de material particulado fino (PM_{2.5}) y grueso (PM₁₀) mostraron una tendencia general a la disminución, manteniéndose, en su mayoría, por debajo de los 45 µg/m³, conforme a la métrica utilizada en la Red de Monitoreo Atmosférico de la Ciudad de México. Esta reducción puede atribuirse a las restricciones de movilidad, el cierre de actividades industriales y la disminución del tráfico vehicular durante los confinamientos.

Sin embargo, al analizar la evolución de los contagios por COVID-19 en el periodo 2020–2023, no se identificó una asociación directa entre los picos epidémicos y las variaciones mensuales de PM_{2.5} y PM₁₀. La dinámica del virus respondió con mayor fuerza a la circulación de variantes y la cobertura de vacunación. No obstante, se tiene el antecedente de exposición crónica a partículas finas en años previos a la pandemia (2009–2019) que debilitó progresivamente el sistema respiratorio de la población, generando una condición subyacente de vulnerabilidad que afectó a todos los grupos de edad y género.

En la figura 22 se observa que las distintas olas epidémicas marcadas por aumentos abruptos en los contagios acumulados no coinciden con los periodos de mayor concentración de PM_{2.5} y PM₁₀. Sin embargo, la población ya se encontraba en un estado de susceptibilidad respiratoria producto de una exposición prolongada a estos contaminantes en la década anterior. Las olas de contagio más pronunciadas, como las de diciembre de 2020, agosto de 2021 y enero de 2022, se produjeron durante periodos de estabilidad o descenso en los niveles de material particulado, lo que refuerza la hipótesis de una relación indirecta y acumulativa

entre contaminación atmosférica y gravedad de las enfermedades respiratorias durante eventos pandémicos.

Figura 22 Tendencias de PM_{2.5}, PM₁₀ y contagios por COVID-19 en la Ciudad de México (2020–2023)



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

3.3.7 Dióxido de azufre (SO₂)

El dióxido de azufre (SO₂) es un gas incoloro con un olor irritante que se forma principalmente durante la combustión de combustibles fósiles que contienen azufre. Este compuesto tiene dos fuentes principales: antropogénicas y naturales. Las emisiones antropogénicas provienen de la quema de combustibles fósiles, siendo una de las principales fuentes de emisión el Aeropuerto Internacional Benito Juárez, ubicado en la alcaldía Venustiano Carranza de la Ciudad de México (SEDEMA, 2014). Por otro lado, las fuentes naturales incluyen las emisiones volcánicas y los incendios forestales (SEDEMA, 2016).

En la zona norte de la Ciudad de México, las concentraciones de dióxido de azufre (SO₂) se ven influenciadas por fuentes regionales externas, particularmente por el corredor industrial Tula-Tepeji, ubicado en el estado de Hidalgo. Esta zona concentra diversas instalaciones energéticas e industriales que emiten grandes volúmenes de contaminantes atmosféricos. De acuerdo con SEDEMA (2022), las emisiones de SO₂ provenientes de este corredor son transportadas hacia la Ciudad de México mediante vientos dominantes del

noreste, fenómeno especialmente notorio durante las noches y madrugadas, cuando las condiciones atmosféricas favorecen la acumulación y el desplazamiento de contaminantes hacia el valle.

Durante el año 2015, se documentaron niveles particularmente elevados de SO₂ en los meses de noviembre y diciembre, con concentraciones que superaron los 200 ppb, principalmente durante el horario nocturno (SEDEMA, 2016). Estos episodios evidencian el papel de las fuentes regionales y las dinámicas atmosféricas en la configuración espacial y temporal de la calidad del aire en la Ciudad de México.

La Sierra de Guadalupe, localizada al norte de la Ciudad de México, funciona como una barrera orográfica que limita el libre desplazamiento de las masas de aire provenientes del sur del estado de Hidalgo. Esta configuración topográfica incide en las emisiones de dióxido de azufre (SO₂) a que se desvíen hacia los municipios de Tlalnepantla y Ecatepec, desde donde el contaminante puede avanzar hacia el centro y sur de la capital, dispersándose gradualmente en el trayecto (SEDEMA, 2016). Como resultado de esta dinámica, las zonas del noroeste de la ciudad presentan los valores promedio anuales más elevados de SO₂, mientras que las concentraciones disminuyen de forma progresiva hacia el sureste (SEDEMA, 2014).


Durante noviembre de 2015, se registró el valor máximo puntual de concentración de SO₂, alcanzando los 200 ppb, con mayor incidencia en horarios nocturnos y de madrugada (SEDEMA, 2016). Además, datos correspondientes al año 2013 revelan que los viernes fueron los días con mayor frecuencia de episodios críticos de concentración, lo cual podría relacionarse con patrones de movilidad de *commuters* y actividad industrial.

El análisis de la serie temporal mostró que los niveles más altos de SO₂ se concentraron en los meses invernales, seguidos por una disminución marcada durante el verano y un posterior repunte en octubre y noviembre. Esta dinámica indica una clara variabilidad estacional, modulada por condiciones meteorológicas como la estabilidad atmosférica y la temperatura, así como por el incremento de actividades humanas durante el último trimestre del año.

Se observa una marcada variabilidad en las concentraciones de SO₂, con picos recurrentes que superan los 6 ppb, y que alcanzan valores cercanos a los 10 ppb en episodios críticos, como los registrados entre finales de 2010, principios de 2011, así como en los inviernos de 2013, 2016 y 2019, como se muestra en la figura 23.

En relación con los contagios acumulados no se observa una correlación lineal directa entre los picos de SO₂ y los picos de contagios, se identifican algunos momentos donde los aumentos en la concentración de este gas coinciden con repuntes en los casos reportados. Esto se asocia con una posible relación de tipo retardada o acumulativa, donde la exposición continua al contaminante podría debilitar progresivamente el sistema respiratorio y predisponer a la población a infecciones respiratorias, tal como ha sido planteado en la literatura científica (Macintyre et al., 2016; Mebrahtu et al., 2023)

Figura 23 Contagios de enfermedades respiratorias infecciosas y dióxido de azufre (SO₂) (2009-2019)



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

El análisis de la serie temporal de dióxido de azufre (SO₂) en la Ciudad de México, entre 2009 y 2019, permitió identificar patrones espaciales y temporales diferenciados. La alcaldía Azcapotzalco presentó los valores más altos, con un pico crítico el 1 de diciembre de 2010, fecha en la que se alcanzó un promedio diario de 6.5 unidades y un valor máximo puntual de 55.05 unidades. Este episodio refleja una acumulación atípica de contaminantes

atribuida a la alta densidad industrial y a condiciones meteorológicas específicas, como la dirección del viento, que favorecen la concentración en esta zona.

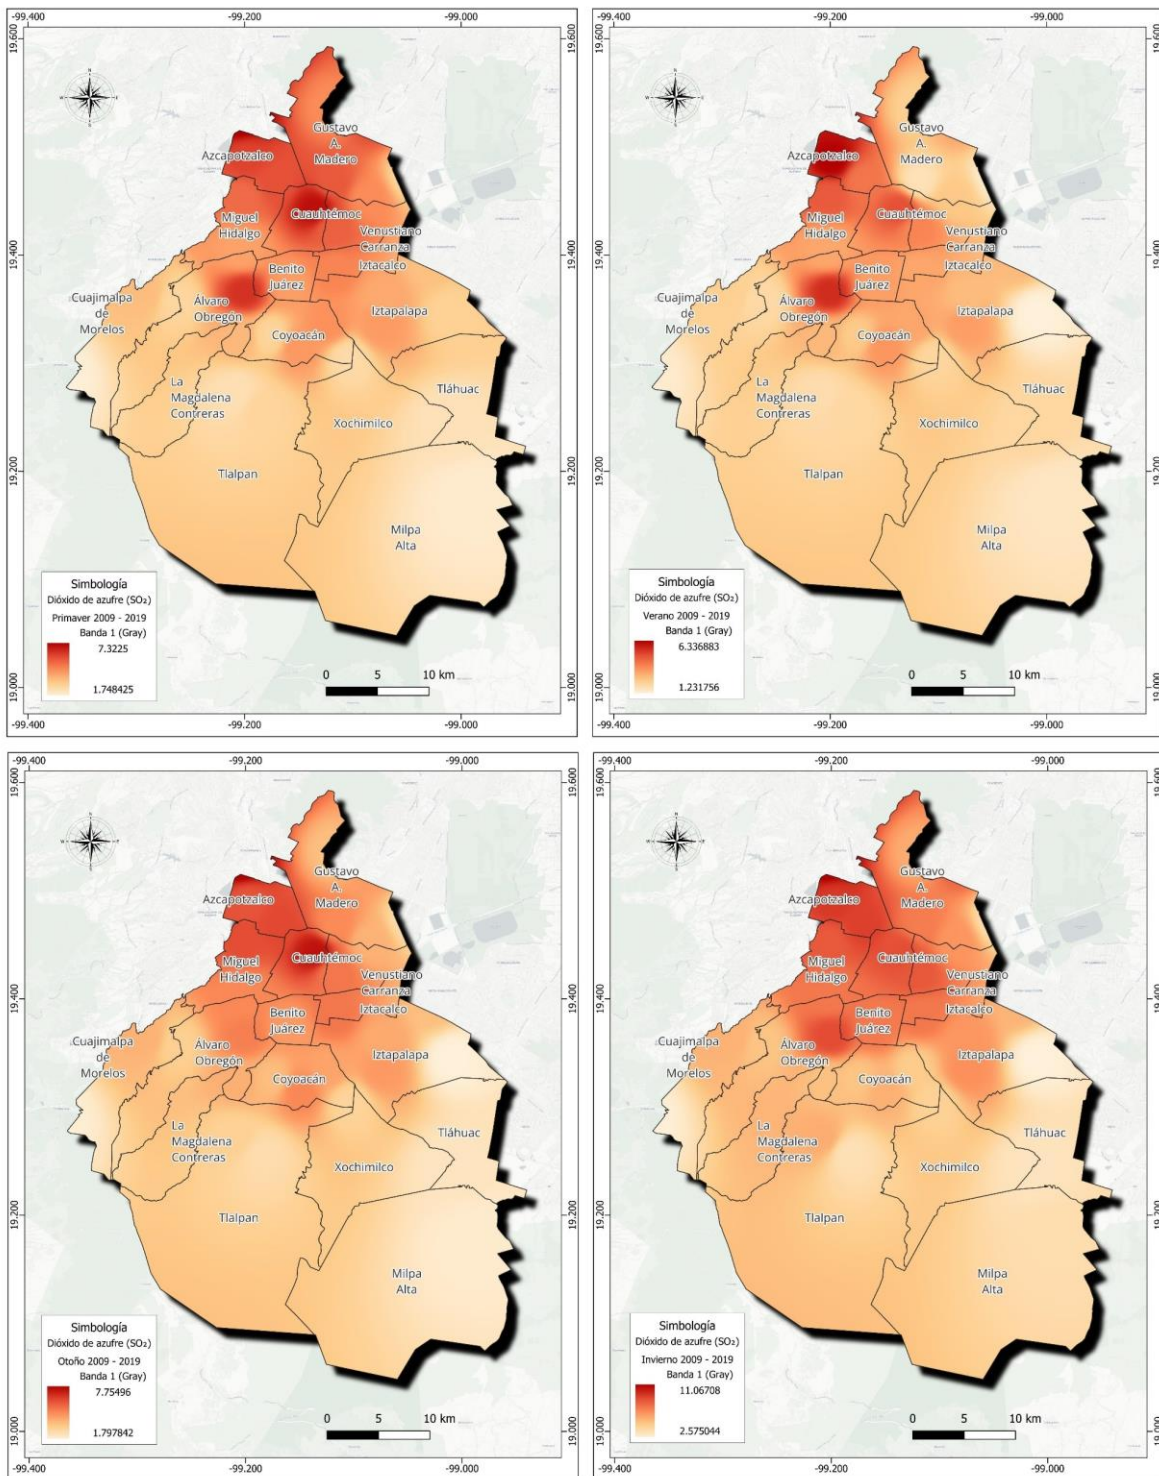
La alcaldía Cuauhtémoc registró un promedio de 5.75 unidades, destacando un máximo puntual el 8 de enero de 2017, vinculado a fenómenos de inversión térmica y movilidad vehicular intensa en el centro urbano. La alcaldía, Miguel Hidalgo ocupó el tercer lugar con un promedio de 5.65 unidades, alcanzando su máximo el 1 de diciembre de 2010, coincidiendo con el evento registrado en Azcapotzalco. Estas dinámicas evidencian la interacción entre fuentes fijas (industriales), condiciones atmosféricas y características morfológicas urbanas, subrayando la necesidad de estrategias diferenciadas de monitoreo y mitigación para cada alcaldía.

Diversos estudios han evidenciado los efectos adversos del dióxido de azufre (SO_2) sobre la salud respiratoria, tanto en exposiciones agudas como crónicas. De acuerdo con concentraciones de SO_2 en el rango de 4.1 a 8.5 ppb se han asociado con una mayor prevalencia de rinitis alérgica en población infantil, especialmente en niños en edad escolar, los niveles considerados moderados podrían desencadenar respuestas inmunológicas e inflamatorias en grupos sensibles (Kim et al., 2021)

Nurhisana & Hasyim (2022) señalan que la exposición a corto plazo al SO_2 incrementa la morbilidad respiratoria en adultos como en niños, con mayor impacto en personas con asma o en adultos mayores, quienes presentan menor capacidad pulmonar y mayor susceptibilidad a agentes irritantes. La exposición a este gas puede causar una amplia gama de efectos adversos, que van desde irritación ocular, nasal y faríngea, hasta edema pulmonar y, en casos extremos, la muerte. También el SO_2 puede reducir de forma significativa la función pulmonar, provocando tos persistente, disnea y exacerbación de cuadros asmáticos.

De acuerdo con Daud (2013, citado por Nurhisana & Hasyim (2022), los residentes que habitan en un radio de 300 metros respecto a zonas industriales presentan entre 1.37 y 1.62 veces más riesgo de reducción en la función pulmonar.

Figura 24 Distribución promedio estacional de Dióxido de azufre (SO₂) entre 2009 y 2019

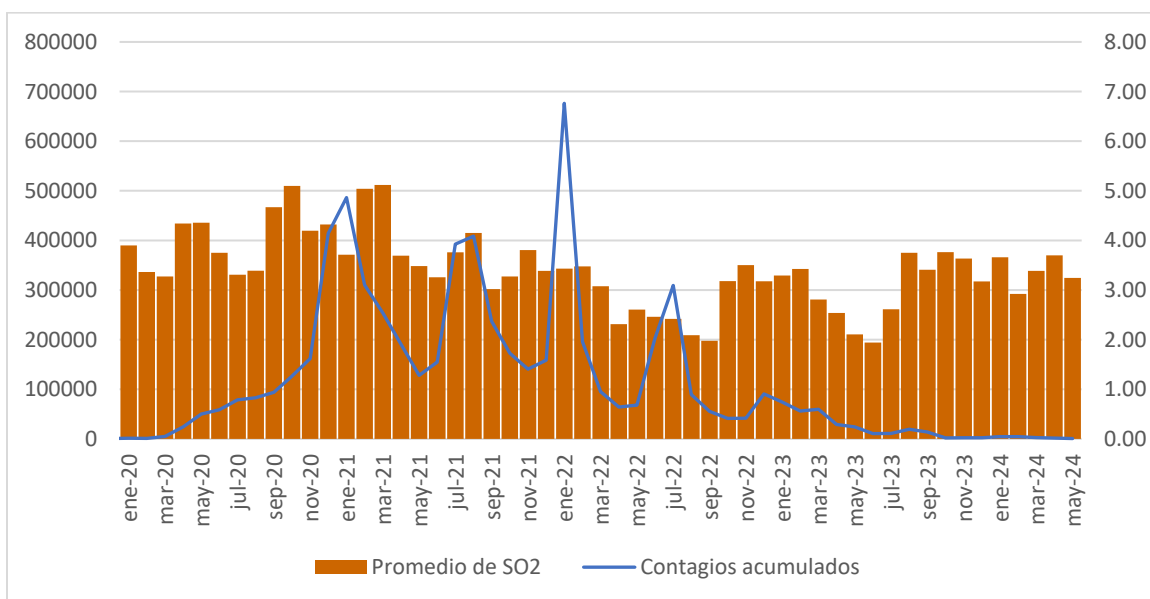


Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

Durante este periodo de pandemia, las concentraciones promedio mensuales de SO₂ se mantuvieron en un rango moderado, oscilando principalmente entre 2.5 y 4.5 ppb, sin alcanzar los valores críticos registrados en años previos. Esta estabilización se atribuye a la disminución de actividades industriales y de transporte durante las fases más estrictas de confinamiento sanitario.

La figura 25 muestra que, aunque el dióxido de azufre (SO₂) no presentó una relación directa e inmediata con los picos epidémicos de COVID-19. La presencia constante de SO₂ en un entorno urbano caracterizado por la exposición crónica a contaminantes atmosféricos, habría contribuido a agravar la vulnerabilidad respiratoria de la población. En este sentido, es posible que los efectos acumulativos del SO₂ hayan actuado como un condicionante subyacente, predisponiendo a la población a una mayor severidad en los cuadros clínicos durante las distintas fases de la pandemia, especialmente entre aquellos sectores previamente afectados por la degradación ambiental prolongada.

Figura 25 Contagios de COVID-19 y acumulación media mensual de SO₂ (2020-2023)



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

3.3.8 Monóxido de carbono (CO)

El monóxido de carbono (CO) es un gas inodoro, insípido, incoloro y venenoso producido por la combustión incompleta de compuestos orgánicos, La exposición a altas cantidades de CO puede resultar en hipoxia y producir una serie de efectos adversos para la

salud, como dolores de cabeza, náuseas, fatiga, disfunción respiratoria, daño tisular e incluso la muerte Una de las fuentes comunes de exposición a CO es el tabaquismo


Es la principal fuente de exposición al CO. Para los fumadores, fumar expone a las personas a una alta concentración de CO En el informe de la OMS, la concentración de CO en el humo del tabaco es de alrededor del 4,5% (45.000 ppm), y los fumadores inhalan aire con una concentración de alrededor de 400–500 ppm de CO durante el tabaquismo

El CO exógeno se encuentra a través de la exposición ambiental incidental, generalmente por la inhalación y el humo del cigarrillo que presenta una fuente importante de exposición al CO en humanos son un indicador de un marcador de estrés oxidativo junto con el NO. Se respira involuntariamente al estar expuestos a gases de escape de vehículos. Quema de combustibles fósiles, madera, fuga de estufas, calentadores mal ventilados, humo del tabaco, incendios y contaminación industrial.

Entra al cuerpo humano por medio de la inhalación de aire contaminado, una vez que llega a los pulmones pasa por el torrente sanguíneo, donde se une a la hemoglobina forma carboxihemoglobina, que bloquea el transporte del oxígeno, provoca hipoxia (falta de oxígeno en los tejidos). Lo que afecta el funcionamiento normal de órganos vitales, debido a que impide la oxigenación del cuerpo, el CO exógeno daña principalmente los pulmones generando estrés oxidativo, inflamación y dificultad respiratoria, el cerebro ocasionando dolores de cabeza, confusión, mareos, pérdida de conciencia; daña el corazón donde genera síntomas como arritmias y riesgo inflamatorio, también genera daños en el sistema nervioso central presentando daño cognitivo, alteración de funciones motoras y memoria.

En la Figura 26 se observa una relación variable entre los niveles promedio mensuales de monóxido de carbono (CO) y los contagios acumulados por enfermedades respiratorias infecciosas en el periodo previo a la pandemia. Entre 2009 y 2016, se identifican varios picos en la concentración de CO, particularmente en los años 2011, 2013 y 2016, los cuales coinciden con aumentos relevantes en el número de contagios. Aunque la asociación no es lineal ni inmediata, el comportamiento conjunto de ambas variables sugiere que los periodos de mayor concentración de CO precedieron temporalmente varios repuntes en la incidencia de enfermedad respiratoria. A partir de 2017, ambas tendencias muestran una disminución progresiva, destacando niveles relativamente bajos en 2018 y 2019.


Figura 26 Contagios de enfermedades respiratorias y monóxido de carbono (2009-2019)



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

La Figura 27 ilustra la dinámica entre las concentraciones promedio mensuales de monóxido de carbono (CO) y los contagios acumulados por COVID-19 en el periodo comprendido entre enero de 2020 y mayo de 2024. Durante esta etapa, caracterizada por una alta volatilidad epidemiológica, se identifican fluctuaciones marcadas en los niveles de contagio, sin que estas respondan de manera inmediata a variaciones en las concentraciones de CO, las cuales se mantienen dentro de un umbral elevado y relativamente constante. Este comportamiento sugiere que el CO no actúa como un desencadenante directo de los brotes epidémicos, pero sí puede desempeñar un papel como condicionante ambiental estructural, al configurar un entorno de exposición crónica que compromete la función respiratoria y reduce la resiliencia inmunológica de la población

Figura 27 Contagios de COVOD y monóxido de carbono (CO) (2020-2023)



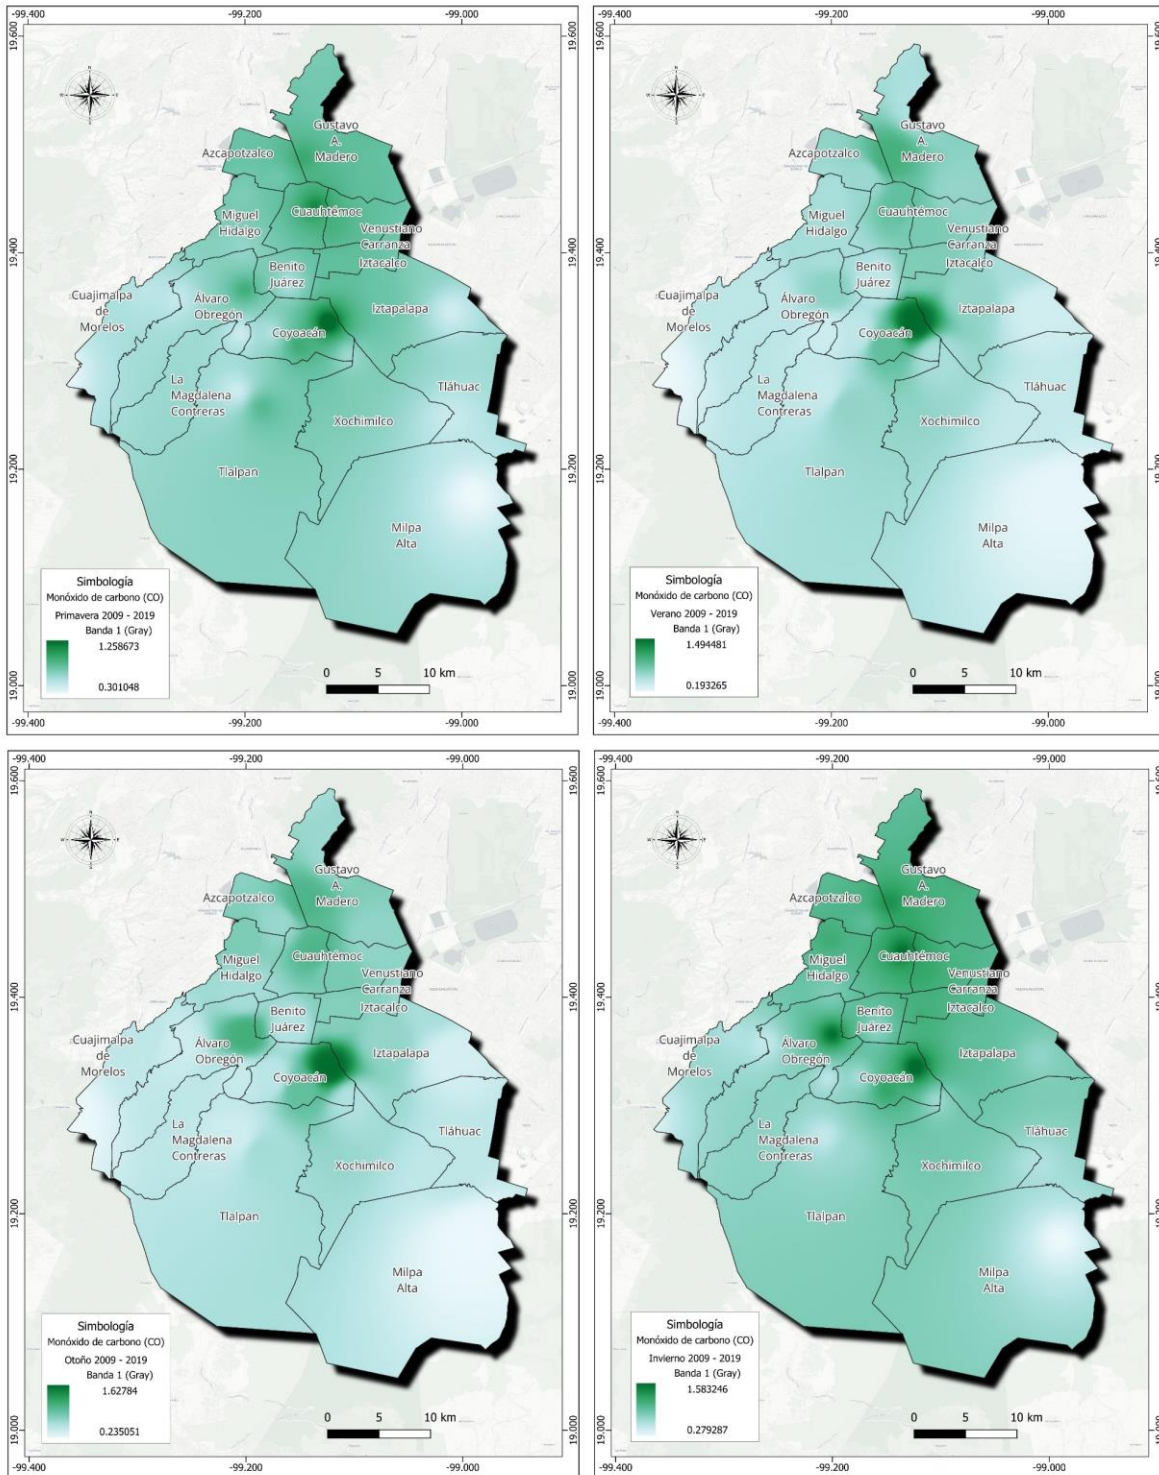
Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

En la figura 28 se muestra que el monóxido de carbono (CO) en la Ciudad de México entre 2009 y 2019 revela patrones de acumulación en el centro-norte de la ciudad. Se observa una distribución heterogénea con predominio de niveles elevados en las alcaldías de Gustavo A. Madero, Venustiano Carranza, Cuauhtémoc y sectores de Azcapotzalco.

Esta concentración coincide con zonas caracterizadas por alta densidad poblacional, intensa circulación vehicular, infraestructura industrial y menor cobertura vegetal, condiciones que favorecen tanto la emisión como la retención del CO en el ambiente urbano. El patrón norte-sur revela una distribución espacial decreciente, donde las alcaldías del sur Tlalpan, Milpa Alta, Xochimilco y partes de La Magdalena Contreras registran sistemáticamente las concentraciones más bajas, atribuibles a su altitud, vegetación densa y menor actividad industrial.

La distribución identificada permite inferir una relación estructural entre la concentración de CO y las condiciones territoriales, en zonas de tránsito denso, urbanización acelerada y baja ventilación atmosférica. El monóxido de carbono actúa como un marcador geográfico de desigualdad ambiental, reflejando la vulnerabilidad acumulada de ciertos sectores urbanos frente a la exposición crónica a contaminantes nocivos.

Figura 28 Distribución promedio estacional de Monóxido de carbono (CO) entre 2009 y 2019



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

3.3.9 Óxido de nitrógeno (NO_x)


Los óxidos de nitrógeno (NO_x), compuestos por óxido nítrico (NO) y dióxido de nitrógeno (NO₂), se generan principalmente por la quema de combustibles fósiles en vehículos, centrales eléctricas e industrias, aunque también provienen de fuentes residenciales, particularmente en interiores mal ventilados donde se utilizan estufas o calentadores de gas (Environmental Protection Agency, 2025). El NO se oxida rápidamente en la atmósfera para formar NO₂, un gas de color marrón amarillento, ácido y altamente corrosivo, que participa en la formación del smog fotoquímico y afecta directamente la salud respiratoria.

La exposición a NO₂ se ha asociado con irritación de las vías respiratorias, exacerbación del asma y aumento de hospitalizaciones por enfermedades respiratorias, especialmente en niños, adultos mayores y personas con comorbilidades pulmonares (EPA, 2025). Estudios recientes también han relacionado su presencia con mayor mortalidad en pacientes con fibrosis pulmonar idiopática (Ko & Kyung, 2022).

En zonas urbanas, el transporte motorizado representa la principal fuente de emisión de NO_x, seguido por actividades industriales y energéticas, como la quema de biomasa (Awez et al., 2024). Estas emisiones agravan la vulnerabilidad respiratoria de la población, particularmente en áreas densamente pobladas y con deficiente calidad del aire.

En la figura 29 se observa una coincidencia temporal entre los aumentos en las concentraciones mensuales de NO_x y los picos en los contagios acumulados por enfermedades respiratorias infecciosas (ERI). Esta relación indica una asociación significativa entre la exposición ambiental a óxidos de nitrógeno y la incidencia de infecciones respiratorias, especialmente en periodos invernales, cuando la estabilidad atmosférica favorece la acumulación de contaminantes. Durante este periodo, la población más afectada fue la integrada por niñas, niños y personas adultas mayores, grupos con mayor vulnerabilidad inmunológica ante la exposición a gases irritantes como el NO₂.

Figura 29 Contagios por enfermedades respiratorias infecciosas (ERI) y concentraciones promedio de óxidos de nitrógeno (NO_x) en la Ciudad de México, 2009–2019




Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

La figura 30, que abarca el periodo 2020–2023, muestra una ruptura en la relación que se presentó previo a la pandemia. Durante la pandemia los contagios respondieron a una lógica epidemiológica distinta, asociada a la transmisión viral comunitaria y medidas sanitarias. A pesar de que los niveles de NO_x se mantuvieron relativamente estables, los picos de contagios no coincidieron con incrementos en las concentraciones de este contaminante. Estos resultados indican que, durante la pandemia, el NO_x no tuvo un papel determinante en la dinámica de los contagios, aunque no puede descartarse su efecto acumulativo como factor de riesgo preexistente.

En el periodo pre-pandémico, existió una asociación clara entre la exposición a NO_x y la incidencia de ERI, en población infantil y adulta mayor. Sin embargo, esta relación se cambió durante la pandemia, cuando las dinámicas de transmisión viral y las condiciones sociales del contagio adquirieron mayor peso que los factores ambientales inmediatos.

Esta diferencia no implica una ausencia de relación, sino más bien una temporalidad distinta en los efectos. La población ya se encontraba en condiciones de vulnerabilidad respiratoria, producto de una exposición prolongada y crónica a contaminantes como el NO₂ en años anteriores. Es decir, los daños derivados de la contaminación atmosférica no operan de forma inmediata, sino que se acumulan con el tiempo y deterioran progresivamente la función pulmonar. En este contexto, la pandemia encontró a una población con su salud respiratoria ya comprometida, lo que pudo amplificar la severidad clínica de los contagios, particularmente en los sectores históricamente más expuestos.

Figura 30 Contagios por COVID-19 y concentraciones mensuales promedio de óxidos de nitrógeno (NO_x) en la Ciudad de México, 2020–2023

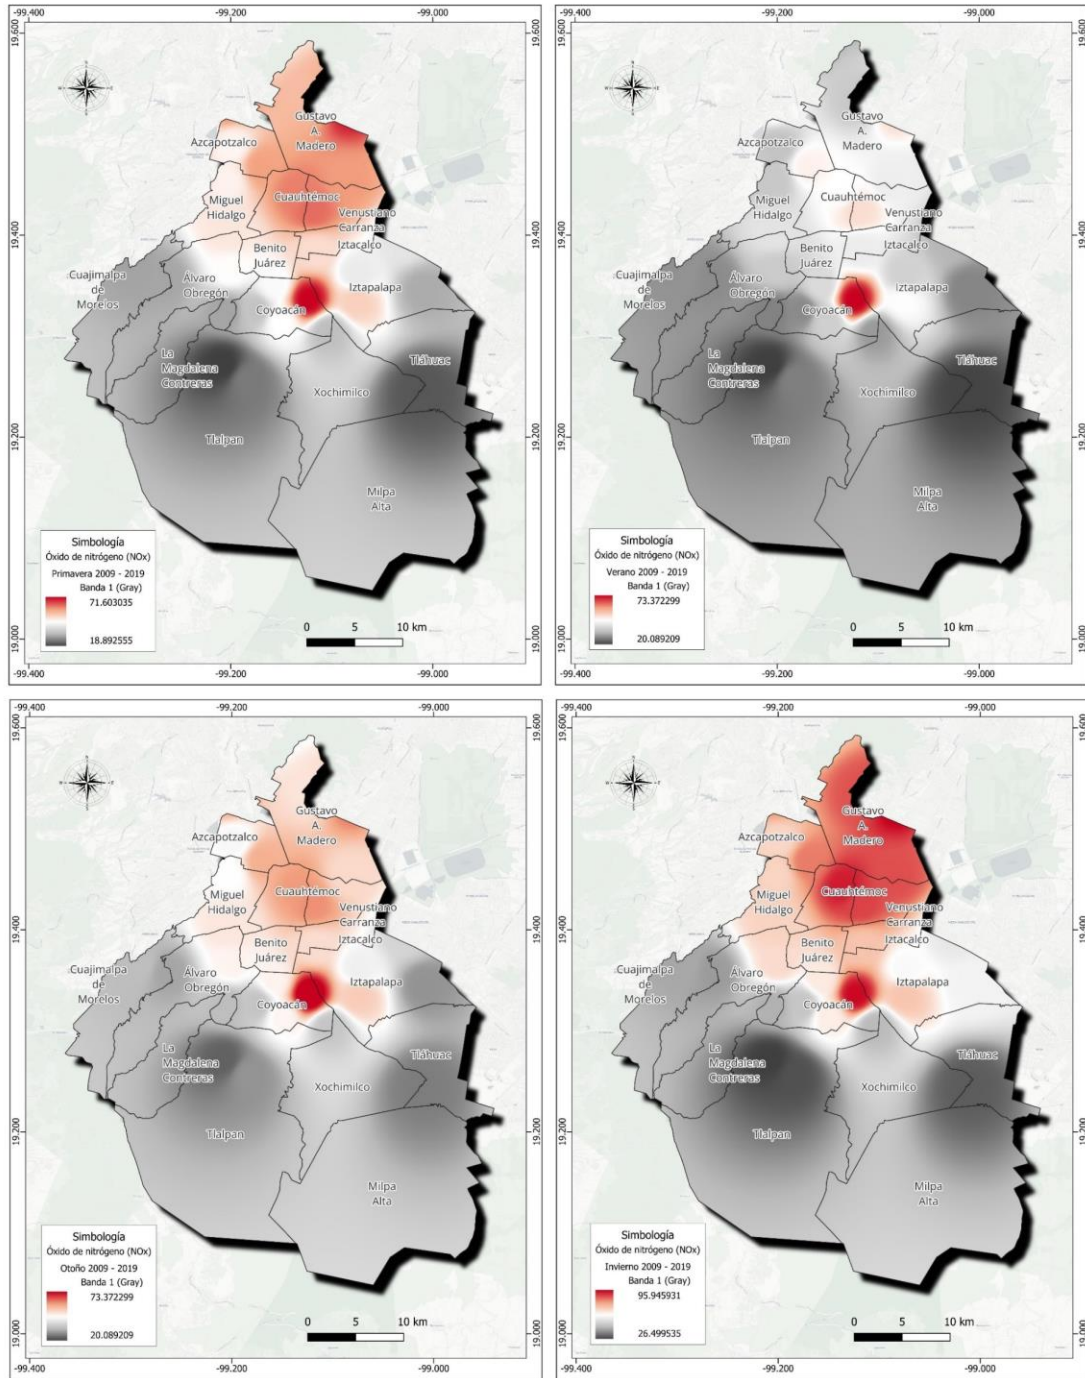


Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

La Figura 31 evidencia una alta concentración estacional de NO₂ en las alcalcías Cuauhtémoc, Gustavo A. Madero y Venustiano Carranza. Estas zonas centro-norte superan los 95 µg/m³ en invierno, asociadas con alta densidad urbana y limitada dispersión atmosférica. En contraste, el sur y poniente registran niveles bajos por su altitud y ventilación.

El patrón se mantiene estable en todas las estaciones. Esta distribución revela una exposición crónica diferenciada que actúa como condicionante estructural de riesgo respiratorio.

Figura 31 Distribución promedio estacional de Óxido de nitrógeno (NOx) (2009 y 2019)



Fuente: Elaboración propia con base en datos de la Red de Monitoreo Atmosférico de la Ciudad de México

3.4 Condiciones sociales

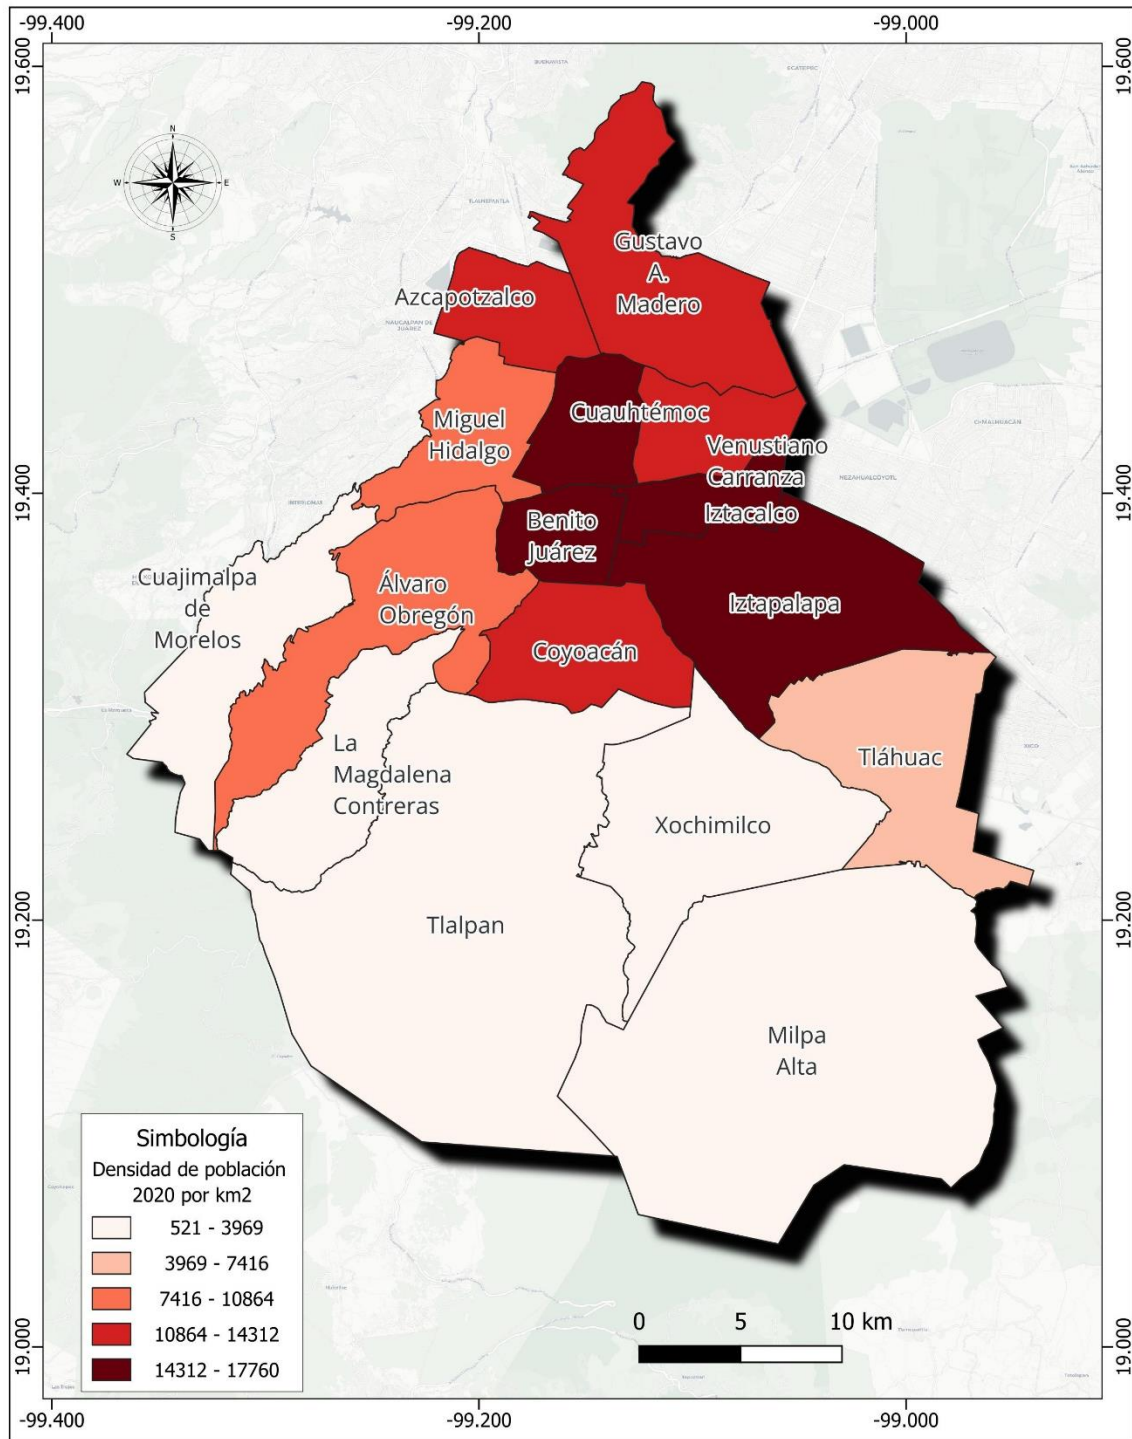
3.4.1 Densidad de población

En 2020, la Ciudad de México se posicionó como la segunda entidad con mayor población a nivel nacional. De acuerdo con el cálculo de densidad poblacional de ese año, la alcaldía Iztacalco destaca con la mayor densidad, alcanzando 17,7559 habitantes por kilómetro cuadrado (Hab./Km²). Le siguen la alcaldía Cuauhtémoc y Benito Juárez, con densidades de 16,998 y 16,482 Hab./Km², respectivamente. En cuarto lugar, se encuentra Iztapalapa, con 16,406 Hab./Km².

Esta alta densidad poblacional se debe a que la región centro de la Ciudad de México fue una de las primeras en ser habitada y desarrollada (Luna-Vargas, 2022). A lo largo del tiempo, la centralización de las actividades económicas y el incremento de la demanda del sector terciario han contribuido a una urbanización potencial en estas delegaciones, lo que ha incrementado la concentración de persona y la demanda de servicios e infraestructura.

Por otra parte, las alcaldías ubicadas al sur de la ciudad presentan densidades de población significativamente menores. Milpa Alta, es la segunda alcaldía con mayor superficie cuenta con una densidad de 520 Hab./Km². Tlalpan, la alcaldía con mayor extensión territorial, tiene una densidad de 2,255 Hab./Km². Estas zonas, caracterizan por estar situadas en terrenos abruptos y extensas áreas naturales protegidas que limitan el crecimiento urbano acelerado. Además, estas alcaldías concentran localidades rurales, lo cual contribuye a una densidad poblacional más baja y dispersa en comparación con el área central de la ciudad.

Figura 32 Densidad de población 2020 ((Hab./Km²), por alcaldía de la Ciudad de México



Fuente: Elaboración propia con base en datos del Consejo Nacional de Población (2024)

3.4.2 Uso de suelo

El uso de suelo en la Ciudad de México permitió la identificación de condiciones espaciales que potencialmente facilitaron o mitigaron la propagación del COVID-19. La estructura urbana, expresada en la distribución del uso del suelo, el número de niveles constructivos y la superficie promedio por predio, desempeñó un papel determinante en la exposición diferencial de la población al virus y en la capacidad de contención territorial.

El 30% de las alcaldías de la Ciudad de México prevalece el uso de suelo habitacional como categoría dominante, con excepción de alcaldías como Gustavo A. Madero, Álvaro Obregón y Venustiano Carranza, donde se registró una alta proporción de uso habitacional con comercio en planta baja. Este tipo de uso mixto, caracterizado por una mayor interacción social en espacios semiprivados, implicó una mayor exposición al contagio en periodos de alta transmisión.

Los niveles constructivos promedio se ubicaron entre 2.3 y 3.8 pisos. Cuauhtémoc y Miguel Hidalgo registraron los valores más elevados, alcanzando hasta 22 niveles en algunos predios, lo cual indica una concentración vertical de habitantes y actividades económicas.

Las alcaldías con menores superficies promedio por predio, como Iztapalapa (150.9 m²), Gustavo A. Madero (195.8 m²) e Iztacalco (219.5 m²), enfrentaron mayores desafíos para el distanciamiento físico al interior de las viviendas. Estas dimensiones limitadas favorecieron condiciones de hacinamiento, especialmente en zonas donde convergieron altos niveles de ocupación residencial y comercio informal.

En las alcaldías como Milpa Alta, Tlalpan y Xochimilco se identificaron predios con mayores extensiones, con promedios que superaron los 300 m², e incluso alcanzaron los 2,137.2 m² en Milpa Alta. Estas dimensiones, asociadas a usos de preservación ecológica y rural agroindustrial, con una menor exposición al contagio debido a la baja densidad construida y a la relativa autosuficiencia alimentaria de estos territorios.

La superficie total destinada a preservación ecológica principalmente se identificó en Tlalpan (163.4 km²) y Milpa Alta (187.4 km²). Estas áreas funcionaron como amortiguadores ecológicos, y como zonas de bajo riesgo sanitario durante la emergencia.

El contraste entre alcaldías periféricas con usos rurales extensivos y zonas centrales densamente urbanizadas evidencia una marcada heterogeneidad socioespacial. Mientras Milpa Alta, Tláhuac y Xochimilco se distinguieron por su baja densidad y gran cobertura de suelo, demarcaciones como Cuauhtémoc, Benito Juárez y Iztapalapa condensaron población, comercio, y servicios en áreas reducidas. Esta divergencia generó una distribución desigual de los riesgos y de la capacidad de respuesta sanitaria frente a la pandemia.

La Ciudad de México concentra una elevada diversidad y densidad de usos de suelo en un territorio profundamente desigual, donde el entrelazamiento funcional entre vivienda, comercio, industria y servicios se desarrolla en condiciones de saturación física. Esta hiperconcentración territorial, lejos de constituir una fortaleza, operó como un catalizador de la crisis sanitaria, al restringir de facto las posibilidades de aislamiento y protección de la población. En las zonas con mayor carga urbana, el tejido construido impuso límites espaciales concretos: viviendas mínimas, calles estrechas, comercio en planta baja, transporte masivo desbordado. Bajo estas condiciones, la ciudad no ofreció refugio ni alternativas, y el contagio se convirtió en una consecuencia casi inevitable del modelo urbano. La infraestructura existente, diseñada para la eficiencia económica y no para la contención epidemiológica, expuso de forma desproporcionada a quienes habitan en espacios reducidos y barrios de alta densidad. Así, el virus encontró en la morfología urbana un aliado involuntario, revelando la fragilidad estructural de una ciudad capital no preparada para enfrentar fenómenos de propagación acelerada ni garantizar el derecho a la salud en términos espaciales.

3.4.3 Actividades económicas

La configuración territorial de la Ciudad de México revela una distribución desigual de establecimientos industriales vinculados con sectores altamente contaminantes, lo cual permite identificar zonas críticas de exposición ocupacional a agentes tóxicos. El análisis abarca los subsectores industriales más intensivos en emisiones contaminantes, tales como la industria del papel (322), productos derivados del petróleo y carbón (324), industria química (325), plásticos y hule (326), minerales no metálicos (327), metales básicos (331), productos metálicos (332), maquinaria y equipo (333), electrónica (334), equipo eléctrico (335) y equipo de transporte (336). Estas industrias generan compuestos orgánicos volátiles (COV),

partículas finas (PM_{2.5} y PM₁₀), óxidos de nitrógeno (NO_x), monóxido de carbono (CO) y otros agentes nocivos que comprometen la salud respiratoria, cardiovascular y neurológica de los trabajadores.

Las alcaldías de Iztapalapa, Azcapotzalco, Miguel Hidalgo e Iztacalco concentraron la mayor cantidad de personal ocupado en industrias de alto impacto ambiental. Destaca Iztapalapa con 6,986 personas empleadas en la industria del plástico y el hule (326) y otras 2,990.5 en la industria química (325), lo que refleja una exposición prolongada en un entorno densamente urbanizado y con limitadas condiciones de ventilación y control ambiental. Azcapotzalco mantiene más de 1,800 personas en sectores como metales básicos, productos metálicos e industria química, y dada su cercanía a zonas habitacionales, se configura un entorno de alta carga tóxica combinada entre exposición ocupacional y residencial.

En Miguel Hidalgo, se contabilizan más de 1,400 trabajadores en la industria del plástico y del hule, además de una presencia considerable en los subsectores eléctrico y químico, lo cual incrementa la complejidad atmosférica y laboral. Iztacalco concentra más de 2,400 personas en la industria del plástico y otras 1,800 en el sector químico, lo que evidencia una convergencia de industrias pesadas en un espacio urbano reducido y con bajo amortiguamiento ambiental. Aunque Benito Juárez cuenta con menor número de establecimientos, emplea a más de 3,100 personas en la industria química, lo que evidencia una exposición laboral concentrada en un entorno de alta densidad poblacional.

Otras demarcaciones como Cuajimalpa de Morelos, Venustiano Carranza y Tláhuac superan los 1,000 trabajadores en sectores como metales, plásticos o productos químicos, dentro de territorios afectados por topografía montañosa o urbanización densa, lo cual limita la dispersión de contaminantes.

La Figura 33 ilustra el coeficiente de localización industrial (CL), indicador que permite identificar la especialización sectorial relativa de cada alcaldía. Este análisis muestra una estructura productiva altamente desigual. Cuauhtémoc alcanza el valor más alto de CL (4.37) en la industria del papel, una actividad con elevada demanda energética y emisiones contaminantes significativas. Benito Juárez se especializa en industria química con un CL de 4.04, mientras que Miguel Hidalgo alcanza un CL de 3.93 en equipo eléctrico, lo que evidencia su concentración en procesos industriales de alto riesgo sanitario. Azcapotzalco,

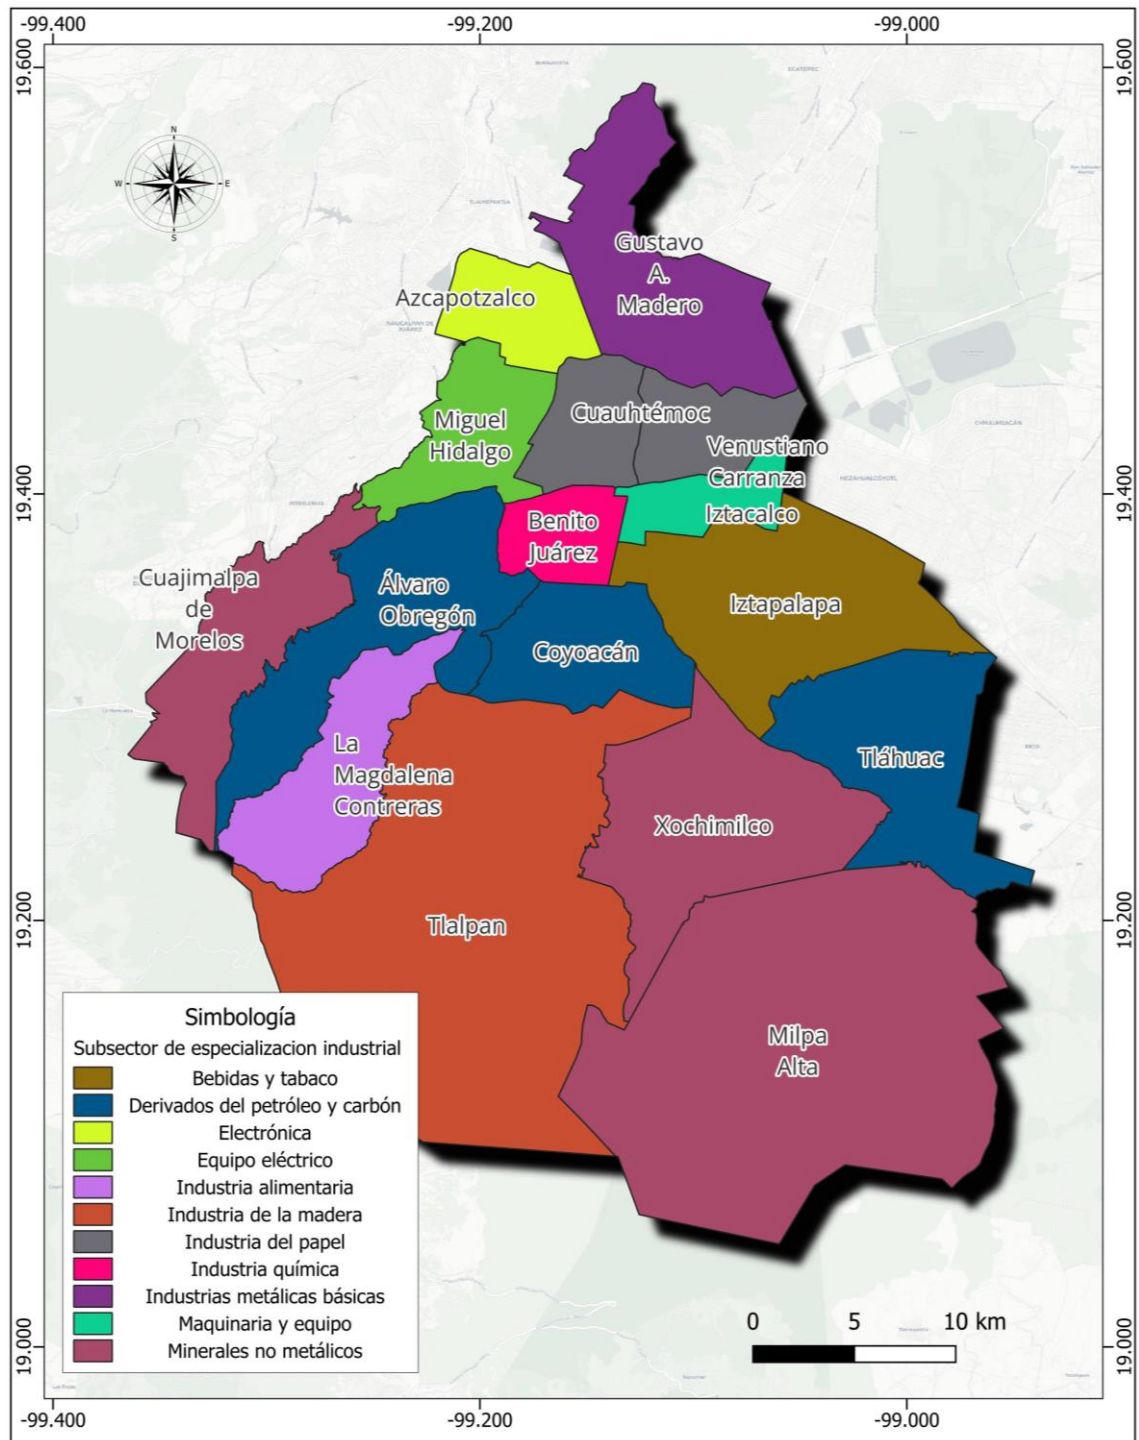
con un CL de 3.44 en electrónica, y Álvaro Obregón, con 3.41 en derivados del petróleo y carbón, refuerzan esta tendencia de concentración industrial contaminante.

En Coyoacán (CL = 2.65), Tláhuac (2.06) y nuevamente Álvaro Obregón, el subsector 324 genera emisiones de CO, NO_x, SO₂ y compuestos aromáticos volátiles, todos ellos asociados a enfermedades respiratorias crónicas. Venustiano Carranza (CL = 2.11) y Xochimilco (1.68) se especializan en industria del papel y minerales no metálicos, respectivamente, este último subsector también se concentra en Cuajimalpa, Milpa Alta y Tlalpan, zonas vinculadas con producción de materiales como cemento, cerámica y ladrillo, altamente generadores de partículas suspendidas.

Aunque algunas alcaldías presentan CL más moderados como La Magdalena Contreras en industria alimentaria, Iztapalapa en bebidas y tabaco, e Iztacalco en maquinaria, su densidad poblacional y morfología urbana incrementan el riesgo de exposición en comunidades cercanas a núcleos industriales.

En conjunto, estos resultados evidencian una estructura urbana de riesgo ambiental y ocupacional basada en la concentración desigual de actividades industriales contaminantes. Esta configuración genera una forma persistente e invisible de vulnerabilidad respiratoria estructural, donde la exposición cotidiana al ambiente laboral degradado deteriora progresivamente la salud de los trabajadores, especialmente en contextos con escasa protección ambiental.

Figura 33 Subsector de especialización comercial



Fuente: Elaboración propia con base en datos del DENUE (2024)

Capítulo IV Dinámica espacio – temporal de la pandemia por COVID-19

4.1 Condiciones de salud

Distribución espaciotemporal de contagios COVID-19

De acuerdo con la Secretaría de Salud (2023) durante la pandemia de COVID-19 a nivel nacional, se identificaron seis olas epidemiológicas las cuales se presentaron de la siguiente manera:

- 1ª ola COVID-19: Desde el 19 de febrero de 2020 (Semana Epidemiológica 8) hasta el 29 de septiembre de 2020 (Semana Epidemiológica 39).
- 2ª ola COVID-19: Desde el 30 de septiembre de 2020 (Semana Epidemiológica 40) hasta el 15 de abril de 2021 (Semana Epidemiológica 15).
- 3ª ola COVID-19: Desde el 4 de junio de 2021 (Semana Epidemiológica 23) hasta el 21 de octubre de 2021 (Semana Epidemiológica 42).
- 4ª ola COVID-19: Desde el 17 de diciembre de 2021 (Semana Epidemiológica 51) hasta el 4 de marzo de 2022 (Semana Epidemiológica 9).
- 5ª ola COVID-19: Desde el 28 de mayo de 2022 (Semana Epidemiológica 22) hasta el 19 de agosto de 2022 (Semana Epidemiológica 33).
- 6ª ola COVID-19: Desde el 3 de diciembre de 2022 (Semana Epidemiológica 49) hasta el 28 de enero de 2023 (Semana Epidemiológica 4).

En particular la pandemia de COVID-19 afectó de manera desigual a los diferentes municipios de la Ciudad de México, con un impacto significativo en las zonas urbanas. Los primeros casos se registraron en las delegaciones con mayor densidad de población y se expandieron hacia otras delegaciones con menor densidad de población y que aún tienen características urbanas.

En 2020, Iztapalapa fue la alcaldía con el mayor número de contagios, acumulando el 15.17% del total de casos (166,521 contagios). Le siguió Gustavo A. Madero con el 11.93% de los contagios (131,009 casos), y Álvaro Obregón, con el 9.45% del total (104,212 contagios). Cuajimalpa de Morelos y Milpa Alta presentaron porcentajes menores, con el 2.43% y 2.27% de los casos (26,701 y 24,939 contagios, respectivamente). Las semanas epidemiológicas más críticas ocurrieron entre el 6 y el 26 de diciembre, alcanzando el punto máximo de contagios durante la semana del 20 al 26 de diciembre evidenciando la primera ola epidemiológica de la pandemia en la ciudad.

En 2021, la Ciudad de México registró un total de 3,033,630 contagios, lo que representó un incremento anual del 176.29% respecto a 2020. El patrón de distribución espacial de los contagios fue similar al del año anterior, con los mayores números de casos concentrados en las mismas delegaciones. Iztapalapa continuó siendo la más afectada, con el 18.21% de los casos (552,503 contagios), seguida por Gustavo A. Madero, que acumuló el 12.92% de los casos (392,027 contagios). Las semanas epidemiológicas más críticas de 2021 se presentaron entre el 17 y el 23 de enero, debido al aumento de contagios registrado en diciembre de 2020 y a la disminución de la temperatura. Posteriormente, se identificó otro punto crítico durante la semana del 1 al 7 de agosto de 2021, lo que marcó el pico de la segunda ola de la pandemia.

Durante 2022, se registraron 1,930,302 casos acumulados de COVID-19, lo que representó una disminución del 36.37% respecto al año anterior. Este descenso se atribuye a la implementación de programas de vacunación. La semana más afectada fue la del 16 al 22 de enero de 2022, marcando la tercera ola epidemiológica, mientras que la cuarta ola se presentó entre el 10 y el 16 de julio de 2022.

4.1.1 Tasa de prevalencia por COVID-19


En 2020, los datos evidencian una variabilidad considerable en la tasa de prevalencia de COVID-19 entre los municipios de la Ciudad de México. La Magdalena Contreras presentó la mayor tasa de prevalencia, con 1,948.97 casos por cada 10,000 habitantes, seguida por Milpa Alta con 1,605.30 y Tláhuac con 1,482.31, lo cual indica una afectación significativa durante la primera fase de la pandemia. Álvaro Obregón (1,356.39) y Cuajimalpa de Morelos (1,206.43) también registraron tasas elevadas, reflejando la distribución desigual de la enfermedad en el territorio capitalino. Por otro lado, Iztapalapa, el municipio con mayor población, mostró una tasa de prevalencia de 896.82 casos por cada 10,000 habitantes, lo cual puede atribuirse a la alta densidad poblacional que dispersó la incidencia de los contagios. Gustavo A. Madero (1,103.51) y Azcapotzalco (1,149.65) presentaron tasas moderadas, indicando un impacto intermedio en estas áreas.

En 2021, se observó un aumento significativo en las tasas de prevalencia en todos los municipios, con La Magdalena Contreras nuevamente encabezando la lista con 4,427.15 casos por cada 10,000 habitantes. Le siguieron Milpa Alta (4,149.47) y Venustiano Carranza

(4,340.64), siendo las áreas más afectadas durante este segundo año de la pandemia. Gustavo A. Madero (3,334.25) y Álvaro Obregón (3,795.53) también presentaron tasas elevadas, indicando una propagación considerable del virus en áreas con densidad poblacional media y alta. Este incremento puede asociarse con la aparición de nuevas variantes del virus y el relajamiento de las medidas sanitarias. Benito Juárez (2,791.33) y Miguel Hidalgo (2,322.72) registraron tasas menores en comparación con otros municipios, aunque el aumento respecto a 2020 fue notable en toda la ciudad.

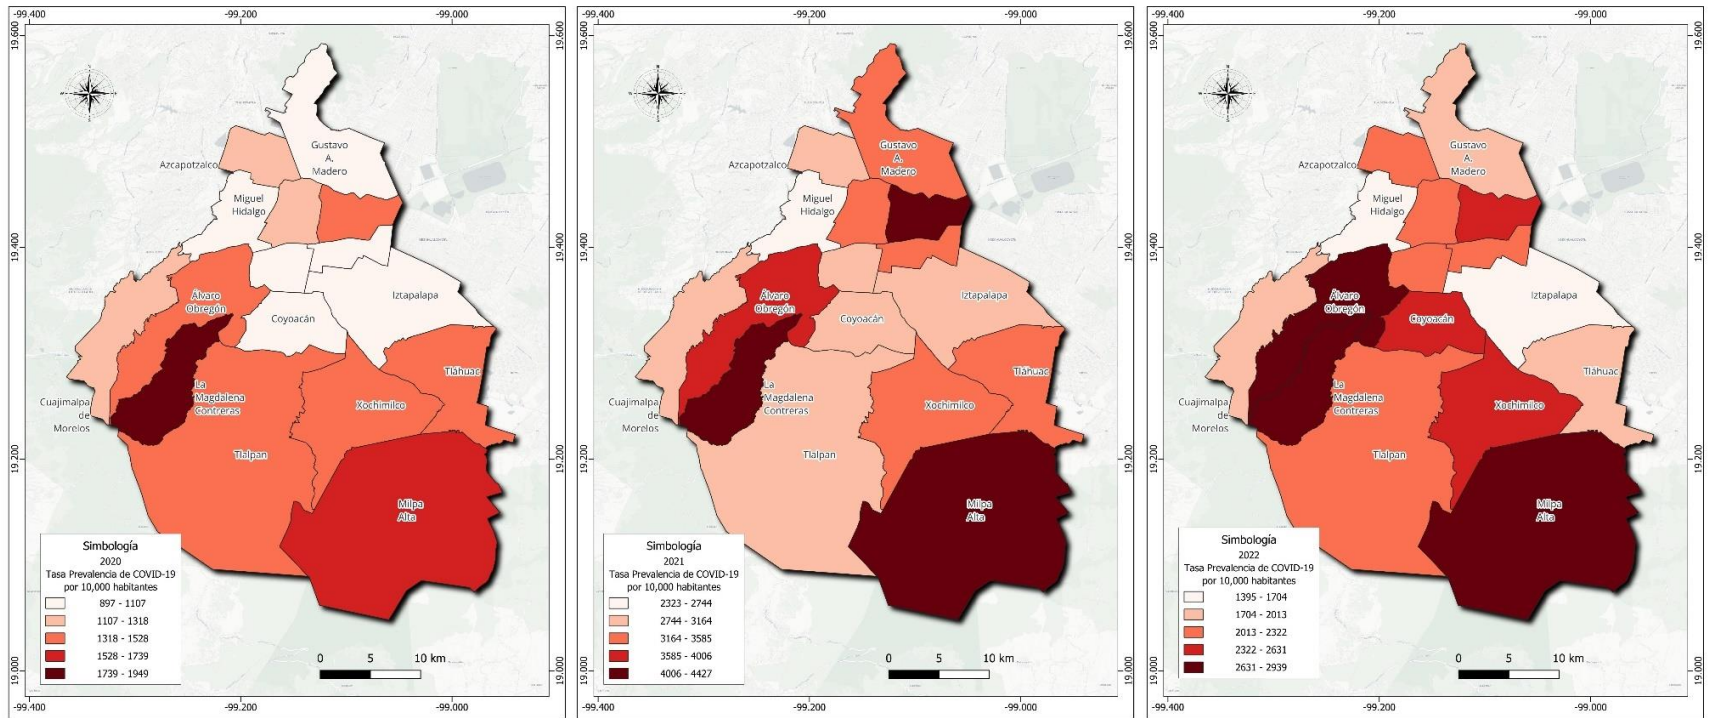
En 2022, la tendencia cambió hacia una disminución general en las tasas de prevalencia, atribuible a la implementación de programas de vacunación masiva y políticas de salud pública. La Magdalena Contreras y Milpa Alta continuaron presentando tasas relativamente elevadas (2,855.08 y 2,887.93 respectivamente), aunque considerablemente menores que en el año anterior. Álvaro Obregón (2,939.41) y Coyoacán (2,541.52) mantuvieron tasas de prevalencia significativas, lo cual refleja la importancia de los esfuerzos de mitigación. Iztapalapa mostró una notable reducción, con 1,395.41 casos por cada 10,000 habitantes, lo que evidencia la efectividad del acceso ampliado a las vacunas y la implementación de medidas preventivas.

Figura 34 Evolución de los Contagios Acumulados de COVID-19 en la Ciudad de México (2020-2022)



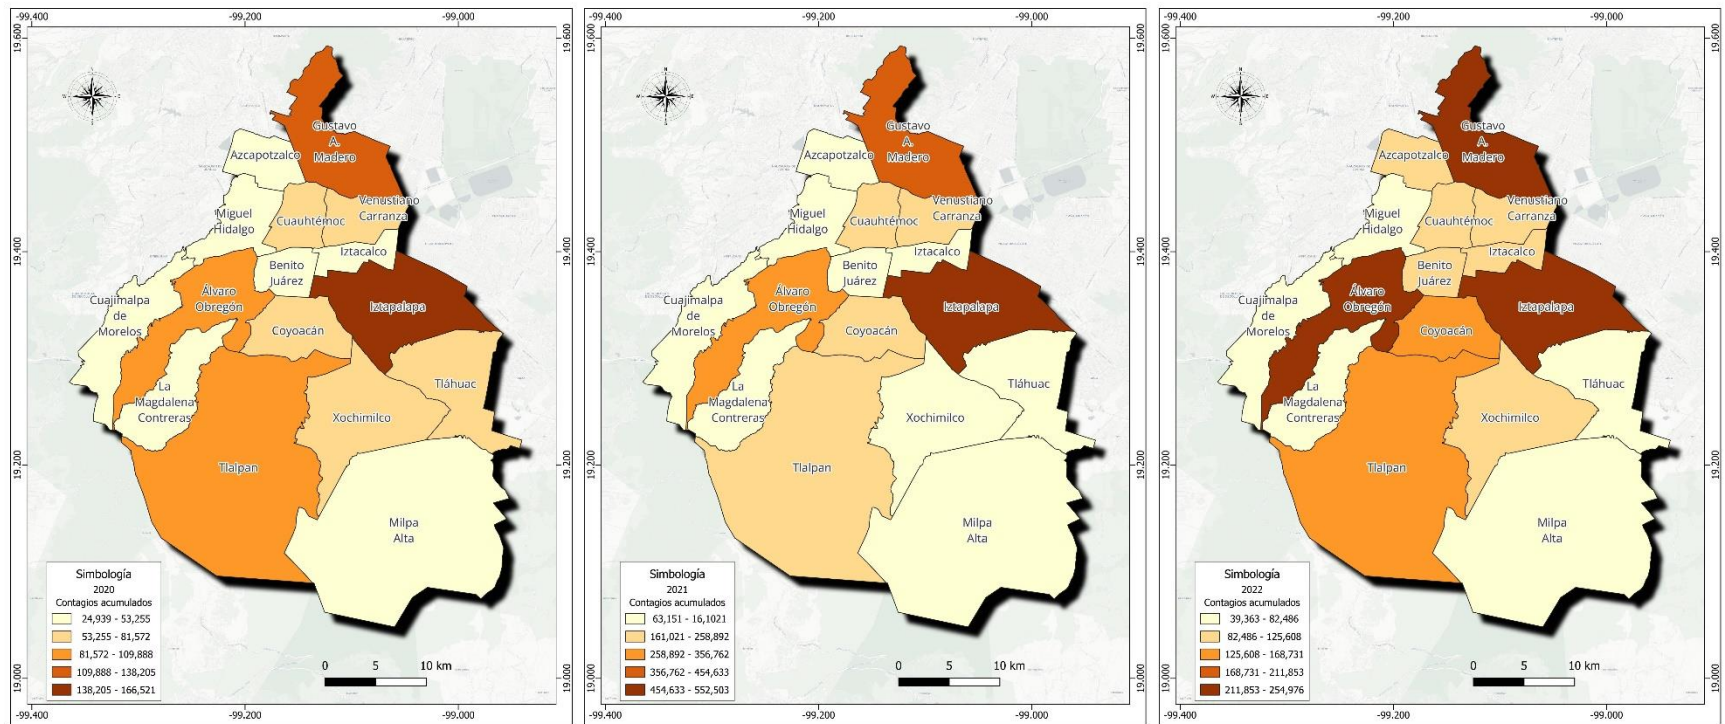
Fuente: Elaboración propia con base en datos de la Dirección General de Epidemiología (2024)

Figura 35 Tasa de prevalencia 2020, 2021, 2022 por 10,000 habitantes



Fuente: Elaboración propia con base en datos de la Dirección General de Epidemiología (2023)

Figura 36 Contagios acumulados de COVID-19 anuales por municipio de la Ciudad de México



Fuente: Elaboración propia con base en datos de la Dirección General de Epidemiología (2023)

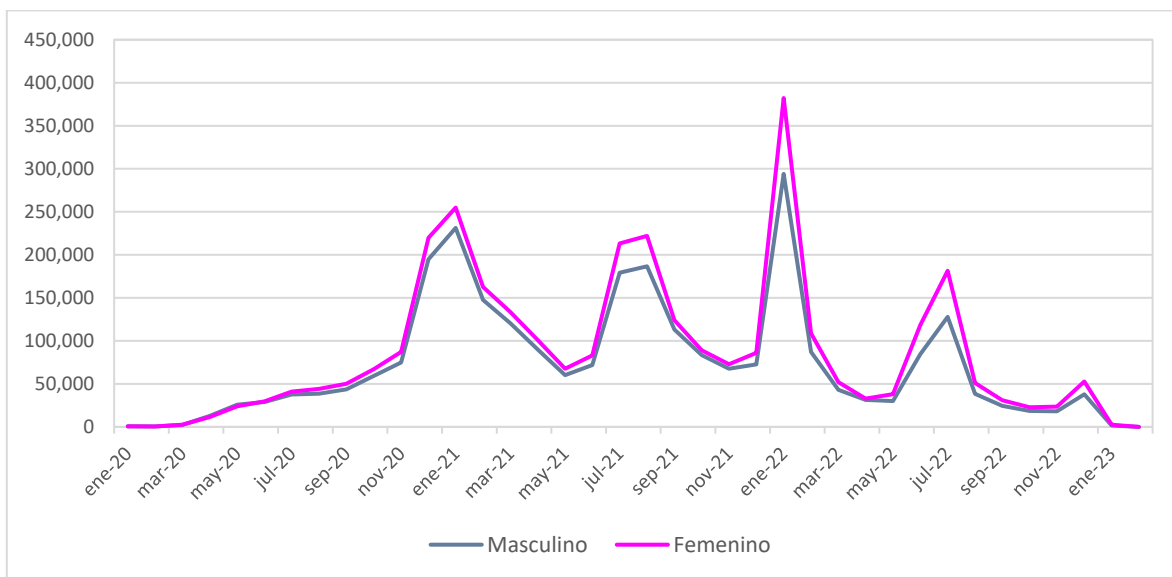
4.1.2 Tasa de prevalencia por género de COVID-19

En 2020, La Magdalena Contreras presentó la tasa de prevalencia más alta tanto en mujeres (2,087.13 por 10,000 habitantes) como en hombres (1,798.89 por 10,000), lo cual indica una mayor afectación en este municipio. Otros municipios que destacaron fueron Milpa Alta y Tláhuac, con tasas elevadas, especialmente en mujeres. Iztapalapa, aunque reportó el mayor número absoluto de contagios con el 15.17% del total de casos (166,521 contagios), tuvo una tasa de prevalencia relativamente más baja (894.87 para mujeres y 898.89 para hombres) debido a su gran población. Municipios como Cuajimalpa de Morelos y Xochimilco mostraron tasas más altas en mujeres, mientras que en Benito Juárez y Cuauhtémoc la prevalencia fue mayor en hombres, lo que refleja la distribución heterogénea de factores de riesgo, densidad poblacional y condiciones locales.

En 2021, se observó un incremento significativo en las tasas de prevalencia en la mayoría de los municipios. La Magdalena Contreras nuevamente presentó las tasas más altas, con 4,687.29 en mujeres y 4,145.07 en hombres, reflejando un fuerte impacto en ese año. De manera similar, Milpa Alta y Xochimilco reportaron altas tasas de prevalencia, evidenciando un notable impacto en estas zonas semiurbanas, probablemente debido a dificultades en el acceso a servicios de salud y el control de la propagación del virus. En Venustiano Carranza, se observó una notable diferencia entre hombres y mujeres, con una tasa de prevalencia mayor en hombres (4,904.09) que en mujeres (3,838.94), lo cual podría estar relacionado con diferencias en la exposición al riesgo debido a actividades laborales predominantes en la región.

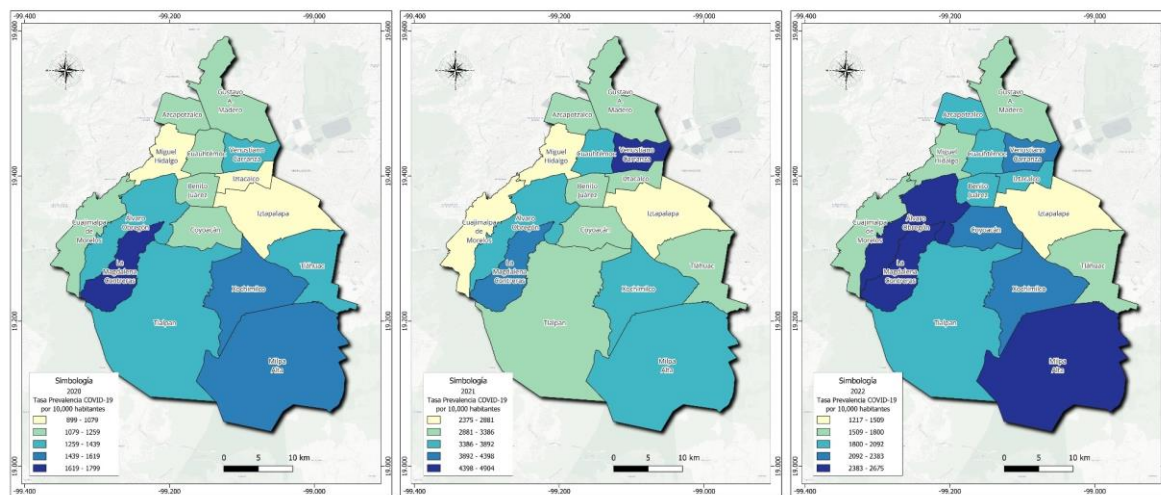
En 2022, se observó una disminución general en las tasas de prevalencia en todos los municipios, en gran parte atribuible a los programas de vacunación implementados. No obstante, La Magdalena Contreras y Milpa Alta continuaron presentando tasas relativamente elevadas, aunque con una reducción notable en comparación con el año anterior. Iztapalapa experimentó una disminución significativa en sus tasas de prevalencia (1,563.01 en mujeres y 1,217.38 en hombres), lo que evidenció la efectividad de las intervenciones sanitarias. Asimismo, Álvaro Obregón y Tlalpan mantuvieron tasas importantes de prevalencia, probablemente vinculadas con la dinámica urbana y las características sociodemográficas de sus habitantes.

Figura 37 Contagios acumulados de COVID-19 por género en la Ciudad de México (2020-2022)



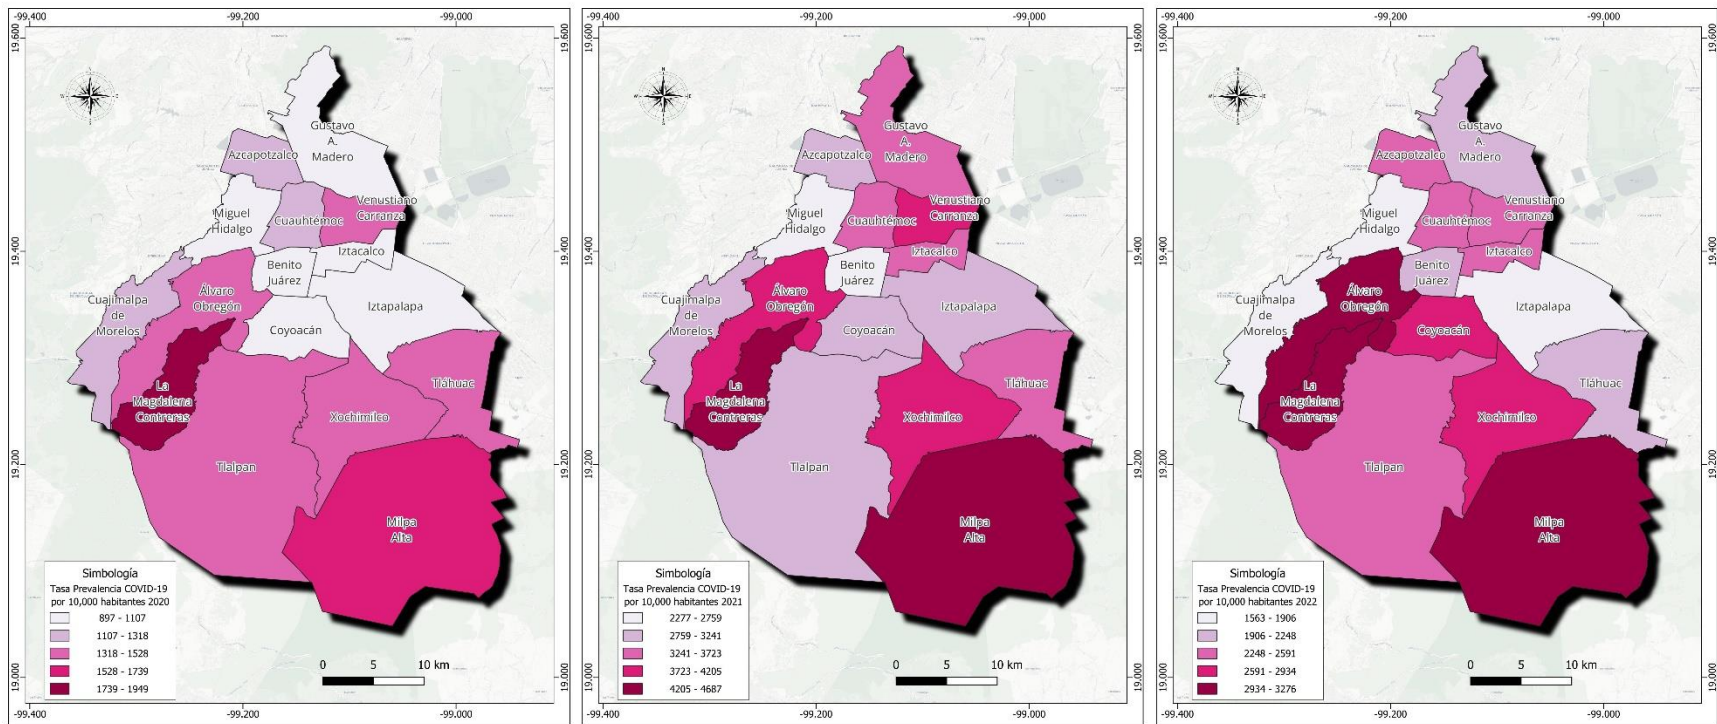
Fuente: Elaboración propia con base en datos de la Dirección General de Epidemiología (2023)

Figura 38 Tasa de prevalencia de COVID-19 por 10,000 hombres en la Ciudad de México



Fuente: Elaboración propia con base en datos de la Dirección General de Epidemiología (2023)

Figura 39 Tasa de prevalencia de COVID-19 por 10,000 mujeres en la Ciudad de México



Fuente: Elaboración propia con base en datos de la Dirección General de Epidemiología (2023)

4.1.3 Contagios de COVID-19 por grupos de edad

Durante la pandemia de COVID-19, la distribución de contagios en la Ciudad de México evidenció diferencias significativas entre los distintos grupos etarios, mostrando patrones que evolucionaron en el tiempo y espacio.

Durante 2020, se reportaron 47,198 contagios en la primera infancia, 85,316 en niñez, 204,799 en adolescencia, 735,711 en juventud, 1,615,772 en edad adulta. Los grupos de primera infancia, niñez y adolescencia registraron tendencias similares en la distribución de contagios, con una concentración mayor de casos en las alcaldías del sur de la ciudad, como Tláhuac, Xochimilco, Milpa Alta, Tlalpan y la alcaldía La Magdalena Contreras. En estas delegaciones, los porcentajes de contagio se mantuvieron por debajo del 18%, lo que indica una afectación menor en comparación con otros grupos etarios.

Al inicio de la pandemia, con la predominancia de la variante Alfa, los contagios en estos grupos etarios infantiles permanecieron relativamente bajos. Sin embargo, hacia finales de 2020, la aparición de la variante Beta coincidió con un aumento de casos. Este incremento puede estar asociado a condiciones ambientales específicas, tales como el descenso de temperaturas y la intensificación de los vientos invernales. Estas condiciones meteorológicas probablemente favorecieron la propagación del virus en un contexto urbano denso. Además, las características topográficas del sur de la Ciudad de México y altitudes elevadas podrían haber influido en los patrones de dispersión del virus. En 2020, no se contaba con vacunas para menores de 12 años.

La población juvenil (19 a 29 años) fue uno de los grupos con alto porcentaje de contagios, especialmente en delegaciones como Milpa Alta (24.9%). El patrón de distribución espacial de contagios fue similar al de la población infantil, aunque con algunas diferencias. La alcaldía Cuajimalpa de Morelos presentó un porcentaje del 23.0%, seguida de Xochimilco y Tláhuac con un 22.7% cada una. Otras delegaciones, como Tlalpan, Álvaro Obregón y La Magdalena Contreras, registraron valores entre el 22.0% y el 21.0%. Los contagios en la región sur se presentaron de manera similar a la población infantil y adolescente, posiblemente debido a la ubicación de estas delegaciones en zonas con altitudes elevadas y la recepción de vientos directos provenientes del este. Milpa Alta, con una altitud de hasta 3,600 metros sobre el nivel del mar, recibe vientos fríos directos y tiene un clima

predominantemente frío, lo cual podría haber sido un factor condicionante del aumento de contagios en la población joven. Las delegaciones con menor porcentaje de contagios en este grupo se ubican al centro de la ciudad, de las cuales fueron Venustiano Carranza (19.0%) y Benito Juárez (19.4%).

Las variantes Alfa y Beta predominaron en la población adulta de 30 a 59 años, concentrando la mayor cantidad de contagios durante 2020, con porcentajes que superaron el 50% en diversas delegaciones. Las delegaciones más afectadas se localizaron en el centro y este de la ciudad, tales como Benito Juárez e Iztacalco registrando los mayores porcentajes de contagio (59.4%), seguidas por Cuauhtémoc (59.2%) e Iztapalapa (58.9%). Azcapotzalco, Miguel Hidalgo y Venustiano Carranza mostraron cifras superiores al 58%, mientras que Gustavo A. Madero y Coyoacán alcanzaron el 57.7%. En delegaciones como Tláhuac (55.1%) y Milpa Alta (54.6%) más de la mitad de los contagios correspondieron a este grupo etario, lo que refleja una alta concentración de casos incluso en demarcaciones que, comparativamente, presentaron menor volumen absoluto de contagios. Dada la alta capacidad de propagación de la variante Beta, esta ocasionó el pico más alto de contagios en diciembre de 2020, en un contexto en el que aún no había vacunas disponibles.

Los adultos mayores (60 años o más) fueron el segundo grupo más afectado en términos de porcentaje de contagios en 2020, aunque en menor medida que la población adulta. Venustiano Carranza, Azcapotzalco y Benito Juárez reportaron los mayores porcentajes (15.7%, 15.6% y 15.6%, respectivamente). Miguel Hidalgo (15.4%) y Coyoacán (15.2%) también presentaron cifras elevadas. En contraste, delegaciones como Tláhuac y Milpa Alta mostraron los porcentajes más bajos, con 11.4% y 10.7%, respectivamente. Fue hasta el 23 de diciembre de 2020 cuando llegaron las primeras vacunas contra COVID-19, que inicialmente se aplicaron al personal de salud, seguido por la población de 60 años y más, y posteriormente a la población adulta (Secretaría de Salud, 2020). Antes de esa fecha, la población de la Ciudad de México estaba desprotegida, siguiendo protocolos de sana distancia, confinamiento, uso obligatorio de cubrebocas y actividades a distancia.

Diciembre de 2020 marcó el punto más alto de la pandemia, con 414,532 contagios reportados. Este patrón de incremento se mantuvo en enero de 2021, cuando se registró la primera ola epidemiológica, con 486,140 casos en toda la ciudad.

En enero de 2021 se identificó la primera ola epidemiológica de la Ciudad de México, la cual generó 486,140 contagios solo en ese mes.

En 2021 se identificó una nueva variante, denominada Delta, la cual era un 80% más transmisible que la variante Alfa. Esto resultó en un incremento de contagios en la población infantil y juvenil, aunque no fueron los sectores más afectados en comparación con el año anterior. Para ese año se registraron los siguientes casos acumulados a lo largo del año: en la población en edad de primera infancia se registraron 47,198 casos; en niñez, 85,316; en adolescencia, 204,799; en juventud, 735,711; en edad adulta, 1,615,772; y en adultos mayores.

En cuanto a la población adulta, los casos de contagio incrementaron significativamente. Delegaciones como Venustiano Carranza presentaron porcentajes de contagio del 55.74% para ese año, seguidas de Benito Juárez con 55.38%, Cuauhtémoc 54.67%, Iztacalco 54.31%, Miguel Hidalgo 54.18%, Iztapalapa 53.77%, Azcapotzalco 53.72%, La Magdalena Contreras 53.25%, Gustavo A. Madero 52.88%, Xochimilco 52.53%, Coyoacán 52.44%, Álvaro Obregón 52.17%, Tláhuac 52.00%, Tlalpan 51.99%, Cuajimalpa de Morelos 51.93%, y Milpa Alta 48.55%.

Durante este año, los casos de contagio disminuyeron en la población adulta mayor. Los valores más altos se presentaron en la alcaldía Benito Juárez con 14.50%, seguida de Coyoacán con 12.46% y Cuauhtémoc con 12.44%. Otras delegaciones como Venustiano Carranza (12.39%), Miguel Hidalgo (11.92%), Gustavo A. Madero (11.83%), Iztacalco (11.79%), Azcapotzalco (11.63%), Iztapalapa (11.48%), Álvaro Obregón (10.92%), Tlalpan (10.89%), La Magdalena Contreras (10.09%), Xochimilco (9.51%), Tláhuac (8.91%), Cuajimalpa de Morelos (8.85%), y Milpa Alta (8.38%), la disminución de los casos podría atribuirse que para esa fecha la población adulta mayor ya había recibido al menos la primera dosis de alguna vacuna.


A mediados de 2021, se presentó un incremento exponencial de los casos de contagio en toda la Ciudad de México, siendo el año con mayor número de contagios. Este aumento se detonó en los meses de julio y agosto, a pesar de que eran meses con temperaturas cálidas. Este incremento podría atribuirse a que algunas instituciones públicas y privadas realizaron actividades híbridas, lo cual llevó a que la población comenzara a retomar actividades fuera

de casa. En los meses posteriores, comenzó a observarse una disminución en los contagios, alcanzando su punto más bajo en noviembre y diciembre.

En 2022 se registraron los siguientes casos acumulados en la población en edad de primera infancia, 45,934 casos; en niñez, 80,205; en adolescencia, 125,796; en juventud, 411,916; en edad adulta, 1,029,111; y en adultos mayores, 237,353. En enero de 2022 se identificó una nueva variante aún más contagiosa que las anteriores, denominada Ómicron. Esta variante generó, solo en enero de 2022, un total de 676,289 casos de contagio en toda la ciudad. Fue clasificada como la cepa más predominante de la pandemia, causando la ola de contagios más alta de todo el periodo y afectando a todos los grupos etarios.

Para febrero del mismo año se logró reducir los casos de contagio, pero en julio se presentó una nueva ola epidemiológica que afectó principalmente a la población en edad adulta. Las delegaciones más afectadas fueron Benito Juárez (56.87%), Cuauhtémoc (55.18%), Miguel Hidalgo (54.57%), Iztacalco (54.38%), Iztapalapa (54.04%), Venustiano Carranza (54.02%), Azcapotzalco (53.56%), Gustavo A. Madero (53.52%), Xochimilco (53.40%), Coyoacán (52.57%), Tláhuac (52.55%), Álvaro Obregón (52.24%), Cuajimalpa de Morelos (52.19%), Tlalpan (51.67%), La Magdalena Contreras (51.63%), y Milpa Alta (48.61%). Para agosto de 2022 se regresó completamente a actividades presenciales. En algunos casos se mantuvieron actividades híbridas, pero en el sector educativo se regresó a clases de manera normal, con todos los niveles educativos asistiendo de forma presencial.

Figura 40 Contagios de COVID-19 por grupos de edad de la Ciudad de México



Fuente: Elaboración propia con base en datos de la Dirección General de Epidemiología (2023)

Consideraciones

Los contagios de COVID-19 en la Ciudad de México afectaron principalmente a la población en edad adulta, seguida por la población adulta mayor. La distribución de los casos por grupos etarios varía según las características demográficas y geográficas de cada alcaldía. La población infantil, en sus primeras etapas de vida, mostró una menor incidencia de contagio en comparación con otros grupos, posiblemente debido a la naturaleza de las variantes de SARS-CoV-2 presentes en ese periodo. En contraste, las delegaciones con mayor densidad poblacional, como Benito Juárez e Iztacalco, concentraron una elevada proporción de casos en la población adulta, mientras que los casos en la población adulta mayor se distribuyeron mayormente en las zonas centro y norte de la ciudad. Estos patrones de contagio resaltan la influencia de factores geográficos y demográficos en la propagación del COVID-19 en diferentes grupos de edad, destacando la necesidad de estrategias de salud pública específicas para cada grupo. La población infantil y adolescentes se presentaron los casos de contagio al sur de la Ciudad de México principalmente en las delegaciones que presentan temperaturas más frías.

4.1.4 Comorbilidades asociadas a COVID-19

En 2020, el COVID-19 emergió como una enfermedad nueva, lo cual permitió descubrir, a partir de los casos confirmados, que la presencia de comorbilidades incrementaba significativamente las probabilidades de infección y complicaciones graves en los pacientes. En países como México, este hallazgo permitió identificar a los adultos mayores como un grupo poblacional particularmente vulnerable, debido a la prevalencia de condiciones crónicas como diabetes, enfermedades cardiovasculares (por ejemplo, insuficiencia cardíaca o hipertensión), afecciones pulmonares, cáncer, tabaquismo y situaciones específicas como ser receptores de trasplantes.

En 2020, los datos muestran que la mayoría de los pacientes registrados no presentaron comorbilidades, con un total de 724,704 casos, lo que representa un grupo significativo de personas aparentemente sanas al momento de su registro. Sin embargo, entre los pacientes con enfermedades preexistentes, fue el tabaquismo la comorbilidad más común, afectando a 85,943 pacientes. Le siguieron la obesidad, con 59,183 casos; la hipertensión, con 52,661; y la diabetes, con 32,853 pacientes.

En 2020, el tabaquismo fue la comorbilidad predominante entre los hombres adultos, destacándose la alcaldía Iztapalapa con 6,287 casos, mientras que en otras delegaciones se observaron cifras menores. Asimismo, la obesidad fue relevante en delegaciones como Álvaro Obregón (5,366 casos) y Azcapotzalco (2,401 casos).

Entre las mujeres adultas, la obesidad prevaleció como la comorbilidad más común, registrando los valores más altos en Gustavo A. Madero e Iztapalapa, con 5,944 casos. Álvaro Obregón también destacó con 3,643 casos. En cuanto al tabaquismo, delegaciones como Benito Juárez (1,857 casos) y La Magdalena Contreras (1,680 casos de hipertensión) fueron las más afectadas.

En 2021, los casos de tabaquismo casi se duplicaron, pasando de 85,943 en 2020 a 179,795. La hipertensión también experimentó un incremento significativo, de 52,661 a 110,883 casos, al igual que la obesidad, que pasó de 59,183 a 93,945, y la diabetes, que aumentó de 32,853 a 70,841. Además, el asma mostró un crecimiento considerable, con 36,548 pacientes en 2021, frente a los 16,003 registrados en 2020.

Durante 2021, el tabaquismo continuó siendo la comorbilidad más frecuente entre los hombres adultos, con Iztapalapa liderando los casos (15,155), seguida de Gustavo A. Madero (10,219 casos). La hipertensión también fue relevante, con Cuajimalpa de Morelos registrando 1,437 casos y La Magdalena Contreras 732 casos.

En la población femenina, la hipertensión prevaleció, alcanzando 14,140 casos en Iztapalapa. La obesidad continuó siendo común en delegaciones como Azcapotzalco, Cuauhtémoc, Tláhuac, Iztacalco y Miguel Hidalgo. Aunque el tabaquismo fue menos frecuente, se presentó entre mujeres adultas de delegaciones como Coyoacán y Benito Juárez, como la comorbilidad predominante.

En 2022, el tabaquismo continuó siendo predominante entre los hombres adultos, con Iztapalapa reportando 4,556 casos y Gustavo A. Madero 4,467. La hipertensión mostró menor incidencia, pero destacó en La Magdalena Contreras con 692 casos. Por otro lado, la diabetes afectó principalmente a hombres en Milpa Alta (502 casos) y Cuajimalpa de Morelos (302 casos).

Los datos sobre comorbilidades de pacientes con COVID-19 muestran tendencias significativas y algunos cambios respecto a los años anteriores. Las comorbilidades más frecuentes continuaron siendo el tabaquismo (76,278 casos), la hipertensión (63,068), la obesidad (48,966) y la diabetes (39,743). Estas afecciones se mantuvieron como las más comunes, reflejando la continuidad en los patrones de vulnerabilidad frente al COVID-19.

4.1.5 Combinación de comorbilidades

Las comorbilidades que tuvieron mayor impacto durante el periodo analizado fueron la diabetes, hipertensión, obesidad y tabaquismo, destacando su prevalencia en diversas combinaciones que afectaron de manera significativa a la población de la Ciudad de México. De acuerdo con los datos, el conjunto de enfermedades más frecuentes fueron diabetes, hipertensión, obesidad y tabaquismo, así como la triada de diabetes, hipertensión y obesidad. Estas afectaron de manera diferencial a la población según el género y el ciclo de vida, mostrando patrones específicos de distribución geográfica.

En el caso de las mujeres, las adultas mayores fueron las más afectadas por la comorbilidad de diabetes e hipertensión, con un predominio significativo en la alcaldía Iztapalapa, que reportó 3,640 casos en el año 2021, seguida por las delegaciones Gustavo A. Madero y Álvaro Obregón, con 2,252 y 1,723 casos, respectivamente. Además, la combinación de obesidad y tabaquismo también tuvo un impacto considerable en las mujeres adultas, especialmente en la alcaldía Azcapotzalco, con 723 casos. La triada de diabetes, hipertensión y obesidad fue particularmente prevalente entre las mujeres en edad adulta, con Gustavo A. Madero registrando 724 casos, seguido por Iztapalapa y Álvaro Obregón, con 605 y 344 casos, respectivamente. En Benito Juárez, las mujeres adultas mayores también presentaron esta triada en un número menor, con 117 casos.

En la población masculina, la afectación por comorbilidades presentó un patrón ligeramente diferente. Entre los adultos mayores, la diabetes e hipertensión fue la combinación más frecuente, particularmente en la alcaldía Iztapalapa, con 2,263 casos en el año 2021. Este patrón se replicó en las delegaciones de Álvaro Obregón, Tlalpan, Coyoacán y Cuauhtémoc, indicando una mayor vulnerabilidad de los hombres mayores con estas condiciones preexistentes durante la pandemia. Entre los adultos, la obesidad y el tabaquismo fueron las comorbilidades más prevalentes, especialmente en la alcaldía Gustavo A. Madero,

que registró 2,066 casos, seguida por Tláhuac, Iztacalco y Miguel Hidalgo. La triada de diabetes, hipertensión y obesidad afectó principalmente a los hombres adultos, con una alta incidencia en Gustavo A. Madero (236 casos), seguida por Iztapalapa (156 casos) y Cuauhtémoc (123 casos).

Geográficamente, las delegaciones con mayor afectación por comorbilidades durante los años 2021 y 2022 fueron Iztapalapa y Gustavo A. Madero, las cuales concentraron la mayor parte de los casos en prácticamente todas las combinaciones analizadas. Iztapalapa fue particularmente afectada por la combinación de diabetes e hipertensión, tanto en mujeres como en hombres mayores, mientras que Gustavo A. Madero destacó por los casos de obesidad y tabaquismo en hombres adultos y la triada de diabetes, hipertensión y obesidad en ambos géneros.

En conclusión, las comorbilidades de diabetes, hipertensión, obesidad y tabaquismo afectaron principalmente a adultos mayores y adultos en la Ciudad de México, mostrando un claro sesgo hacia la población femenina adulta mayor con diabetes e hipertensión y hacia la población masculina adulta con obesidad y tabaquismo. Las delegaciones Iztapalapa y Gustavo A. Madero resultaron ser las áreas de mayor concentración de casos, reflejando una distribución espacial predominante en la región este y norte de la ciudad.

4.2 Modelo de predicción de COVID-19

Al inicio de la pandemia de COVID-19 se desarrollaron diversos modelos predictivos orientados a determinar la localización y el momento en que podrían registrarse nuevos casos de contagio. Estas proyecciones se implementaron en distintas escalas espaciales (continental, nacional, estatal y regional), lo que permitió estimar de manera preliminar el número potencial de personas infectadas.

El empleo de modelos predictivos con enfoque territorial ha contribuido a explicar las diferencias geográficas en la prevalencia del virus, poniendo en evidencia una marcada variabilidad espacial en la calibración de sus hiperparámetros. Esta dinámica ha posibilitado la identificación de patrones de concentración de casos, así como la delimitación de áreas prioritarias para la atención sanitaria inmediata.

La predicción a nivel de alcaldía mostró que el COVID-19 presenta una distribución heterogénea en el territorio, incluso dentro de la misma unidad administrativa. Este hallazgo evidencia que, a escalas locales, el riesgo de contagio no es homogéneo y responde a factores y condiciones diferenciadas que inciden en la dinámica espacio-temporal de la enfermedad, que puede ser por el tipo de clima, la densidad de población, la ocupación económica, entre otros factores.

El análisis temporal de la pandemia permite comprender con mayor precisión la evolución y propagación del COVID-19 en contextos urbanos complejos. En este sentido, los modelos predictivos basados en Deep Learning aportan conocimiento científico para anticipar la aparición de nuevos casos y generar alertas tempranas dirigidas a la población. En la Ciudad de México, la implementación de un modelo híbrido CNN+LSTM permitió la estimación a corto plazo de casos de contagio, con un horizonte promedio de 10 días, en las 16 delegaciones. A partir del 1 de septiembre de 2023, este sistema logró proyectar de manera satisfactoria la incidencia potencial de casos, aportando información estratégica para la gestión sanitaria y la asignación de recursos en territorios con elevada densidad poblacional.

El modelo predictivo CNN+LSTM aplicado a la estimación de casos de contagio por COVID-19 en la Ciudad de México presentó, para cada alcaldía, configuraciones específicas de hiperparámetros con el objetivo de lograr proyecciones precisas a un horizonte mínimo de 10 días. Esta variabilidad en la calibración reflejó la heterogeneidad espacial en la dinámica de transmisión del virus. Del mismo modo, las métricas de evaluación mostraron valores distintos entre delegaciones, lo que sugiere que la capacidad predictiva del modelo estuvo condicionada por características particulares de cada territorio, entre ellas la densidad poblacional, la movilidad y las condiciones socioambientales.

Aunque el modelo alcanzó niveles satisfactorios de precisión en las distintas delegaciones, su principal valor radica en la capacidad de proyectar escenarios futuros de contagio. Esta cualidad lo convierte en una herramienta estratégica para anticipar posibles repuntes y planificar intervenciones sanitarias con enfoque territorial.

El modelo CNN+LSTM se desarrolló con el propósito de representar las trayectorias temporales y espaciales del contagio por COVID-19, adaptando sus parámetros a las condiciones específicas de cada alcaldía. Mediante una arquitectura híbrida que combina la

detección de patrones espaciales con la capacidad de memoria a largo plazo, fue posible modelar las curvas de contagio incorporando márgenes de predicción que describen escenarios potenciales de evolución epidémica.

Predicción del modelo CNN+LSTM por alcaldía

El modelo CNN+LSTM aplicado en las dieciséis delegaciones de la Ciudad de México reprodujo las tendencias principales de los contagios de COVID-19 con un grado aceptable de precisión. El análisis cuantitativo mostró que en 12 de las 16 delegaciones (75%) los intervalos de confianza permanecieron estrechos en más del 85% de los días analizados, lo que indica estabilidad en la predicción. En contraste, en 4 delegaciones centrales y de alta movilidad (Iztapalapa, Iztacalco, Venustiano Carranza y Gustavo A. Madero) se observaron desajustes significativos: los contagios reales superaron el margen superior en entre 8% y 15% de los días del periodo de estudio.

En las siguientes tablas por alcaldía se comparan los contagios reales con las predicciones, incluyendo los márgenes superior e inferior que definen el intervalo de confianza.

Alcaldía Azcapotzalco

En Azcapotzalco, el modelo CNN+LSTM consiguió reproducir de manera aceptable la trayectoria general descendente de los contagios, aunque presentó fluctuaciones notorias en su precisión diaria. Durante los primeros días del periodo de análisis, las estimaciones se mantuvieron próximas a los valores observados, pero conforme avanzaron las fechas y se registraron cambios abruptos en la dinámica epidemiológica, comenzaron a surgir desviaciones más amplias. En la tabla 5, se muestran los valores reales y las proyecciones

Estas variaciones pueden explicarse por la ausencia en el modelo de variables que capturen condiciones coyunturales del territorio. Entre los factores que inciden en este comportamiento se encuentran las modificaciones repentinas en los patrones de movilidad urbana y la interacción social, muchas veces asociadas a eventos locales, concentraciones masivas o actividades recreativas que incrementan el riesgo de transmisión. Asimismo, ajustes en la capacidad de diagnóstico, cambios en las políticas de aplicación de pruebas o variaciones en la notificación de casos pueden alterar la relación entre los valores reales y los

proyectados. A ello se suman posibles influencias ambientales y meteorológicas que afectan la propagación del virus, pero que no fueron incorporadas en esta versión del modelo.

Desde la geografía de la salud, en un territorio con alta densidad poblacional y fuertes conexiones metropolitanas como Azcapotzalco, la transmisión viral puede experimentar variaciones rápidas y difíciles de anticipar únicamente a partir de los registros históricos de contagios. En consecuencia, aunque la predicción ofrece un insumo útil para la planeación sanitaria a corto plazo, su precisión se ve condicionada por fenómenos socioespaciales y contextuales que no forman parte de su estructura de entrenamiento.

Tabla 5 Alcaldía Azcapotzalco CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen Inferior	Margen Superior
01/09/2023	Azcapotzalco	34	37.5	34.7	40.3
02/09/2023	Azcapotzalco	19	26	23.2	28.9
03/09/2023	Azcapotzalco	24	19.2	16.4	22.1
04/09/2023	Azcapotzalco	47	41.6	38.7	44.4
05/09/2023	Azcapotzalco	49	51.2	48.3	54
06/09/2023	Azcapotzalco	47	51.1	48.3	53.9
07/09/2023	Azcapotzalco	41	41.7	38.8	44.5
08/09/2023	Azcapotzalco	53	36.4	33.6	39.2
09/09/2023	Azcapotzalco	19	25	22.1	27.8
10/09/2023	Azcapotzalco	12	21.6	18.8	24.5
11/09/2023	Azcapotzalco	69	37.8	34.9	40.6
12/09/2023	Azcapotzalco	43	46.2	43.4	49.1
13/09/2023	Azcapotzalco	67	46.1	43.3	48.9
14/09/2023	Azcapotzalco	51	39.1	36.3	41.9
15/09/2023	Azcapotzalco	20	32.8	29.9	35.6
16/09/2023	Azcapotzalco	5	25.5	22.7	28.3
17/09/2023	Azcapotzalco	5	23.6	20.8	26.4
18/09/2023	Azcapotzalco	36	33.9	31.1	36.7
19/09/2023	Azcapotzalco	22	41.4	38.6	44.2

Fuente: Elaboración propia

De acuerdo con el análisis de importancia de variables realizado mediante el algoritmo XGBoost, imperaron las comorbilidades. Adicionalmente el principal contaminante fue el dióxido de azufre (SO₂) con mayor asociación a los casos de COVID-19 en la alcaldía Azcapotzalco. Este compuesto, generado principalmente por procesos industriales y la quema de combustibles fósiles, posee un efecto nocivo comprobado sobre la salud

respiratoria, intensificando la gravedad de los cuadros clínicos en personas infectadas y aumentando la vulnerabilidad en grupos con comorbilidades preexistentes como el asma.

El análisis histórico muestra que, previo a la pandemia, durante el periodo 2009–2019, Azcapotzalco registró niveles elevados de exposición a SO₂. Esto implica que, tanto en la etapa previa como durante la crisis sanitaria, la población local estuvo sometida de forma continua a concentraciones significativas de este contaminante. La dinámica atmosférica de la zona, influida por vientos predominantes que transportan emisiones industriales hacia el territorio, refuerza la persistencia del problema y anticipa que, en ausencia de medidas de control, la exposición se mantendrá.

La interacción entre altos niveles de SO₂ y la transmisión viral intensificó el impacto del COVID-19 en Azcapotzalco, elevando el riesgo de complicaciones respiratorias y condicionando la dinámica local de contagio. La exposición prolongada a contaminantes como el dióxido de azufre actúa, por tanto, como un cofactor clave en la propagación y severidad de enfermedades respiratorias. La temperatura desempeñó un papel modulador en la dinámica de contagio, ya que las variaciones térmicas influyen tanto en la estabilidad del virus en el ambiente como en los comportamientos sociales y patrones de movilidad que favorecen o limitan la transmisión.

Alcaldía Coyoacán

En Coyoacán, el comportamiento del modelo fue más errático. El 4 de septiembre, la predicción (72.1) resultó inferior al valor real (91), superando este límite superior estimado. El 11 de septiembre se repitió esta tendencia, con un contagio real de 99 frente a una predicción de apenas 62.7. En los días con baja transmisión, como el 16 y 17, el modelo proyectó cifras más altas que las observadas. Esta discrepancia sugiere una capacidad limitada para captar variaciones rápidas o fenómenos atípicos en la dinámica de contagio.

La predicción osciló entre estimaciones precisas y desviaciones abruptas. El modelo no captó con precisión los valles bajos que ocurrieron en la segunda semana, y los márgenes resultaron insuficientes para contener los descensos. Este patrón se asocia a la heterogeneidad interna de la alcaldía, donde la estructura residencial y universitaria genera dinámicas distintas que el modelo trató como homogéneas.

Tabla 6 Alcaldía Coyoacán CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción Futura	Margen Superior	Margen Inferior
01/09/2023	Coyoacán	57	61.5	65.8	57.3
02/09/2023	Coyoacán	26	21.6	25.8	17.3
03/09/2023	Coyoacán	17	14.6	18.9	10.4
04/09/2023	Coyoacán	91	72.1	76.3	67.8
05/09/2023	Coyoacán	88	77.4	81.6	73.1
06/09/2023	Coyoacán	92	77.6	81.8	73.3
07/09/2023	Coyoacán	87	69.0	73.2	64.7
08/09/2023	Coyoacán	63	48.0	52.3	43.8
09/09/2023	Coyoacán	39	20.7	25.0	16.5
10/09/2023	Coyoacán	23	19.0	23.2	14.7
11/09/2023	Coyoacán	99	62.7	67.0	58.5
12/09/2023	Coyoacán	85	72.8	77.0	68.5
13/09/2023	Coyoacán	73	74.7	79.0	70.5
14/09/2023	Coyoacán	80	64.0	68.3	59.7
15/09/2023	Coyoacán	57	43.2	47.4	38.9
16/09/2023	Coyoacán	7	24.8	29.1	20.6
17/09/2023	Coyoacán	5	22.4	26.6	18.1
18/09/2023	Coyoacán	56	55.5	59.7	51.2
19/09/2023	Coyoacán	43	65.9	70.1	61.6

Fuente: Elaboración propia

Alcaldía Cuajimalpa

Durante todo el periodo analizado, los valores observados se mantuvieron dentro de los intervalos de confianza delimitados por los márgenes superior e inferior, sin registrarse desbordamientos. La diferencia máxima entre la predicción del modelo y los contagios reales fue de tres casos diarios como se muestra en la tabla 7, lo que representa un error mínimo en comparación con delegaciones de mayor densidad poblacional.

La dinámica epidemiológica en Cuajimalpa resulta más estable y menos volátil, lo que facilita su representación a través de modelos híbridos de predicción basados en series temporales como las CNN+LSTM. El análisis de variables explicativas mediante XGBoost indica que, si bien la hipertensión y la diabetes ocupan los primeros lugares de importancia en la Ciudad de México en general, en Cuajimalpa su peso es menor. Esta menor carga de comorbilidades en la población contribuye a que los contagios presenten trayectorias más suaves y sin oscilaciones abruptas, lo cual explica la mayor precisión del modelo.

En esta alcaldía destacó la influencia del monóxido de carbono (CO) como contaminante asociado a la dinámica de contagios. Este hallazgo se explica por la localización estratégica de Cuajimalpa como punto de tránsito de gran parte de la fuerza laboral proveniente de la zona metropolitana de Toluca y de otros municipios aledaños. El aforo vehicular en esta área es elevado debido a la conectividad carretera y la función de corredor entre el Valle de México y el Valle de Toluca, lo que incrementa las emisiones de CO y, con ello, su peso en el modelo predictivo.

Tabla 7 Alcaldía Cuajimalpa de Morelos CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
01/09/2023	Cuajimalpa	21	15.2	16.7	13.8
02/09/2023	Cuajimalpa	Sin dato	4.6	6.0	3.1
03/09/2023	Cuajimalpa	3	8.0	9.4	6.5
04/09/2023	Cuajimalpa	31	15.1	16.5	13.6
05/09/2023	Cuajimalpa	19	17.8	19.3	16.4
06/09/2023	Cuajimalpa	43	18.2	19.7	16.8
07/09/2023	Cuajimalpa	14	16.2	17.7	14.7
08/09/2023	Cuajimalpa	19	12.6	14.1	11.2
09/09/2023	Cuajimalpa	5	9.6	11.1	8.2
10/09/2023	Cuajimalpa	2	11.4	12.8	9.9
11/09/2023	Cuajimalpa	19	14.6	16.1	13.2
12/09/2023	Cuajimalpa	30	15.9	17.3	14.4
13/09/2023	Cuajimalpa	27	15.9	17.3	14.4
14/09/2023	Cuajimalpa	15	14.8	16.3	13.4
15/09/2023	Cuajimalpa	12	13.0	14.5	11.6
16/09/2023	Cuajimalpa	1	12.1	13.6	10.7
17/09/2023	Cuajimalpa	23	12.9	14.4	11.4
18/09/2023	Cuajimalpa	8	14.1	15.6	12.7
19/09/2023	Cuajimalpa	16	14.6	16.1	13.2

Fuente: Elaboración propia

Alcaldía Gustavo A. Madero

El desempeño del modelo CNN+LSTM resultó considerablemente más limitado en comparación con otras delegaciones periféricas como Cuajimalpa. Durante el periodo el modelo logró predecir correctamente los contagios dentro de los intervalos de confianza en 63 % de los días. En los casos restantes, particularmente en jornadas con repuntes abruptos, los valores reales superaron ampliamente el margen superior de predicción.

En la tabla 8 se muestra que los días con menor transmisión, fueron 2 y el 3 de septiembre, las predicciones se ajustaron de manera aceptable a los registros oficiales, lo que confirma que el modelo puede desempeñarse adecuadamente en contextos de estabilidad relativa. Sin embargo, frente a escenarios de variabilidad acelerada, su capacidad predictiva se redujo notablemente. En la alcaldía Gustavo A. Madero, la elevada prevalencia de diabetes mellitus y asma, combinada con la influencia indirecta de la humedad relativa sobre los contaminantes atmosféricos, configuró un entorno complejo para la propagación epidémica. Este conjunto de condiciones debilitó la resistencia de la población ante el virus y generó un contexto respiratorio más frágil, donde las variaciones ambientales intensificaron la exposición y favorecieron fluctuaciones abruptas en los contagios. Bajo estas circunstancias, el modelo CNN+LSTM no logró reproducir con exactitud los repuntes más pronunciados, ya que la interacción entre condiciones socioespaciales de la salud produjo una dinámica de transmisión menos predecible y más volátil.

Tabla 8 Alcaldía Gustavo A. Madero CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
01/09/2023	Gustavo A. Madero	72	66.0	71.3	60.7
02/09/2023	Gustavo A. Madero	19	13.8	19.1	8.4
03/09/2023	Gustavo A. Madero	9	13.3	18.7	8.0
04/09/2023	Gustavo A. Madero	111	69.9	75.2	64.6
05/09/2023	Gustavo A. Madero	93	78.0	83.3	72.7
06/09/2023	Gustavo A. Madero	106	92.8	98.2	87.5
07/09/2023	Gustavo A. Madero	76	80.7	86.0	75.4
08/09/2023	Gustavo A. Madero	74	51.4	56.7	46.1
09/09/2023	Gustavo A. Madero	22	18.0	23.3	12.6
10/09/2023	Gustavo A. Madero	18	19.9	25.3	14.6
11/09/2023	Gustavo A. Madero	95	52.8	58.1	47.5
12/09/2023	Gustavo A. Madero	98	67.9	73.2	62.6
13/09/2023	Gustavo A. Madero	111	83.0	88.4	77.7
14/09/2023	Gustavo A. Madero	77	68.6	74.0	63.3
15/09/2023	Gustavo A. Madero	31	43.3	48.6	38.0
16/09/2023	Gustavo A. Madero	6	25.5	30.8	20.2
17/09/2023	Gustavo A. Madero	8	24.0	29.4	18.7
18/09/2023	Gustavo A. Madero	78	41.6	46.9	36.2
19/09/2023	Gustavo A. Madero	68	54.2	59.6	48.9

Fuente: Elaboración propia

Alcaldía Iztacalco

El modelo logró mantener los valores reales dentro de los intervalos de confianza en aproximadamente el 74 % de los días, lo que refleja una capacidad predictiva aceptable. En los días con niveles bajos o moderados de transmisión, las predicciones se ajustaron de manera adecuada a los registros observados.

En la tabla 9 se muestra que las predicciones se mantuvieron dentro del margen la mayor parte del tiempo, aunque con una tendencia a sobrestimar los casos diarios. Esta característica es consistente con una curva de contagio aplanada en la realidad, que el modelo no logró recalibrar debido a su entrenamiento con picos previos. Aun así, las diferencias absolutas no fueron elevadas, lo que otorga al modelo un desempeño aceptable en esta demarcación.

Si bien las comorbilidades explicaron gran parte del comportamiento epidémico, las variables ambientales también desempeñaron un papel complementario. La humedad relativa representó un 1.14 % de importancia, mientras que el monóxido de carbono (CO) alcanzó 0.70 %, seguido del dióxido de nitrógeno (NO₂) con 0.53 %. Aunque sus porcentajes son bajos frente a las comorbilidades, en un contexto de sobrepoblación y movilidad intensiva, estas condiciones atmosféricas adquieren relevancia porque deterioran la salud respiratoria y potencian la vulnerabilidad de quienes padecen asma o enfermedades crónicas.

La alta densidad poblacional, prevalencia de tabaquismo y exposición a contaminantes configura un entorno donde la transmisión viral se intensifica y los contagios se vuelven menos predecibles. Por ello, el modelo CNN+LSTM logró un ajuste aceptable en periodos de estabilidad, pero presentó limitaciones claras en los días de repunte, cuando la interacción de factores clínicos y ambientales rebasó su capacidad predictiva.

Tabla 9 Alcaldía Iztacalco CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
01/09/2023	Iztacalco	38	24.9	27.5	22.4
02/09/2023	Iztacalco	9	10.4	12.9	7.9
03/09/2023	Iztacalco	6	17.7	20.2	15.2
04/09/2023	Iztacalco	46	39.1	41.6	36.6
05/09/2023	Iztacalco	49	38.6	41.1	36.1

06/09/2023	Iztacalco	39	36.7	39.2	34.2
07/09/2023	Iztacalco	35	30.9	33.4	28.4
08/09/2023	Iztacalco	56	22.1	24.6	19.6
09/09/2023	Iztacalco	17	17.3	19.8	14.8
10/09/2023	Iztacalco	12	22.6	25.1	20.1
11/09/2023	Iztacalco	66	37.8	40.3	35.3
12/09/2023	Iztacalco	45	39.0	41.5	36.5
13/09/2023	Iztacalco	47	34.1	36.6	31.6
14/09/2023	Iztacalco	39	28.3	30.8	25.8
15/09/2023	Iztacalco	24	25.4	27.9	22.9
16/09/2023	Iztacalco	3	22.9	25.4	20.4
17/09/2023	Iztacalco	3	25.2	27.7	22.7
18/09/2023	Iztacalco	30	35.7	38.2	33.2
19/09/2023	Iztacalco	36	36.1	38.6	33.6

Fuente: Elaboración propia

Alcaldía Iztapalapa

El modelo CNN+LSTM mostró un desempeño aceptable al mantener los valores reales dentro de los intervalos de confianza en cerca del 68 % de los días analizados. En escenarios de transmisión baja o moderada, las predicciones se ajustaron de manera adecuada, mientras que en los días de mayor número de contagios las estimaciones tendieron a ubicarse ligeramente por debajo de los valores observados. Esta característica muestra las condiciones propias de la alcaldía, marcada por su alta densidad poblacional y su papel como nodo de movilidad laboral y comercial en la Ciudad de México y a nivel metropolitano.

En Iztapalapa, el modelo CNN+LSTM consiguió representar de manera consistente la trayectoria general de los contagios. Aunque la magnitud de algunos incrementos no fue reflejada en su totalidad, la secuencia temporal prevista guardó correspondencia con el comportamiento observado. La Tabla 10 muestra cómo las proyecciones se mantuvieron en concordancia con los registros diarios, incluso dentro de un escenario urbano denso y de alta movilidad.

Tabla 10 Iztapalapa CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
31/08/2023	Iztapalapa	94	84.4	90.2	78.6

01/09/2023	Iztapalapa	72	93.8	99.6	88.0
02/09/2023	Iztapalapa	34	47.3	53.1	41.6
03/09/2023	Iztapalapa	31	32.7	38.5	26.9
04/09/2023	Iztapalapa	129	82.1	87.9	76.3
05/09/2023	Iztapalapa	107	76.2	82.0	70.5
06/09/2023	Iztapalapa	117	88.3	94.1	82.5
07/09/2023	Iztapalapa	122	69.3	75.1	63.5
08/09/2023	Iztapalapa	98	65.8	71.6	60.0
09/09/2023	Iztapalapa	35	45.4	51.2	39.6
10/09/2023	Iztapalapa	31	36.5	42.3	30.7
11/09/2023	Iztapalapa	184	58.5	64.3	52.7
12/09/2023	Iztapalapa	120	58.2	64.0	52.4
13/09/2023	Iztapalapa	115	64.4	70.1	58.6
14/09/2023	Iztapalapa	95	52.1	57.9	46.3
15/09/2023	Iztapalapa	72	48.4	54.2	42.7
16/09/2023	Iztapalapa	6	41.3	47.1	35.5
17/09/2023	Iztapalapa	21	35.4	41.2	29.6
18/09/2023	Iztapalapa	61	44.1	49.9	38.3
19/09/2023	Iztapalapa	71	46.6	52.4	40.8

Fuente: Elaboración propia

Alcaldía La Magdalena Contreras

En La Magdalena Contreras, el modelo CNN+LSTM alcanzó un nivel de ajuste notable, con los contagios reales ubicados dentro de los intervalos de confianza en aproximadamente el 87 % de los días analizados. Este desempeño sobresaliente responde a que la alcaldía presenta una dinámica epidemiológica más estable que otras zonas de la Ciudad de México, con series temporales de contagio sin picos abruptos ni variaciones extremas. La menor densidad poblacional, los flujos de movilidad reducidos hacia otras demarcaciones y la limitada centralidad laboral contribuyeron a un escenario de menor complejidad socioespacial, lo que permitió al modelo capturar con mayor fidelidad la evolución temporal de los casos.

De acuerdo con el modelo XGBoost la hipertensión arterial concentró el 61.50 % de la importancia relativa, seguida de la diabetes mellitus con 22.29 % y el asma con 2.91 %. Estos resultados revelan un perfil epidemiológico condicionado por comorbilidades crónicas, sobre todo de carácter cardiovascular y metabólico.

Tabla 11 Alcaldía La Magdalena Contreras CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
31/08/2023	La Magdalena Contreras	22	26.6	29.2	24.1
01/09/2023	La Magdalena Contreras	18	21.3	23.8	18.8
02/09/2023	La Magdalena Contreras	7	13.9	16.4	11.3
03/09/2023	La Magdalena Contreras	9	11.5	14.0	9.0
04/09/2023	La Magdalena Contreras	23	20.9	23.4	18.4
05/09/2023	La Magdalena Contreras	36	25.0	27.5	22.5
06/09/2023	La Magdalena Contreras	21	27.5	30.1	25.0
07/09/2023	La Magdalena Contreras	20	25.7	28.3	23.2
08/09/2023	La Magdalena Contreras	28	21.3	23.8	18.7
09/09/2023	La Magdalena Contreras	9	16.3	18.8	13.8
10/09/2023	La Magdalena Contreras	10	15.1	17.6	12.6
11/09/2023	La Magdalena Contreras	39	20.3	22.8	17.8
12/09/2023	La Magdalena Contreras	50	23.2	25.8	20.7
13/09/2023	La Magdalena Contreras	31	25.9	28.5	23.4
14/09/2023	La Magdalena Contreras	58	24.1	26.6	21.5
15/09/2023	La Magdalena Contreras	11	20.9	23.4	18.3
16/09/2023	La Magdalena Contreras	8	17.8	20.3	15.2
17/09/2023	La Magdalena Contreras	5	17.2	19.7	14.7
18/09/2023	La Magdalena Contreras	24	20.0	22.5	17.4
19/09/2023	La Magdalena Contreras	18	21.7	24.3	19.2

Fuente: Elaboración propia

Alcaldía Milpa Alta

La dinámica del modelo CNN+LSTM fue estable y precisa, los valores reales de contagio se mantuvieron dentro de los intervalos de confianza en aproximadamente el 90 % de los días analizados, lo que convierte a esta alcaldía en una de las que presentó mejor ajuste entre predicciones y registros oficiales. Este desempeño se asocia a las características socioespaciales propias de la alcaldía. Milpa Alta cuenta con la menor densidad poblacional de la ciudad, áreas rurales y una dinámica de movilidad reducida hacia el resto de la ciudad. Estas condiciones generaron series temporales con volúmenes bajos de contagio y sin picos abruptos, lo que facilitó que el modelo reprodujera con mayor exactitud la evolución de los casos.

En Milpa Alta la transmisión del virus siguió patrones más predecibles y de menor magnitud. Por ello, el CNN+LSTM logró ajustarse de manera casi lineal a la realidad observada, con márgenes de error reducidos y estabilidad en las proyecciones. La tabla 12

muestra cómo las predicciones se mantuvieron alineadas con los contagios reales durante la mayor parte del periodo analizado.

La presencia de enfermedades como la hipertensión, diabetes y asma en la población, evidencia la vulnerabilidad frente al virus y explica la relación estrecha entre los registros reales y las proyecciones del modelo. Sobresalieron las variables ambientales como la humedad relativa y la temperatura, que en conjunto superaron la influencia de partículas contaminantes. La alcaldía cuenta con territorio zonas boscosas, altitud elevada y microclimas que generan contrastes térmicos notorios. Estos factores actúan como moduladores del riesgo respiratorio, amplificando la importancia de la meteorología en comparación con la contaminación vehicular.

Tabla 12 Milpa Alta CNN+LSTM 01 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
01/09/2023	Milpa Alta	14	17.6	18.9	16.3
02/09/2023	Milpa Alta	5	13.1	14.4	11.9
03/09/2023	Milpa Alta	6	12.0	13.3	10.7
04/09/2023	Milpa Alta	24	12.6	13.8	11.3
05/09/2023	Milpa Alta	19	11.9	13.2	10.6
06/09/2023	Milpa Alta	28	14.7	16.0	13.5
07/09/2023	Milpa Alta	25	15.0	16.3	13.7
08/09/2023	Milpa Alta	13	15.7	17.0	14.4
09/09/2023	Milpa Alta	6	15.4	16.6	14.1
10/09/2023	Milpa Alta	32	15.9	17.2	14.6
11/09/2023	Milpa Alta	21	16.1	17.4	14.8
12/09/2023	Milpa Alta	11	16.1	17.4	14.9
13/09/2023	Milpa Alta	19	17.5	18.7	16.2
14/09/2023	Milpa Alta	9	17.9	19.2	16.7
15/09/2023	Milpa Alta	2	18.7	20.0	17.5
16/09/2023	Milpa Alta	5	19.1	20.4	17.9
17/09/2023	Milpa Alta	13	19.9	21.1	18.6
18/09/2023	Milpa Alta	6	20.4	21.6	19.1
19/09/2023	Milpa Alta	2	20.9	22.2	19.6

Fuente: Elaboración propia

Alcaldía Álvaro Obregón

El modelo CNN+LSTM logró mantener un nivel de precisión cercano al 78 % de los días analizados, lo que la coloca entre las delegaciones con desempeño intermedio. Sin

embargo, este resultado no puede entenderse sin considerar la particularidad del territorio aquí coexisten sectores de alta plusvalía inmersos en áreas boscosas con zonas de expansión urbana que conectan con la periferia de la ciudad. Esta dualidad introduce contrastes notables en la movilidad y en la exposición de la población, lo que explica por qué en ciertos periodos los contagios superaron el límite superior de los intervalos de predicción.

La Tabla 13 muestra cómo, a pesar de estas condiciones estructurales, el modelo consiguió representar la tendencia general de la epidemia en la alcaldía. El desempeño se benefició de la estabilidad relativa de los sectores de baja densidad, aunque se vio tensionado por los contrastes internos de un territorio donde conviven el bosque y el tránsito vehicular, la alta movilidad laboral y la vulnerabilidad respiratoria derivada de las comorbilidades. Según el análisis de XGBoost, el asma concentró el mayor peso explicativo con 38.00 %, seguido por la diabetes mellitus con 26.58 % y la hipertensión arterial con 14.29 %. Esta distribución refleja que las enfermedades respiratorias tuvieron un protagonismo superior al observado en otras demarcaciones, lo que explica las oscilaciones más abruptas en la serie temporal de contagios. La alcaldía concentra sectores residenciales de ingresos altos y medios, con mejores condiciones de acceso a servicios de salud y entornos menos hacinados. Eso se traduce en menor prevalencia de enfermedades crónicas graves en la población, los contaminantes como el PM₁₀ y el SO₂ adquieren mayor peso respecto a otras delegaciones, porque la estructura territorial (boscos en contraste con vialidades saturadas) redistribuye el peso explicativo hacia variables ambientales.

Tabla 13 Alcaldía Álvaro Obregón CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
31/08/2023	Álvaro Obregón		106.2	111.4	101.1
01/09/2023	Álvaro Obregón	70	71.9	77.1	66.8
02/09/2023	Álvaro Obregón	34	48.8	53.9	43.7
03/09/2023	Álvaro Obregón	23	41.9	47.1	36.8
04/09/2023	Álvaro Obregón	105	94.1	99.3	89.0
05/09/2023	Álvaro Obregón	109	92.0	97.1	86.8
06/09/2023	Álvaro Obregón	131	97.2	102.3	92.1
07/09/2023	Álvaro Obregón	99	88.0	93.1	82.9
08/09/2023	Álvaro Obregón	99	71.4	76.5	66.2
09/09/2023	Álvaro Obregón	42	56.9	62.0	51.8
10/09/2023	Álvaro Obregón	37	51.4	56.5	46.3

11/09/2023	Álvaro Obregón	124	89.3	94.4	84.2
12/09/2023	Álvaro Obregón	125	88.3	93.4	83.2
13/09/2023	Álvaro Obregón	115	91.9	97.0	86.8
14/09/2023	Álvaro Obregón	80	81.1	86.2	76.0
15/09/2023	Álvaro Obregón	41	71.1	76.2	66.0
16/09/2023	Álvaro Obregón	24	61.5	66.6	56.4
17/09/2023	Álvaro Obregón	23	58.1	63.2	53.0
18/09/2023	Álvaro Obregón	73	84.7	89.8	79.6
19/09/2023	Álvaro Obregón	66	85.2	90.3	80.1

Fuente: Elaboración propia

Alcaldía Tláhuac

El modelo CNN+LSTM alcanzó un nivel de ajuste satisfactorio, con los valores reales de contagio contenidos en los intervalos de confianza en aproximadamente el 81 % de los días analizados. Esto refleja un desempeño consistente, favorecido por una dinámica epidemiológica de menor complejidad que en las delegaciones centrales, aunque con ciertas oscilaciones vinculadas a episodios de transmisión comunitaria. Esto muestra que, aun cuando la dinámica local presentó oscilaciones, el algoritmo logró adaptarse y mantener estabilidad en las proyecciones. La mayor parte del tiempo, la diferencia absoluta entre valores reales y estimados fue reducida con diferencias promedio inferiores a 5 casos diarios, lo que otorga confianza en la utilidad del modelo como herramienta de análisis prospectivo en un territorio periférico con movilidad intermedia. La Tabla 14 ilustra cómo el CNN+LSTM mantuvo una capacidad aceptable para reproducir las variaciones en la transmisión, mostrando que, incluso en un contexto urbano complejo, la predicción no se desvió respecto a los registros oficiales.

Tabla 14 Tláhuac CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
01/09/2023	Tláhuac	28	18.9	20.8	16.9
02/09/2023	Tláhuac	5	9.9	11.9	8.0
03/09/2023	Tláhuac	3	12.4	14.3	10.5
04/09/2023	Tláhuac	24	22.7	24.6	20.7
05/09/2023	Tláhuac	28	21.5	23.4	19.6
06/09/2023	Tláhuac	28	28.0	29.9	26.0
07/09/2023	Tláhuac	27	25.6	27.5	23.6
08/09/2023	Tláhuac	26	20.0	21.9	18.0

09/09/2023	Tláhuac	4	17.4	19.3	15.4
10/09/2023	Tláhuac	2	18.9	20.8	17.0
11/09/2023	Tláhuac	44	22.3	24.2	20.4
12/09/2023	Tláhuac	22	21.9	23.9	20.0
13/09/2023	Tláhuac	32	26.9	28.8	25.0
14/09/2023	Tláhuac	25	23.8	25.8	21.9
15/09/2023	Tláhuac	10	22.2	24.1	20.3
16/09/2023	Tláhuac	2	22.1	24.1	20.2
17/09/2023	Tláhuac	1	22.8	24.8	20.9
18/09/2023	Tláhuac	25	22.6	24.6	20.7
19/09/2023	Tláhuac	14	22.3	24.3	20.4

Fuente: Elaboración propia

Alcaldía Tlalpan

En Tlalpan, la dinámica del modelo CNN+LSTM alcanzó un nivel alto de precisión, con los valores reales de contagio dentro de los intervalos de confianza en alrededor del 83 % de los días estudiados. Este resultado refleja la capacidad del modelo para ajustarse a un territorio con marcadas diferencias socioespaciales, donde conviven zonas urbanas de alta densidad con extensas áreas rurales y de conservación ecológica. Lejos de generar inconsistencias, esta diversidad territorial favoreció un ajuste más equilibrado entre predicciones y registros oficiales.

En los días donde los contagios oscilaron entre 20 y 45 casos diarios, el modelo logró un ajuste estrecho, con una diferencia media absoluta de apenas 3.7 casos respecto a los registros observados.

Tabla 15 Alcaldía Tlalpan CNN+LSTM 01al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
01/09/2023	Tlalpan	55	51.9	56.2	47.6
02/09/2023	Tlalpan	27	22.9	27.2	18.6
03/09/2023	Tlalpan	12	15.8	20.1	11.5
04/09/2023	Tlalpan	60	68.2	72.5	63.9
05/09/2023	Tlalpan	52	64.2	68.5	59.9
06/09/2023	Tlalpan	69	55.6	59.9	51.3
07/09/2023	Tlalpan	66	49.0	53.3	44.7
08/09/2023	Tlalpan	45	39.9	44.2	35.6
09/09/2023	Tlalpan	24	20.6	24.9	16.3
10/09/2023	Tlalpan	21	20.4	24.7	16.1

11/09/2023	Tlalpan	106	56.5	60.8	52.2
12/09/2023	Tlalpan	78	59.4	63.7	55.1
13/09/2023	Tlalpan	67	52.6	56.9	48.3
14/09/2023	Tlalpan	56	43.6	47.9	39.3
15/09/2023	Tlalpan	35	33.8	38.0	29.5
16/09/2023	Tlalpan	11	23.5	27.8	19.2
17/09/2023	Tlalpan	9	23.6	27.9	19.3
18/09/2023	Tlalpan	37	46.5	50.8	42.2
19/09/2023	Tlalpan	27	52.4	56.7	48.1

Fuente: Elaboración propia

Alcaldía Xochimilco

En la alcaldía Xochimilco, el modelo CNN+LSTM mostró un nivel de ajuste aceptable al mantener los valores reales dentro de los intervalos de confianza en 13 de los 19 días analizados (68.4 %). La precisión fue mayor en jornadas de alta transmisión, como el 1, 4, 11 y 18 de septiembre, cuando los contagios superaron los 40 casos diarios y las diferencias entre predicción y registros oficiales no excedieron el 8 %. Este comportamiento sugiere que el modelo reproduce con mayor fidelidad las dinámicas de contagio cuando la incidencia es elevada y presenta patrones más definidos. En contraste, en los días con menor número de contagios por debajo de los 10 casos diarios el modelo tendió a sobreestimar los registros. Esta tendencia indica que, en escenarios de baja incidencia, las proyecciones se ven influidas por la inercia de valores previos y pierden precisión. La Tabla 16 sintetiza esta dualidad un desempeño sólido en contextos de alta transmisión y un margen de error más amplio cuando la epidemia se expresó en niveles bajos.

Tabla 16 Alcaldía Xochimilco CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
01/09/2023	Xochimilco	40	44.9	47.8	42.0
02/09/2023	Xochimilco	9	15.8	18.7	13.0
03/09/2023	Xochimilco	3	11.5	14.3	8.6
04/09/2023	Xochimilco	42	42.5	45.4	39.7
05/09/2023	Xochimilco	32	39.8	42.6	36.9
06/09/2023	Xochimilco	25	49.1	52.0	46.2
07/09/2023	Xochimilco	28	43.8	46.7	41.0
08/09/2023	Xochimilco	34	35.8	38.7	33.0

09/09/2023	Xochimilco	6	21.7	24.6	18.9
10/09/2023	Xochimilco	4	20.5	23.4	17.7
11/09/2023	Xochimilco	44	43.9	46.8	41.1
12/09/2023	Xochimilco	25	39.0	41.9	36.1
13/09/2023	Xochimilco	21	48.4	51.3	45.5
14/09/2023	Xochimilco	19	41.5	44.3	38.6
15/09/2023	Xochimilco	11	36.2	39.1	33.4
16/09/2023	Xochimilco	6	27.3	30.1	24.4
17/09/2023	Xochimilco	5	27.5	30.4	24.7
18/09/2023	Xochimilco	18	41.5	44.3	38.6
19/09/2023	Xochimilco	11	38.4	41.3	35.6

Fuente: Elaboración propia, 2025

Alcaldía Benito Juárez

El modelo CNN+LSTM mantuvo los valores reales de contagio dentro de los intervalos de confianza en 11 de los días analizados (57.9 %), lo que refleja un desempeño intermedio frente a otras delegaciones. El ajuste fue más preciso en jornadas con incidencia moderada, como el 1 de septiembre, cuando los contagios reales se ubicaron en torno a los 30 casos y las diferencias con las predicciones no superaron el 8 %. Lo cual representa escenarios de transmisión estable, el modelo logra reproducir la dinámica temporal de manera aceptable.

Sin embargo, el modelo mostró limitaciones ante incrementos abruptos. Entre el 12 y 14 de septiembre y el 16 de septiembre, cuando el registro oficial reportó un solo caso y el modelo predijo más de 18, revelando un margen de error amplio en días de baja incidencia. Estas discrepancias confirman que el modelo responde de manera más consistente en contextos de transmisión intermedia, pero pierde precisión cuando la curva epidémica presenta extremos.

Tabla 17 Alcaldía Benito Juárez CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
31/08/2023	Benito Juárez	38	36.09	38.46	33.73
01/09/2023	Benito Juárez	29	26.01	28.37	23.65
02/09/2023	Benito Juárez	17	14.14	16.50	11.78
03/09/2023	Benito Juárez	12	17.23	19.60	14.87
04/09/2023	Benito Juárez	47	32.47	34.83	30.11
05/09/2023	Benito Juárez	39	31.19	33.56	28.83

06/09/2023	Benito Juárez	44	34.91	37.27	32.54
07/09/2023	Benito Juárez	35	27.21	29.57	24.85
08/09/2023	Benito Juárez	31	20.71	23.07	18.35
09/09/2023	Benito Juárez	26	16.91	19.27	14.54
10/09/2023	Benito Juárez	11	19.44	21.80	17.08
11/09/2023	Benito Juárez	42	27.44	29.80	25.07
12/09/2023	Benito Juárez	50	27.32	29.69	24.96
13/09/2023	Benito Juárez	53	27.21	29.58	24.85
14/09/2023	Benito Juárez	45	22.19	24.55	19.83
15/09/2023	Benito Juárez	27	19.79	22.15	17.43
16/09/2023	Benito Juárez	1	18.35	20.71	15.99
17/09/2023	Benito Juárez	7	19.83	22.19	17.46
18/09/2023	Benito Juárez	30	24.46	26.83	22.10
19/09/2023	Benito Juárez	16	24.06	26.42	21.70

Fuente: Elaboración propia, 2025

Alcaldía Cuauhtémoc

El desempeño del modelo mostró contrastes claros entre jornadas de transmisión elevada y escenarios de baja incidencia. Durante los días 4, 5, 6 y 7 de septiembre, cuando los contagios reales oscilaron entre 45 y 64 casos diarios, las predicciones del modelo se alinearon con notable exactitud a los registros oficiales, con diferencias menores al 7 %. En estas fechas, el intervalo de confianza contuvo los valores reales de manera precisa, lo que revela que el modelo alcanzó su mayor capacidad de ajuste frente a series estables y de magnitud intermedia a alta.

Tabla 18 Alcaldía Cuauhtémoc CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
01/09/2023	Cuauhtémoc	60	41	44.4	37.6
02/09/2023	Cuauhtémoc	7	15.8	19.2	12.3
03/09/2023	Cuauhtémoc	8	29.6	33	26.2
04/09/2023	Cuauhtémoc	64	61.7	65.1	58.3
05/09/2023	Cuauhtémoc	60	64.2	67.6	60.8
06/09/2023	Cuauhtémoc	64	56.2	59.6	52.8
07/09/2023	Cuauhtémoc	45	48	51.4	44.6
08/09/2023	Cuauhtémoc	50	33.1	36.6	29.7
09/09/2023	Cuauhtémoc	12	25.6	29	22.2
10/09/2023	Cuauhtémoc	16	33.9	37.3	30.5
11/09/2023	Cuauhtémoc	98	53.9	57.3	50.5
12/09/2023	Cuauhtémoc	58	53.9	57.3	50.5

13/09/2023	Cuauhtémoc	68	46.4	49.8	42.9
14/09/2023	Cuauhtémoc	66	37.6	41	34.1
15/09/2023	Cuauhtémoc	21	34.1	37.5	30.7
16/09/2023	Cuauhtémoc	6	29.4	32.8	26
17/09/2023	Cuauhtémoc	7	33.5	36.9	30
18/09/2023	Cuauhtémoc	53	43.9	47.3	40.5
19/09/2023	Cuauhtémoc	41	42.2	45.6	38.8

Fuente: Elaboración propia, 2025

Alcaldía Miguel Hidalgo

El modelo CNN+LSTM alcanzó su mayor nivel de precisión durante la semana epidemiológica comprendida entre el 31 de agosto y el 8 de septiembre. En este periodo, los valores reales de contagio se mantuvieron en un rango de 12 a 35 casos diarios, mientras que las predicciones se alinearon con dichos registros, mostrando diferencias absolutas inferiores a 3 casos y conservándose dentro de los intervalos de confianza establecidos. Esta dinámica reproduce la dinámica de transmisión local cuando la incidencia se mantuvo en niveles moderados, consolidándose como un recurso confiable para el seguimiento temporal de los contagios en contextos de estabilidad epidemiológica.

Tabla 19 Alcaldía Cuauhtémoc CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
31/08/2023	Miguel Hidalgo	30	29.5	31.2	27.1
01/09/2023	Miguel Hidalgo	11	24.5	26.6	22.4
02/09/2023	Miguel Hidalgo	12	10.5	12.6	8.4
03/09/2023	Miguel Hidalgo	8	12.6	14.7	10.5
04/09/2023	Miguel Hidalgo	26	32.7	34.8	30.6
05/09/2023	Miguel Hidalgo	28	28.5	30.5	26.4
06/09/2023	Miguel Hidalgo	35	33.3	35.4	31.2
07/09/2023	Miguel Hidalgo	21	27.4	29.5	25.4
08/09/2023	Miguel Hidalgo	21	19.3	21.4	17.2
09/09/2023	Miguel Hidalgo	5	12.3	14.4	10.3
10/09/2023	Miguel Hidalgo	2	15	17.1	12.9
11/09/2023	Miguel Hidalgo	53	26.9	29	24.8
12/09/2023	Miguel Hidalgo	33	24.5	26.5	22.4
13/09/2023	Miguel Hidalgo	38	27.9	30	25.8
14/09/2023	Miguel Hidalgo	31	21.7	23.8	19.6
15/09/2023	Miguel Hidalgo	7	16.1	18.1	14
16/09/2023	Miguel Hidalgo	3	13.3	15.4	11.2

17/09/2023	Miguel Hidalgo	5	15.6	17.7	13.5
18/09/2023	Miguel Hidalgo	19	22	24.1	19.9
19/09/2023	Miguel Hidalgo	22	20.4	22.5	18.3

Fuente: Elaboración propia, 2025

Alcaldía Venustiano Carranza

El modelo logró captar la tendencia general descendente de los contagios en el periodo analizado y mantuvo una buena capacidad de ajuste en los días de baja y moderada transmisión. Las proyecciones estuvieron dentro o muy cerca de los intervalos de confianza, sobre todo cuando los contagios reales no superaron los 20 casos diarios. Esto significa que, aunque el modelo tuvo limitaciones para reproducir los picos abruptos (como el 11 y 13 de septiembre), sí consiguió representar con precisión los escenarios más frecuentes de contagio en la alcaldía, que fueron días con volúmenes bajos o moderados.

Tabla 20 Alcaldía Venustiano Carranza CNN+LSTM 01 al 15 de septiembre 2023

Fecha	Municipio	Contagios reales	Predicción CNN+LSTM	Margen superior	Margen inferior
31/08/2023	Venustiano Carranza	35	31.1	33.7	28.5
01/09/2023	Venustiano Carranza	31	24	26.6	21.4
02/09/2023	Venustiano Carranza	9	7	9.6	4.4
03/09/2023	Venustiano Carranza	8	5.2	7.8	2.7
04/09/2023	Venustiano Carranza	35	32.2	34.7	29.6
05/09/2023	Venustiano Carranza	30	32.4	35	29.8
06/09/2023	Venustiano Carranza	39	27.2	29.8	24.7
07/09/2023	Venustiano Carranza	20	24.7	27.3	22.1
08/09/2023	Venustiano Carranza	33	19.3	21.9	16.7
09/09/2023	Venustiano Carranza	8	6.7	9.2	4.1
10/09/2023	Venustiano Carranza	5	5.9	8.5	3.3
11/09/2023	Venustiano Carranza	37	22.4	25	19.8
12/09/2023	Venustiano Carranza	36	24.7	27.3	22.2
13/09/2023	Venustiano Carranza	46	21.3	23.9	18.7
14/09/2023	Venustiano Carranza	34	19	21.5	16.4
15/09/2023	Venustiano Carranza	16	14.4	17	11.8
16/09/2023	Venustiano Carranza	11	6.7	9.3	4.2
17/09/2023	Venustiano Carranza	4	6.6	9.2	4
18/09/2023	Venustiano Carranza	17	16	18.6	13.4
19/09/2023	Venustiano Carranza	17	18.7	21.3	16.1

Fuente: Elaboración propia, 2025

De acuerdo con los resultados obtenidos, las delegaciones con mayor complejidad epidemiológica fueron Iztapalapa, Gustavo A. Madero, Coyoacán, Iztacalco y Venustiano Carranza mostraron una dinámica de contagios con picos abruptos. Esto se debe a que estas delegaciones concentran grandes flujos de población, centralidad laboral y redes de transporte, factores que multiplican las oportunidades de transmisión viral y dificultan la predicción matemática de la curva epidémica.

En la Tabla 21 se presenta la evaluación del modelo del modelo CNN+LSTM y los resultados de Mean Absolute Error (MAE), Mean Squared Error (MSE) y Root Mean Squared Error (RMSE).

Tabla 21 Evaluación del modelo del modelo CNN+LSTM

Municipio	Mean Absolute Error (MAE)	Mean Squared Error (MSE)	Root Mean Squared Error (RMSE)
Azcapotzalco	15.90	553.28	23.52
Coyoacán	23.08	1262.70	35.53
Cuajimalpa	8.40	143.66	11.99
Gustavo A. Madero	28.61	1955.09	44.22
Iztacalco	14.46	450.61	21.23
Iztapalapa	32.37	2334.62	48.32
La Magdalena Contreras	14.74	447.30	21.15
Milpa Alta	7.43	110.60	10.52
Álvaro Obregón	28.55	1816.97	42.63
Tláhuac	10.75	255.61	15.99
Tlalpan	24.14	1290.84	35.93
Xochimilco	15.65	570.14	23.88
Benito Juárez	13.67	388.12	19.70
Cuauhtémoc	19.16	812.26	28.50
Miguel Hidalgo	11.21	299.11	17.29
Venustiano Carranza	13.93	471.92	21.72

Importancia relativa de condicionantes de salud y ambientales en la predicción de contagios por COVID-19 con XGBoost

El modelo XGBoost permitió estimar la relevancia de un conjunto de variables en la predicción de contagios de COVID-19 en la Ciudad de México. Los resultados mostraron que las comorbilidades crónicas aportaron el mayor peso explicativo en todas las delegaciones, mientras que los factores meteorológicos y los contaminantes atmosféricos conservaron valores reducidos dentro del esquema predictivo como se muestra en la tabla 21.

Las enfermedades cardiovasculares y metabólicas concentraron la mayor proporción de importancia relativa. La hipertensión arterial se posicionó como el predictor principal en nueve delegaciones, con valores superiores a 40% en Gustavo A. Madero (40.6%), Iztacalco (46.8%), Iztapalapa (57.1%), Tláhuac (59.1%) y Coyoacán (39.7%). De forma complementaria, la diabetes mellitus adquirió mayor relevancia en Cuajimalpa (51.1%), Benito Juárez (60.2%), Cuauhtémoc (25.5%) y Venustiano Carranza (26.6%). Estas cifras muestran que las comorbilidades de metabólicas se distribuyen territorialmente de manera desigual y condicionan la magnitud de los contagios en áreas de alta densidad urbana.

En delegaciones específicas se presentaron patrones distintos. En Azcapotzalco, el asma alcanzó un peso de 38%, mientras que en Coyoacán representó el 29.1%. En Iztacalco, el tabaquismo ocupó el primer lugar con 46.8%, seguido por Magdalena Contreras (14.7%) y Álvaro Obregón (14.9%). Estos resultados indican que, en determinados contextos locales, los padecimientos respiratorios y los hábitos de riesgo como el tabaquismo aportaron una señal predictiva diferenciada respecto a la hipertensión o la diabetes.

La obesidad mostró un valor atípicamente elevado en Azcapotzalco (30.5%), y no se consolidó como una variable predictora dominante. La enfermedad renal crónica mantuvo proporciones inferiores al 2% en la mayoría de las delegaciones, lo que indica un efecto explicativo inferior en el modelo.

Los factores ambientales mostraron una contribución sistemática inferior. Variables como la temperatura, la humedad relativa, el monóxido de carbono (CO), el ozono (O₃) y el material particulado (PM₁₀ y PM_{2.5}) se mantuvieron por debajo del 1.5% en todos los casos. Aunque no alcanzaron un peso principal, su presencia constante sugiere posibles

interacciones sinérgicas con las condiciones crónicas de salud, especialmente en territorios con exposición acumulativa a contaminación atmosférica.

Los resultados revelan una diferenciación geográfica en la incidencia de factores de riesgo. En el oriente de la ciudad (Iztapalapa, Iztacalco, Tláhuac, Milpa Alta) predominó la hipertensión como predictor central, lo que refleja el peso de la población adulta mayor. En el centro y poniente (Benito Juárez, Cuajimalpa, Cuauhtémoc) la diabetes emergió como el factor predictivo más significativo, que se asocia con estilos de vida urbanos caracterizados por sedentarismo y alta prevalencia de sobrepeso. En alcaldías como Azcapotzalco, Álvaro Obregón y la alcaldía Magdalena Contreras, adquirieron mayor peso el asma y el tabaquismo, posiblemente vinculados con gradientes ambientales, heterogeneidad en la ocupación del suelo y proximidad a fuentes puntuales de contaminación de origen industrial.

La tabla 22 se presenta los resultados de evaluación del modelo XGBoost aplicado de manera individual a cada alcaldía de la Ciudad de México, con el propósito de predecir los casos diarios de contagios por COVID-19. Para cada demarcación se realizó un proceso de optimización de hiperparámetros mediante validación cruzada, a fin de identificar la configuración que ofreciera el mejor equilibrio entre ajuste y capacidad de generalización del modelo. Se reportan las métricas de desempeño clave: el Error Absoluto Medio (MAE), la Raíz del Error Cuadrático Medio (RMSE) y el Coeficiente de Determinación (R^2), tanto en los conjuntos de entrenamiento como en los subconjuntos de validación cruzada. Asimismo, se incluye el porcentaje que representa el MAE respecto a la media de contagios, el número total de registros utilizados y el valor promedio de casos diarios por municipio. Estos indicadores permiten establecer comparaciones entre territorios y evaluar la precisión predictiva del modelo en función de las condiciones locales del fenómeno epidemiológico.

Tabla 22 Importancia relativa de variables en la predicción de contagios de COVID-19 por alcaldía en la Ciudad de México, estimada con XGBoost

Municipio	Respiratorias				Cardiovasculares y metabólicas				Factores meteorológicos		Gases contaminantes						Material particulado (PM)	
	Asma	Enfermedad Pulmonar Obstructiva Crónica	Tabaquismo	Neumonía	Diabetes	Hipertensión	Obesidad	Renal crónica	Temperatura	Humedad relativa	Monóxido de carbono (CO)	Óxido de nitrógeno (NO)	Dióxido de nitrógeno (NO ₂)	Óxidos de nitrógeno (Nox)	Ozono (O ₃)	Dióxido de azufre (SO ₂)	Partículas PM ₁₀	Partículas PM ₂₅
Azcapotzalco	9.55%	0.28%	8.35%	1.30%	5.86%	40.66%	30.56%	0.56%	0.22%	0.27%	0.16%	0.25%	0.36%	0.21%	0.47%	0.50%	0.19%	0.23%
Coyoacán	29.18%	0.19%	12.98%	0.84%	14.06%	39.67%	0.67%	0.21%	0.20%	0.31%	0.21%	0.16%	0.21%	0.35%	0.15%	0.19%	0.27%	0.15%
Cuajimalpa	4.16%	1.21%	2.66%	1.65%	26.67%	51.18%	2.67%	1.40%	0.95%	0.82%	1.23%	0.80%	0.83%	0.68%	0.74%	0.76%	0.90%	0.69%
Gustavo A. Madero	21.14%	0.16%	6.18%	0.90%	60.26%	8.60%	1.23%	0.14%	0.14%	0.23%	0.15%	0.13%	0.13%	0.13%	0.12%	0.14%	0.13%	0.10%
Iztacalco	5.67%	0.46%	46.81%	1.44%	10.23%	26.33%	1.69%	1.89%	0.49%	1.14%	0.70%	0.45%	0.43%	0.38%	0.52%	0.47%	0.53%	0.36%
Iztapalapa	11.96%	0.20%	7.99%	0.66%	50.16%	25.03%	1.87%	1.04%	0.15%	0.20%	0.17%	0.10%	0.05%	0.06%	0.08%	0.10%	0.11%	0.06%
La Magdalena Contreras	2.91%	0.65%	2.37%	2.45%	22.29%	61.50%	1.82%	0.75%	0.41%	0.38%	0.55%	0.40%	0.60%	0.55%	0.64%	0.55%	0.67%	0.49%
Milpa Alta	3.98%	0.39%	1.42%	0.74%	28.86%	57.16%	1.26%	0.88%	0.93%	0.93%	0.45%	0.42%	0.45%	0.46%	0.39%	0.33%	0.42%	0.51%
Álvaro Obregón	38.00%	0.51%	8.23%	1.44%	26.58%	14.29%	6.82%	0.30%	0.21%	0.32%	0.21%	0.16%	0.30%	0.52%	0.38%	0.59%	0.80%	0.33%
Tláhuac	1.20%	0.16%	14.72%	0.28%	20.42%	59.10%	1.87%	0.18%	0.30%	0.30%	0.15%	0.16%	0.14%	0.18%	0.21%	0.24%	0.25%	0.14%
Tlalpan	8.62%	0.29%	15.90%	0.64%	17.73%	52.80%	1.69%	0.31%	0.23%	0.30%	0.14%	0.16%	0.17%	0.21%	0.20%	0.24%	0.22%	0.15%
Xochimilco	3.95%	0.15%	1.40%	0.82%	39.07%	46.86%	5.75%	0.15%	0.15%	0.44%	0.15%	0.17%	0.17%	0.20%	0.12%	0.14%	0.19%	0.11%
Benito Juárez	5.06%	0.38%	21.06%	1.16%	22.81%	41.95%	2.32%	0.49%	0.46%	0.52%	0.46%	0.36%	0.48%	0.55%	0.37%	0.63%	0.54%	0.41%
Cuauhtémoc	9.89%	0.23%	7.13%	1.34%	25.54%	49.06%	3.84%	0.31%	0.20%	0.39%	0.28%	0.26%	0.22%	0.29%	0.23%	0.30%	0.24%	0.24%
Miguel Hidalgo	8.65%	0.23%	16.51%	1.08%	20.31%	43.59%	6.95%	0.21%	0.23%	0.32%	0.27%	0.24%	0.18%	0.23%	0.26%	0.25%	0.30%	0.19%
Venustiano Carranza	2.43%	1.34%	8.69%	3.83%	26.67%	46.10%	0.85%	0.90%	0.59%	1.00%	1.36%	0.90%	0.56%	0.98%	0.91%	0.89%	1.45%	0.57%

Fuente: Elaboración propia, 2025

Tabla 23 Evaluación del modelo XGBoost por alcaldía

Clave MUN	Hiperparámetros	MAE	RMSE	R2	MAE CV	RMSE CV	R2 CV	MAE % sobre media	Registros utilizados	Media contagios
9002	{'subsample': 0.8, 'reg_lambda': 10, 'reg_alpha': 0, 'n_estimators': 500, 'max_depth': 7, 'learning_rate': 0.05, 'gamma': 1, 'colsample_bytree': 0.8}	34.18	58.89	0.95	37.51	72.99	0.92	17.43	1516	196.02
9003	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 0, 'n_estimators': 1500, 'max_depth': 10, 'learning_rate': 0.01, 'gamma': 5, 'colsample_bytree': 0.8}	41.16	69.01	0.96	44.23	76.44	0.95	14.94	1585	275.52
9004	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 0, 'n_estimators': 1000, 'max_depth': 5, 'learning_rate': 0.05, 'gamma': 0, 'colsample_bytree': 1.0}	32.64	53.01	0.79	33.22	52.62	0.81	34.49	1431	94.64
9005	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 1, 'n_estimators': 1500, 'max_depth': 5, 'learning_rate': 0.01, 'gamma': 0, 'colsample_bytree': 1.0}	68.41	138.44	0.96	62.95	116.89	0.97	13.79	1589	496.08
9006	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 0, 'n_estimators': 1000, 'max_depth': 5, 'learning_rate': 0.01, 'gamma': 5, 'colsample_bytree': 0.8}	31.40	55.76	0.95	32.24	57.26	0.94	17.76	1550	176.79
9007	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 0, 'n_estimators': 1000, 'max_depth': 5, 'learning_rate': 0.05, 'gamma': 5, 'colsample_bytree': 1.0}	77.00	134.97	0.98	77.40	142.85	0.98	12.02	1588	640.50
9008	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 0, 'n_estimators': 1500, 'max_depth': 10, 'learning_rate': 0.01, 'gamma': 0, 'colsample_bytree': 1.0}	53.91	91.48	0.82	50.99	86.45	0.83	33.50	1502	160.93
9009	{'subsample': 1.0, 'reg_lambda': 10, 'reg_alpha': 0.1, 'n_estimators': 1000, 'max_depth': 5, 'learning_rate': 0.01, 'gamma': 5, 'colsample_bytree': 0.8}	25.17	42.29	0.84	25.98	44.38	0.88	26.29	1482	95.74
9010	{'subsample': 0.8, 'reg_lambda': 5, 'reg_alpha': 0.1, 'n_estimators': 1000, 'max_depth': 5, 'learning_rate': 0.01, 'gamma': 5, 'colsample_bytree': 1.0}	81.19	145.80	0.94	77.74	151.06	0.94	19.68	1586	412.56
9011	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 0, 'n_estimators': 1000, 'max_depth': 7, 'learning_rate': 0.01, 'gamma': 0, 'colsample_bytree': 0.8}	32.36	65.27	0.96	30.00	56.23	0.96	16.97	1509	190.68
9012	{'subsample': 0.8, 'reg_lambda': 10, 'reg_alpha': 0.1, 'n_estimators': 500, 'max_depth': 7, 'learning_rate': 0.05, 'gamma': 1, 'colsample_bytree': 0.8}	53.21	93.47	0.95	50.25	89.13	0.95	16.84	1585	315.97
9013	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 1, 'n_estimators': 500, 'max_depth': 7, 'learning_rate': 0.05, 'gamma': 1, 'colsample_bytree': 1.0}	39.05	72.58	0.94	38.63	69.64	0.95	17.60	1565	221.84
9014	{'subsample': 0.8, 'reg_lambda': 5, 'reg_alpha': 1, 'n_estimators': 1000, 'max_depth': 5, 'learning_rate': 0.01, 'gamma': 0, 'colsample_bytree': 0.8}	32.34	51.00	0.93	34.19	55.86	0.93	18.29	1565	176.83
9015	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 0.1, 'n_estimators': 1500, 'max_depth': 5, 'learning_rate': 0.01, 'gamma': 1, 'colsample_bytree': 0.8}	42.84	68.40	0.96	42.95	68.80	0.96	16.99	1550	252.17
9016	{'subsample': 0.8, 'reg_lambda': 5, 'reg_alpha': 0, 'n_estimators': 1500, 'max_depth': 5, 'learning_rate': 0.01, 'gamma': 1, 'colsample_bytree': 0.8}	31.01	49.93	0.94	27.72	44.65	0.94	20.72	1478	149.66
9017	{'subsample': 0.8, 'reg_lambda': 1, 'reg_alpha': 0, 'n_estimators': 1500, 'max_depth': 7, 'learning_rate': 0.01, 'gamma': 1, 'colsample_bytree': 1.0}	66.47	127.32	0.86	66.51	115.08	0.86	27.32	1519	243.33

Fuente: Elaboración propia, 2025

Conclusiones

El modelo permitió evidenciar que la propagación del COVID-19 en la Ciudad de México no siguió una lógica homogénea, sino que cada alcaldía presentó dinámicas epidemiológicas distintas, influenciadas por condiciones como la calidad del aire y condiciones meteorológicas. Esta heterogeneidad justificó la necesidad de hiperparámetros específicos por territorio, cumpliendo así con el objetivo de explicar las diferencias geográficas en la prevalencia de contagios y evaluar la variabilidad espacial en el ajuste de los parámetros del modelo.

Asimismo, el modelo aportó una herramienta operativa valiosa para la anticipación epidemiológica a nivel local, aunque con limitaciones para detectar extremos. La inclusión de márgenes de predicción y la identificación de asimetrías según la escala poblacional contribuyeron a generar escenarios diferenciados por alcaldía, fortaleciendo la toma de decisiones territorializadas. Esto confirma que el modelo cumple con su objetivo al ofrecer una base técnica sólida para priorizar intervenciones sanitarias estratégicas en función de patrones espaciales observados.

El análisis documental y metodológico evidencia que el diseño e implementación de un modelo espacial basado en Inteligencia Artificial fue coherente con lo planteado en la hipótesis de investigación. A lo largo del estudio, se construyó un marco teórico-conceptual sólido que integró factores de la geografía, la geografía de la salud y las geotecnologías, con énfasis en los condicionantes socioespaciales que influyen en la propagación del COVID-19. Se seleccionaron e incorporaron variables meteorológicas, contaminación del aire, y comorbilidades, para entrenar el modelo predictivo. La arquitectura híbrida CNN+LSTM fue elegida por su capacidad para capturar dinámicas espacio-temporales a escala de días, mostrando el menor error absoluto medio ($MAE = 7.43$), lo que evidencia su alta precisión y confiabilidad para modelar las seis curvas epidemiológicas entre 2020 y 2023. Este modelo se fundamentó en la incorporación de condicionantes socioespaciales de la salud, lo que permitió generar conocimiento técnico con un enfoque innovador, útil para construir una sociedad más resiliente ante futuras emergencias sanitarias.

Los factores ambientales y los condicionantes de salud influyeron de manera diferenciada en la propagación del virus, y dicha influencia mostró variabilidad significativa entre las distintas alcaldías. Esta heterogeneidad territorial evidenció la necesidad de respuestas localizadas, basadas en evidencia científica y ajustadas a las características específicas de cada contexto urbano.

A partir del análisis del marco teórico-conceptual del estudio, se concluye que los enfoques tradicionales en salud pública provenientes de disciplinas como la medicina, la sociología o la epidemiología resultan limitados para explicar fenómenos sanitarios complejos en contextos urbanos contemporáneos, debido a que omiten o subestiman la dimensión territorial que engloba casos de contagio por COVID-19, meteorología y calidad del aire. En este sentido, se adopta la conceptualización de los condicionantes socioespaciales de la salud (CSS), entendidos como condiciones territoriales que influyen, sin determinar de manera absoluta, las condiciones sanitarias de la población. Esta perspectiva reconoce la incertidumbre inherente a los sistemas sociales y a la heterogeneidad de los territorios, haciendo necesaria la superación de visiones lineales.

La propuesta central del marco es el concepto de "geointercalación epidemiológica", el cual plantea que la vulnerabilidad sanitaria en entornos urbanos, como la Ciudad de México, surge de la interacción simultánea y acumulativa de múltiples factores sociales, ambientales, económicos y de salud dentro de un mismo territorio. Esta noción exige la adopción de un modelo teórico integral y dinámico que reconozca las interrelaciones espacio-temporales de dichos factores. Para abordar esta complejidad, se requiere del uso de geotecnologías y herramientas de Inteligencia Artificial, como el aprendizaje automático y profundo, que permiten procesar grandes volúmenes de información, identificar patrones no lineales y generar modelos predictivos robustos. El marco teórico no solo delimita un enfoque geográfico innovador, sino que fundamenta conceptualmente la necesidad de integrar inteligencia espacial y computacional para el análisis y anticipación de eventos epidemiológicos en contextos urbanos dinámicos.

La metodología basada en modelos de Inteligencia Artificial permitió construir un sistema predictivo capaz de estimar contagios de COVID-19 a corto plazo (dos semanas epidemiológicas) en la Ciudad de México. El modelo híbrido CNN+LSTM demostró un alto

desempeño al alcanzar un MAE de 7.43, posicionándose como el más preciso entre los evaluados. Este resultado se logró mediante la incorporación exclusiva de variables dinámicas como los casos diarios de contagio y los niveles de contaminación atmosférica y meteorologías, los cuales presentaron variabilidad suficiente para modelar la evolución espacio-temporal del virus con adecuada sensibilidad. En contraste, variables de carácter estructural o estático, como marginación, uso de suelo o nivel educativo, no fueron útiles para la predicción semanal, dada su baja variación en el tiempo.

Asimismo, el modelo XGBoost complementó el análisis al permitir la identificación de los factores ambientales y comorbilidades que tiene mayor peso en la propagación del virus, revelando una asociación directa entre estilos de vida y episodios de mala calidad del aire y aumentos en los contagios. Este enfoque permitió comprender las condiciones que favorecen la expansión del virus en contextos urbanos densos y complejos. Es importante destacar que los datos de enfermedades respiratorias infecciosas previas a la pandemia (2009–2019) no fueron útiles para realizar la predicción en los primeros meses de la pandemia, debido a que representaban patrones cíclicos no comparables con la dinámica atípica y disruptiva del COVID-19. Por tanto, los modelos desarrollados responden de manera precisa a las particularidades epidemiológicas del periodo 2020–2023, consolidándose como herramientas clave para la anticipación y toma de decisiones en salud pública.

Conclusiones de resultados

De acuerdo con los datos históricos previos a COVID-19, el estudio evidenció una marcada diferencia entre los patrones de enfermedades respiratorias previas a la pandemia (2009–2019) y la dinámica atípica del COVID-19. Mientras que las enfermedades respiratorias presentaban una dinámica cíclica y de menor magnitud, la pandemia se caracterizó por una expansión exponencial. Esta diferencia explica por qué se decidió entrenar el modelo solo con datos del periodo de la pandemia. Los datos anteriores al COVID-19 no representaban una dinámica excepcional del virus, por lo que no eran adecuados para predecir su propagación. Aunque no se descartaron de forma explícita, los resultados del estudio confirman que era necesario usar información específica del contexto pandémico para obtener predicciones precisas.

En cuanto a las variables consideradas, el estudio integró una amplia gama de condicionantes socioespaciales, aunque el análisis de resultados mostró mejores resultados con comorbilidades asociadas al COVID-19 y con variables de carácter dinámico, como temperatura, humedad, y contaminación atmosférica (PM_{2.5}, PM₁₀, O₃, CO, NO_x).

Se identificó que la hipertensión arterial representó la comorbilidad con mayor peso en la incidencia de contagios en prácticamente todas las delegaciones, seguida de la diabetes mellitus y, en menor proporción, el asma y el tabaquismo. Un hallazgo relevante es que estas condiciones de salud rara vez se presentaron de manera aislada; por el contrario, se presentó un patrón de coexistencia, en el que la tríada hipertensión-diabetes-obesidad se configuró como una condición de riesgo recurrente en la población afectada. De manera menos convencional, el tabaquismo, mostró también una relación significativa con los contagios, lo que refuerza su papel como elemento agravante en la vulnerabilidad respiratoria y en la propagación viral.

Los contaminantes asociados a la movilidad vehicular presentaron pesos significativos, mientras que otros, como las partículas finas, mostraron efectos más retardados, asociados a exposición acumulativa. Además, se identificó que la exposición crónica a condiciones atmosféricas durante etapas tempranas de vida podría aumentar la vulnerabilidad ante el COVID-19 en etapas posteriores.

El análisis espacio-temporal, además, puede ajustarse a diferentes periodos de observación, como fases epidémicas, implementación de políticas públicas, aparición de variantes virales, semanas epidemiológicas, días festivos o fines de semana. Las series temporales utilizadas son algoritmos finitos cuya efectividad depende del ajuste preciso de sus parámetros conforme avanza la pandemia. Por ello, es indispensable contar con datos de alta calidad, que reflejen adecuadamente la dinámica diaria de los contagios.

Agenda de investigación

- Actualizar los modelos predictivos con datos de entrenamiento ampliados hasta el año 2025, incorporando tanto casos de COVID-19 como enfermedades respiratorias infecciosas en conjunto.

- Desarrollar estudios con enfoque interseccional, desagregados por género y grupos etarios, para identificar patrones diferenciados de vulnerabilidad y exposición.
- Implementar modelos híbridos avanzados que integren redes neuronales convolucionales (CNN), máquinas de vectores de soporte (SVM) y arquitecturas tipo Transformers, con el fin de mejorar la precisión y especificidad temporal y espacial de las predicciones.
- Analizar los cambios de parámetros epidemiológicos a lo largo del tiempo, y su dinámica diferencial por sexo, edad y zona geográfica.
- Evaluar la calidad de las bases de datos oficiales, tales como las provistas por la Dirección General de Epidemiología y el INEGI, en cuanto a consistencia, nivel de desagregación, y representatividad territorial.
- Explorar la posibilidad de realizar análisis a nivel de localidad o colonia, en caso de que exista acceso a microdatos georreferenciados bajo protocolos éticos y jurídicos que garanticen la privacidad de la población.
- Incorporar estudios sobre la percepción social del riesgo durante la pandemia, mediante herramientas cualitativas que analicen las experiencias de la población en temas de salud, empleo, acceso a servicios, y condiciones espaciales de vida.
- Investigar la relación entre usos de suelo urbano, densidad habitacional y propagación del contagio, considerando factores estructurales como el hacinamiento, la distribución del equipamiento y las dinámicas del espacio construido.
- Modelo de alerta temprana de enfermedades respiratorias infecciosas
- Protocolo de monitoreo de enfermedades infecciosas basadas en intercalación de fuentes de datos.

Retos de investigación

Una de las principales limitaciones de la investigación radica en la disponibilidad y accesibilidad de datos desagregados, especialmente aquellos referidos a la colonia de residencia. En el caso de México, estos datos no se encuentran disponibles públicamente

debido a restricciones legales relacionadas con la protección de datos personales, lo que impide realizar análisis a escalas microterritoriales donde podrían identificarse patrones críticos de riesgo.

Existe un desfase temporal entre la generación de datos oficiales y su publicación, lo que complica la actualización en tiempo real de los modelos predictivos. A esto se suma la heterogeneidad en los formatos, metodologías de recolección y calidad de las bases de datos, lo que exige procesos rigurosos de depuración, validación y estandarización.

La infraestructura computacional necesaria para ejecutar modelos híbridos complejos, especialmente aquellos basados en redes profundas como los Transformers, requieren grandes volúmenes de datos y potencia de cómputo para su entrenamiento y evaluación.

Otro de los retos enfrentados en el desarrollo de esta investigación fue la limitada disponibilidad de datos confiables y desagregados, lo cual restringe tanto el análisis fino como la validación rigurosa de los modelos predictivos. Aunque existen múltiples bases de datos públicas proporcionadas por instituciones como la Dirección General de Epidemiología y el INEGI, se identificaron inconsistencias significativas que ponen en duda la calidad de algunos registros. Por ejemplo, al intentar realizar ejercicios analíticos a nivel de localidad de residencia, se encontraron discrepancias notables entre el número de habitantes reportados por el INEGI y los casos registrados por COVID-19. En ciertas localidades, se reportaba una población de apenas diez personas, mientras que los datos de defunciones por COVID-19 superaban los cincuenta casos, lo que revela errores de actualización o fallas en la depuración de los registros. Este tipo de anomalías compromete la confiabilidad del análisis territorial detallado y evidencia una brecha entre la estadística demográfica y los datos epidemiológicos reales.

En México, no existe un sistema unificado de salud que permita rastrear el historial médico de las personas desde la primera consulta ambulatoria hasta una posible hospitalización. Tampoco se cuenta con un identificador único (como un CURP médico) que relacione a una persona con sus visitas a instituciones médicas públicas o privadas, ni con el número, tipo o frecuencia de enfermedades atendidas. Esta fragmentación limita la posibilidad de construir modelos epidemiológicos personalizados y reduce la eficacia de cualquier política preventiva basada en predicción.

Dado que en México no existe un identificador único de salud que permita rastrear de manera individual la trayectoria médica de cada paciente, se incurre en una posible sobreestimación de los casos registrados durante la pandemia. La ausencia de este mecanismo impide distinguir si los registros corresponden a personas diferentes o a un mismo individuo que se contagió en más de una ocasión. Es importante señalar que muchas personas pudieron haberse enfermado dos, tres o más veces a lo largo del periodo pandémico, o bien, haberse realizado múltiples pruebas de detección (PCR o de antígenos) en farmacias, centros de salud e instituciones hospitalarias. Esta situación genera un sesgo en los datos acumulados, que podría traducirse en cifras sobrestimadas de contagios, dificultando una lectura precisa de la magnitud real de la propagación del virus.

Frente a estos desafíos, se recomienda que a futuro los sistemas de salud refuercen sus capacidades de recolección, integración y análisis de datos, estableciendo registros actualizados, focalizados y territorializados que permitan identificar, con precisión, a las personas más vulnerables a nivel de vivienda o microzona. Aunque la publicación de estos datos sensibles podría mantenerse restringida por motivos de confidencialidad, es crucial que las instituciones gubernamentales sean propietarias de información de alta calidad para su uso estratégico en contextos de emergencia sanitaria. Solo a través de datos sólidos y contextualizados será posible anticipar brotes, diseñar respuestas oportunas y reducir desigualdades en el acceso a la salud.

El modelo de intercalación epidemiológica desarrollado en esta investigación no se limita exclusivamente al análisis del COVID-19. Su estructura es suficientemente flexible para adaptarse al estudio de otras enfermedades respiratorias infecciosas, las cuales suelen solaparse en el tiempo y en el espacio con factores climáticos, meteorológicos, ambientales, sociales y de movilidad urbana. La capacidad de capturar estas interacciones multicausales constituye un avance significativo para la geografía de la salud y para el diseño de estrategias preventivas basadas en evidencia territorializada.

Es necesario dar seguimiento al brote de la variante Ómicron en 2025. Aunque presenta una menor letalidad en comparación con variantes anteriores, no debe subestimarse su potencial impacto. La investigación continua es fundamental para desarrollar nuevos enfoques que permitan afrontar los desafíos en materia de promoción y prevención de la

salud. Contar con evidencia científica robusta permitirá que los tomadores de decisiones diseñen estrategias de comunicación y alerta a la población sobre cambios en las dinámicas sociales durante escenarios pandémicos.

La sociedad debe estar mejor preparada ante posibles rebrotes de COVID-19. Las variantes virales forman parte inherente de la evolución histórica de las pandemias, por lo que es imperativo fortalecer la capacidad de respuesta desde un enfoque interdisciplinario. En ausencia de medidas oportunas y eficaces, las pandemias pueden generar efectos de gran magnitud en la salud pública. Prepararse implica minimizar riesgos, reducir impactos y proteger a las poblaciones más vulnerables.

Bibliografía

- Al Hajjar, S., & McIntosh, K. (2010). The first influenza pandemic of the 21st century. En *Annals of Saudi Medicine* (Vol. 30, Número 1, pp. 1–10). <https://doi.org/10.4103/0256-4947.59365>
- Aleuy, O. A., Pitesky, M., & Gallardo, R. (2018). Using multinomial and space-time permutation models to understand the epidemiology of infectious bronchitis in California between 2008 and 2012. En *Avian Diseases* (Vol. 62, Número 2, pp. 226–232). American Association of Avian Pathologists. <https://doi.org/10.1637/11788-122217-Reg.1>
- Almalki, A., Gokaraju, B., Acquaah, Y., & Turlapaty, A. (2022). Regression Analysis for COVID-19 Infections and Deaths Based on Food Access and Health Issues. *Healthcare (Switzerland)*, 10(2). <https://doi.org/10.3390/healthcare10020324>
- Arsenault, J., Michel, P., Berke, O., Ravel, A., & Gosselin, P. (2013). How to choose geographical units in ecological studies: Proposal and application to campylobacteriosis. *Spatial and Spatio-temporal Epidemiology*, 7, 11–24. <https://doi.org/10.1016/j.sste.2013.04.004>
- Awez, J., Khan, T., & Ali, M. (2024). Assessing Air Pollution Crisis in South Asia: The Health, Economic, and Environmental Implications through Case Studies of Lahore, Delhi, and Dhaka. *Pakistan Languages and Humanities Review*, 8(2). [https://doi.org/https://doi.org/10.47205/plhr.2024\(8-II-S\)22](https://doi.org/https://doi.org/10.47205/plhr.2024(8-II-S)22)
- Bambra, C., Riordan, R., Ford, J., & Matthews, F. (2020). The COVID-19 pandemic and health inequalities. *Journal of Epidemiology and Community Health*, 74(11), 964–968. <https://doi.org/10.1136/jech-2020-214401>
- Banco de México. (2020). *Propagación del COVID-19 en las regiones de México*. <https://www.banxico.org.mx/publicaciones-y-prensa/reportes-sobre-las-economias-regionales/recuadros/%7B3C2226F5-59DA-BA7B-7556-70937FB5B751%7D.pdf>
- Barcellos, C., Buzai, G. D., & Santana, P. (2018). Geografía de la salud: Bases y actualidad. *Salud Colectiva*, 14(1), 1–4. <https://doi.org/10.18294/sc.2018.1763>

- Bashir, M. F., Ma, B., Bilal, Komal, B., Bashir, M. A., Tan, D., & Bashir, M. (2020). Correlation between climate indicators and COVID-19 pandemic in New York, USA. *Science of the Total Environment*, 728. <https://doi.org/10.1016/j.scitotenv.2020.138835>
- Bedford, T., Riley, S., Barr, I. G., Broor, S., Chadha, M., Cox, N. J., Daniels, R. S., Gunasekaran, C. P., Hurt, A. C., Kelso, A., Klimov, A., Lewis, N. S., Li, X., McCauley, J. W., Odagiri, T., Potdar, V., Rambaut, A., Shu, Y., Skepner, E., ... Russell, C. A. (2015). Global circulation patterns of seasonal influenza viruses vary with antigenic drift. *Nature*, 523(7559), 217–220. <https://doi.org/10.1038/nature14460>
- Bello-Chavolla, O. Y., González-Díaz, A., Antonio-Villa, N. E., Fermín-Martínez, C. A., Márquez-Salinas, A., Vargas-Vázquez, A., Bahena-López, J. P., García-Peña, C., Aguilar-Salinas, C. A., & Gutiérrez-Robledo, L. M. (2021). Unequal Impact of Structural Health Determinants and Comorbidity on COVID-19 Severity and Lethality in Older Mexican Adults: Considerations beyond Chronological Aging. *Journals of Gerontology - Series A Biological Sciences and Medical Sciences*, 76(3), E52–E59. <https://doi.org/10.1093/gerona/glaa163>
- Berche, P. (2022). The enigma of the 1889 Russian flu pandemic: A coronavirus? *Presse Medicale*, 51(3). <https://doi.org/10.1016/j.lpm.2022.104111>
- Berry, B. J. L. (1964). Approaches to regional analysis: A synthesis. *Annals of the Association of American Geographers*, 54(2), 2–11.
- Bert, B., & Stephen, T. H. (2002). Air pollution and health. *The Lancet*, 360, 1233–1242. [https://doi.org/10.1016/s0140-6736\(02\)11274-8](https://doi.org/10.1016/s0140-6736(02)11274-8)
- Bien Hernández, J., & Kim, P. (2022). Epidemiology morbidity and mortality. *National Institutes of Health*. <https://www.ncbi.nlm.nih.gov/books/NBK547668/#:~:text=Morbidity%20is%20the%20state%20of,estimated%20using%20prevalence%20or%20incidence.>
- Bodor, K., Szép, R., & Bodor, Z. (2022). The human health risk assessment of particulate air pollution (PM_{2.5} and PM₁₀) in Romania. *Toxicology Reports*, 9, 556–562. <https://doi.org/10.1016/j.toxrep.2022.03.022>

- Bolaños, M. V. (2000). Revisión crítica a la teoría de la transición epidemiológica. *Papeles de Población*, 25, 179–206.
- Buzai, G. (2001). Geografía global el paradigma geotecnológico y el espacio interdisciplinario en la interpretación del mundo del siglo XXI. *Estudios Geográficos*, 245, 621–648. <https://doi.org/10.3989/egeogr.2001.i245.269>
- Buzai, G. (2021). Análisis espacial cuantitativo de los Condicionantes Socioespaciales de la Salud (CSS) de la megaciudad Buenos Aires. *Geográfica digital*, 18(35), 2. <https://doi.org/10.30972/geo.18355130>
- Buzai, G. D. (2001). Paradigma Geotecnológico, Geografía Global y CiberGeografía, la gran explosión de un universo digital en expansión. *GeoFocus*, 1, 24–48.
- Buzai, G., & Santana Juárez, M. V. (2018). Condicionantes Socioespaciales de la Salud (CSS): Bases y alcance conceptual. *Anuario de la División de Geografía*, 12, 170–184.
- Cameron, I., & Pimlott, N. (2015). Art of medicine. *Canadian Family Physician*, 61.
- Capistran, M. A., Capella, A., & Christen, J. A. (2021). Forecasting hospital demand in metropolitan areas during the current COVID-19 pandemic and estimates of lockdown-induced 2nd waves. *PLoS ONE*, 16(1 January). <https://doi.org/10.1371/journal.pone.0245669>
- Cartwright, M. (2023). *Peste negra*. Enciclopedia de la Historia del Mundo. <https://www.worldhistory.org/trans/es/1-17097/peste-negra/>
- Casillas, S., Herrero Fernández, S., & Varon, J. (2008). Gripe aviar: lo que un intensivista debe conocer. *Medicina Intensiva*, 32(4), 183–193.
- Castro, R. R., Santos, R. S. C., Sousa, G. J. B., Pinheiro, Y. T., Martins, I. M., Pereira, M. L. D., & Silva, R. A. R. (2021). Spatial dynamics of the COVID-19 pandemic in Brazil. *Epidemiology and Infection*. <https://doi.org/10.1017/S0950268821000479>
- Ceberio, M. R. (2021). Gripes asesinas y el reinado del virus corona. *Ciencias Psicológicas*, 15(2), 1–10. <https://doi.org/10.22235/cp.v15i2.2704>

- Center of Disease Control and Prevention. (2012, abril). *Lesson 1: Introduction to Epidemiology*. CDC Web Archive. <https://www.cdc.gov/csels/dsepd/ss1978/lesson1/section11.html>
- Chen, S., Prettner, K., Kuhn, M., Geldsetzer, P., Wang, C., Bärnighausen, T., & Bloom, D. E. (2021). Climate and the spread of COVID-19. *Scientific reports*, *11*(1), 9042. <https://doi.org/10.1038/s41598-021-87692-z>
- Chen, X., Xuan, C., & Qiu, R. (2021). Understanding spatial spillover effects of airports on economic development: New evidence from China's hub airports. *Transportation Research Part A: Policy and Practice*, *143*, 48–60. <https://doi.org/10.1016/j.tra.2020.11.013>
- Ching, F. (2018). Bird Flu, SARS and beyond. En *130 Years of Medicine in Hong Kong* (pp. 381–434). Springer Singapore. https://doi.org/10.1007/978-981-10-6316-9_14
- Conde-Gutiérrez, R. A., Colorado, D., & Hernández-Bautista, S. L. (2021). Comparison of an artificial neural network and Gompertz model for predicting the dynamics of deaths from COVID-19 in México. *Nonlinear Dynamics*. <https://doi.org/10.1007/s11071-021-06471-7>
- Consejería Jurídica del Ejecutivo Federal. (2020, marzo 31). *Acuerdo por el que se declara como emergencia sanitaria por causa de fuerza mayor, a la epidemia de enfermedad generada por el virus SARS-COV2 (COVID-19)*. Se declara como emergencia sanitaria la epidemia generada por COVID-19. <https://www.gob.mx/cjef/documentos/se-declara-como-emergencia-sanitaria-la-epidemia-generada-por-covid-19?idiom=es>
- Consejo Nacional de Población. (2024). *Reconstrucción y proyecciones de la población de los municipios de México*. Gobierno de México. <https://www.gob.mx/conapo/articulos/reconstruccion-y-proyecciones-de-la-poblacion-de-los-municipios-de-mexico>
- Cui, L. J., Zhang, C., Zhang, T., Lu, R. J., Xie, Z. De, Zhang, L. L., Liu, C. Y., Zhou, W. M., Ruan, L., Ma, X. J., & Tan, W. J. (2011). Human coronaviruses HCoV-NL63 and HCoV-HKU1 in hospitalized children with acute respiratory infections in Beijing, China. *Advances in Virology*, *2011*, 1–6. <https://doi.org/10.1155/2011/129134>

- Dalziel, B. D., Kissler, S., Gog, J. R., Viboud, C., Bjørnstad, O. N., Jessica, C., Metcalf, E., & Grenfell, B. T. (2018). Urbanization and humidity shape the intensity of influenza epidemics in U.S. cities. *Science*, 362(6410), 75–79. <https://doi.org/10.1126/science.aat603>
- D'Amato, G., Holgate, S. T., Pawankar, R., Ledford, D. K., Cecchi, L., Al-Ahmad, M., Al-Enezi, F., Al-Muhsen, S., Ansotegui, I., Baena-Cagnani, C. E., Baker, D. J., Bayram, H., Bergmann, K. C., Boulet, L. P., Buters, J. T. M., D'Amato, M., Dorsano, S., Douwes, J., Finlay, S. E., ... Annesi-Maesano, I. (2015). Meteorological conditions, climate change, new emerging factors, and asthma and related allergic disorders. A statement of the World Allergy Organization. En *World Allergy Organization Journal* (Vol. 8, Número 1). BioMed Central Ltd. <https://doi.org/10.1186/s40413-015-0073-0>
- D'Amato, M., Molino, A., Calabrese, G., Cecchi, L., Annesi-Maesano, I., & D'Amato, G. (2018). The impact of cold on the respiratory tract and its consequences to respiratory health. En *Clinical and Translational Allergy* (Vol. 8, Número 1). BioMed Central Ltd. <https://doi.org/10.1186/s13601-018-0208-9>
- Das, S. K., & Bebornta, S. (2022). A study on geospatially assessing the impact of COVID-19 in Maharashtra, India. *Egyptian Journal of Remote Sensing and Space Science*, 25(1), 221–232. <https://doi.org/10.1016/j.ejrs.2021.12.010>
- Decoster, A., Minten, T., & Spinnewijn, J. (2021a). The income gradient in mortality during the Covid-19 Crisis: Evidence from Belgium. *Journal of Economic Inequality*, 19(3), 551–570. <https://doi.org/10.1007/s10888-021-09505-7>
- Decoster, A., Minten, T., & Spinnewijn, J. (2021b). The income gradient in mortality during the Covid-19 Crisis: Evidence from Belgium. *Journal of Economic Inequality*, 19(3), 551–570. <https://doi.org/10.1007/s10888-021-09505-7>
- Delgado Mahecha, O. (2003). *Debates sobre el espacio en la geografía contemporánea* (Unibiblos). Universidad Nacional de Colombia.
- Delgado Rodríguez, M., & Llorca Díaz, J. (2004). Estudios longitudinales: concepto y particularidades. *Revista Española de Salud Pública*, 78(2).

- Ding, P. H., Wang, G. S., Guo, Y. L., Chang, S. C., & Wan, G. H. (2017). Urban air pollution and meteorological factors affect emergency department visits of elderly patients with chronic obstructive pulmonary disease in Taiwan. *Environmental Pollution*, 224, 751–758. <https://doi.org/10.1016/j.envpol.2016.12.035>
- Domingo, J. L., & Rovira, J. (2020). Effects of air pollutants on the transmission and severity of respiratory viral infections. En *Environmental Research* (Vol. 187). Academic Press Inc. <https://doi.org/10.1016/j.envres.2020.109650>
- Elliott, P., & Wartenberg, D. (2004). Spatial epidemiology: Current approaches and future challenges. En *Environmental Health Perspectives* (Vol. 112, Número 9, pp. 998–1006). Public Health Services, US Dept of Health and Human Services. <https://doi.org/10.1289/ehp.6735>
- Environmental Protection Agency. (2025, julio 10). *Nitrogen Dioxide (NO2) Pollution*. Basic Information about NO2.
- Faghri, P. D., Dobson, M., Landsbergis, P., & Schnall, P. L. (2021). COVID-19 Pandemic: What has work got to do with it? En *Journal of occupational and environmental medicine* (Vol. 63, Número 4, pp. e245–e249). NLM (Medline). <https://doi.org/10.1097/JOM.0000000000002154>
- Fang, L. Q., De Vlas, S. J., Feng, D., Liang, S., Xu, Y. F., Zhou, J. P., Richardus, J. H., & Cao, W. C. (2009). Geographical spread of SARS in mainland China. *Tropical Medicine and International Health*, 14(SUPPL. 1), 14–20. <https://doi.org/10.1111/j.1365-3156.2008.02189.x>
- Fattorini, D., & Regoli, F. (2020). Role of the chronic air pollution levels in the Covid-19 outbreak risk in Italy. En *Environmental Pollution* (Vol. 264). Elsevier Ltd. <https://doi.org/10.1016/j.envpol.2020.114732>
- Food and Agriculture Organization of the United Nations. (2012). Highly Pathogenic Avian Influenza in Mexico (H7N3) - A significant threat to poultry production not to be underestimated. *EMPRES WATCH*, 26.

- Franch-Pardo, I., Napoletano, B. M., Rosete-Verges, F., & Billa, L. (2020). Spatial analysis and GIS in the study of COVID-19. A review. *Science of the Total Environment*, 739. <https://doi.org/10.1016/j.scitotenv.2020.140033>
- Frenk, J., Bobadilla, J., Sepúlveda, J., Rosenthal, J., & Ruelas, E. (1986). Un modelo conceptual para la investigación en salud pública. *Boletín de la Oficina Sanitaria Panamericana (OSP)*, 101(5).
- Frenk, J., Frejka, T., Bobadilla, J., Stern, C., Lozano, R., Sepúlveda, J., & José, M. (1991). La transición epidemiológica en América Latina. *Boletín de la Oficina Sanitaria Panamericana (OSP)*, 111(6). <https://iris.paho.org/handle/10665.2/16560>
- Ganaza-Domingues, K. L. T., Ramos-Milaré, Á. C. F. H., Lera-Nonose, D. S. S. L., Brustolin, A. Á., de Oliveira, L. F., Rosa, J. S., Otofujii Inada, A. Y., Dias Leme, A. L., Pinel, B. I., Perina, B. S., de Souza Terron, M., da Silva Santos, T., Demarchi, I. G., Lonardoní, M. V. C., & Teixeira, J. J. V. (2025). Effect of Comorbidities on the Mortality of Patients With COVID-19: A Systematic Review of Reviews and Meta-Analyses. En *Reviews in Medical Virology* (Vol. 35, Número 2). John Wiley and Sons Ltd. <https://doi.org/10.1002/rmv.70024>
- Gao, S. (2021). Geospatial Artificial Intelligence (GeoAI). En *Geography*. Oxford University Press. <https://doi.org/10.1093/obo/9780199874002-0228>
- García-García, J., & Ramos, C. (2006). La influenza, un problema vigente de salud pública. *Salud pública de México*, 48(3), 244–267.
- Gatto, M., Bertuzzo, E., Mari, L., Miccoli, S., Carraro, L., Casagrandi, R., & Rinaldo, A. (2020). Spread and dynamics of the COVID-19 epidemic in Italy: Effects of emergency containment measures. *PNAS*, 117(19), 10484–10491. <https://doi.org/10.1073/pnas.2004978117/-/DCSupplemental.y>
- Gobierno de la Ciudad de México. (s/f). *Sistema de Monitoreo Atmosférico de la Ciudad de México*. Recuperado el 21 de enero de 2025, de <http://www.aire.cdmx.gob.mx/default.php>

- Gregg, M. B., Hinman, A. R., & Craven, R. B. (1978). The Russian flu its history and implications for this year's influenza season. *JAMA*, *240*(21), 2260–2263. <http://jama.jamanetwork.com/>
- Grill, E., Eitze, S., De Bock, F., Dragano, N., Huebl, L., Schmich, P., Wieler, L. H., & Betsch, C. (2021). Sociodemographic characteristics determine download and use of a Corona contact tracing app in Germany-Results of the COSMO surveys. En *PLoS ONE* (Vol. 16, Número 9 September). Public Library of Science. <https://doi.org/10.1371/journal.pone.0256660>
- Guarnieri, G., Olivieri, B., Senna, G., & Vianello, A. (2023). Relative Humidity and Its Impact on the Immune System and Infections. En *International Journal of Molecular Sciences* (Vol. 24, Número 11). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/ijms24119456>
- Gustafsson, P. E., San Sebastian, M., Fonseca-Rodriguez, O., & Fors Connolly, A. M. (2022). Inequitable impact of infection: social gradients in severe COVID-19 outcomes among all confirmed SARS-CoV-2 cases during the first pandemic wave in Sweden. *Journal of epidemiology and community health*, *76*(3), 261–267. <https://doi.org/10.1136/jech-2021-216778>
- Henderson, D. A., Courtney, B., Inglesby, T. V., Toner, E., & Nuzzo, J. B. (2009). Public health and medical responses to the 1957-58 influenza pandemic. *Biosecur Bioterror*, *7*(3), 268–273. <https://doi.org/10.1089/bsp.2009.0729>
- Hernández Bernal, J. E., & Santana Juárez, M. V. (2022). Dinámica territorial de la transición epidemiológica en el Estado de México para el grupo de 15 a 64 años de edad, 1980-2020. *Posición*, *7*, 1–17. <https://posicion-inigeo.unlu.edu.ar/>
- Hu, Y., Li, W., Wright, D., Aydin, O., Wilson, D., Maher, O., & Raad, M. (2019). Artificial Intelligence Approaches. *Geographic Information Science & Technology Body of Knowledge*, *2019*(Q3). <https://doi.org/10.22224/gistbok/2019.3.4>
- Hua, Y., Yuan, X., Wang, J., Zeng, K., Zhi, S., & Liu, L. (2022). Association between air pollution and hospital admissions for chronic respiratory disease in people aged over 65 years: a time series analysis in Ningbo, China, 2015–2017. *International Archives of*

- Occupational and Environmental Health*, 95(6), 1293–1304.
<https://doi.org/10.1007/s00420-022-01887-z>
- Huang, Z. H., Liu, X. Y., Zhao, T., Jiao, K. Z., Ma, X. X., Ren, Z., Qiu, Y. F., Liao, J. L., & Ma, L. (2022). Short-term effects of air pollution on respiratory diseases among young children in Wuhan city, China. *World Journal of Pediatrics*, 18(5), 333–342.
<https://doi.org/10.1007/s12519-022-00533-5>
- Huerta López, J. G. (2014). La influenza. *Órgano Oficial del Colegio Mexicano de Alergia, Asma e Inmunología Pediátrica y de la Asociación Latinoamericana de Pediatría*, 23(3), 37–38.
www.medigraphic.org.mx Este artículo también puede ser consultado en versión completa en <http://www.medigraphic.com/alergia/www.medigraphic.org.mx>
- Institute for Health Metrics and Evaluation. (2019). *GBD Compare*. University of Washington. <https://vizhub.healthdata.org/gbd-compare/>
- Instituto Nacional de Salud Pública. (2016, enero 26). *Influenza*.
<https://www.insp.mx/avisos/3974-influenza.html>
- Instituto Nacional de Salud Pública. (2020, abril 24). *Tuberculosis: la enfermedad infecciosa más mortífera en el mundo*. <https://www.insp.mx/avisos/5302-tuberculosis-enfermedad-infecciosa-mortifera.html>
- Janowicz, K., Gao, S., McKenzie, G., Hu, Y., & Bhaduri, B. (2020). GeoAI: spatially explicit artificial intelligence techniques for geographic knowledge discovery and beyond. En *International Journal of Geographical Information Science* (Vol. 34, Número 4, pp. 625–636). Taylor and Francis Ltd. <https://doi.org/10.1080/13658816.2019.1684500>
- Jiang, S., Zhang, J., Jin, J., Zhang, D., & Wang, T. (2011). Spatial Analysis of Influenza A H1N1 and Evaluation of Risk Factors in Changsha City Based on GIS. En *2011 19th International Conference on Geoinformatics*. IEEE.
<https://doi.org/10.1109/GeoInformatics.2011.5981050>
- John Martin Rare Book Room. (2017). *The black death: The plague, 1331-1770*. John Martin Rare Book Room. <http://hosted.lib.uiowa.edu/histmed/plague/>

- Kamel Boulos, M. N. (2004). *Descriptive review of geographic mapping of severe acute respiratory syndrome (SARS) on the Internet*. <http://www.who.int/csr/sars/country/en/>
- Kianfar, N., Mesgari, M. S., Mollalo, A., & Kaveh, M. (2022). Spatio-temporal modeling of COVID-19 prevalence and mortality using artificial neural network algorithms. *Spatial and Spatio-temporal Epidemiology*, 40. <https://doi.org/10.1016/j.sste.2021.100471>
- Kim, S. H., Lee, J., Oh, I., Oh, Y., Sim, C. S., Bang, J. H., Park, J., & Kim, Y. (2021). Allergic rhinitis is associated with atmospheric SO₂: Follow-up study of children from elementary schools in Ulsan, Korea. *PLoS ONE*, 16(3 March). <https://doi.org/10.1371/journal.pone.0248624>
- Kılıç, O. (2020). Pandemics Throughout History and Their Effects on Society Life. En M. Şeker, A. Özer, & C. Korkut (Eds.), *Reflections on the pandemic in the future of the World*. Tuba Turkish Academy of Sciences. <https://doi.org/10.53478/TUBA.2020.073>
- Ko, U. W., & Kyung, S. Y. (2022). Adverse Effects of Air Pollution on Pulmonary Diseases. En *Tuberculosis and Respiratory Diseases* (Vol. 85, Número 4, pp. 313–319). Korean National Tuberculosis Association. <https://doi.org/10.4046/trd.2022.0116>
- Krupnova, T. G., Rakova, O. V., Bondarenko, K. A., Saifullin, A. F., Popova, D. A., Potgieter-Vermaak, S., & Godoi, R. H. M. (2021). Elemental composition of PM_{2.5} and PM₁₀ and health risks assessment in the industrial districts of chelyabinsk, south ural region, Russia. *International Journal of Environmental Research and Public Health*, 18(23). <https://doi.org/10.3390/ijerph182312354>
- Lai, P. C., Wong, C. M., Hedley, A. J., Lo, S. V., Leung, P. Y., Kong, J., & Leung, G. M. (2004). Understanding the spatial clustering of severe acute respiratory syndrome (SARS) in Hong Kong. *Environmental Health Perspectives*, 112(15), 1550–1556. <https://doi.org/10.1289/ehp.7117>
- Lan, Y., & Delmelle, E. (2023). Space-time cluster detection techniques for infectious diseases: A systematic review. En *Spatial and Spatio-temporal Epidemiology* (Vol. 44). Elsevier Ltd. <https://doi.org/10.1016/j.sste.2022.100563>

- Lawson, A. (2006). Ecological Analysis and Scale Change. En *Statistical Methods in Spatial Epidemiology* (Segunda, pp. 247–289). John Wiley & Sons, Ltd.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. En *Nature* (Vol. 521, Número 7553, pp. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>
- León, D. A., Martínez Cuenca, J. G., Ardila Sánchez, I. A., & Mosquera Palacios, D. J. (2022). Inteligencia artificial para el control de tráfico en redes de datos: Una revisión. *Entre ciencia e ingeniería*, 16(31), 17–24. <https://doi.org/10.31908/19098367.2655>
- Lin, Q., Ou, G., Wang, R., Li, Y., Zhao, Y., & Dong, Z. (2021). The spatiotemporal characteristics and climatic factors of covid-19 in Wuhan, China. *Sustainability (Switzerland)*, 13(14). <https://doi.org/10.3390/su13148112>
- Lipp, D. (2016). Principios de la geografía. *Actas científicas CIG-77° Semana de la geografía*, 119–130.
- Littman, R. J. (2009). The plague of Athens: Epidemiology and paleopathology. *Mount Sinai Journal of Medicine*, 76(5), 456–467. <https://doi.org/10.1002/msj.20137>
- Liu, D. X., Liang, J. Q., & Fung, T. S. (2020). Human Coronavirus-229E, -OC43, -NL63, and -HKU1 (Coronaviridae). En *Encyclopedia of Virology: Volume 1-5, Fourth Edition* (Vols. 1–5, pp. 428–440). Elsevier. <https://doi.org/10.1016/B978-0-12-809633-8.21501-X>
- Liu, W., Liu, P., William, ;, Liu, J., Wang, ; Qihui, Tong, Y., & Gao, G. F. (2022). Origins of HIV, HCoV-HKU1, SFTSV, and MERS-CoV and Beyond. *China CDC Weekly*, 823–827. <https://doi.org/10.46234/ccdcw2022.171>
- Luna-Vargas, E. (2022). Despoblamiento de la Ciudad Central de la Zona Metropolitana de la Ciudad de México 1990-2020. *Revista Mexicana de Análisis Político y Administración Pública*, XI(22), 174–204.
- Lunga, D., Hu, Y., Newsam, S., Gao, S., Martins, B., Yang, L., & Deng, X. (2021). GeoAI at ACM SIGSPATIAL: The New Frontier of Geospatial Artificial Intelligence Research. *SIGSPATIAL Special*, 13(1–3), 21–32. <https://doi.org/10.1145/3578484.3578491>

- Macintyre, H. L., Heaviside, C., Neal, L. S., Agnew, P., Thornes, J., & Vardoulakis, S. (2016). Mortality and emergency hospitalizations associated with atmospheric particulate matter episodes across the UK in spring 2014. *Environment International*, 97, 108–116. <https://doi.org/10.1016/j.envint.2016.07.018>
- Mai, G., Cundy, C., Choi, K., Hu, Y., Lao, N., & Ermon, S. (2022, noviembre 1). Towards a foundation model for geospatial artificial intelligence. *GIS: Proceedings of the ACM International Symposium on Advances in Geographic Information Systems*. <https://doi.org/10.1145/3557915.3561043>
- Malvido, E. (2003). La epidemiología , una respuesta para explicar la despoblación americana. *Revista de Indias, LXIII*, 65–78.
- Malvido, E., & Viesca, C. (1985). La epidemia de cocoliztli de 1576. *Historias, 11*, 27–34. <https://revistas.inah.gob.mx/index.php/historias/article/view/15223>
- Mansour, S., Abulibdeh, A., Alahmadi, M., & Ramadan, E. (2022). Spatial Assessment of COVID-19 First-Wave Mortality Risk in the Global South. *Professional Geographer*, 74(3), 440–458. <https://doi.org/10.1080/00330124.2021.2009888>
- Marini, M., Chokani, N., & Abhari, R. S. (2020). COVID-19 Epidemic in Switzerland: Growth Prediction and Containment Strategy Using Artificial Intelligence and Big Data. *medRxiv*. <https://doi.org/10.1101/2020.03.30.20047472>
- Marquès, M., Domingo, J. L., Nadal, M., & Schuhmacher, M. (2020). Health risks for the population living near petrochemical industrial complexes. 2. Adverse health outcomes other than cancer. En *Science of the Total Environment* (Vol. 730). Elsevier B.V. <https://doi.org/10.1016/j.scitotenv.2020.139122>
- McCracken, K., & Phillips, D. R. (2020). Epidemiological Transition. En *International Encyclopedia of Human Geography* (pp. 265–273). Elsevier. <https://doi.org/10.1016/b978-0-08-102295-5.10373-7>
- Mebrahtu, T. F., Santorelli, G., Yang, T. C., Wright, J., Tate, J., & McEachan, R. R. (2023). The effects of exposure to NO₂, PM_{2.5} and PM₁₀ on health service attendances with

- respiratory illnesses: A time-series analysis. *Environmental Pollution*, 333. <https://doi.org/10.1016/j.envpol.2023.122123>
- Mishra, S. V., Gayen, A., & Haque, S. M. (2020). COVID-19 and urban vulnerability in India. *Habitat International*, 103. <https://doi.org/10.1016/j.habitatint.2020.102230>
- Mohammad Ayyoubzadeh, S., Mehdi Ayyoubzadeh, S., Zahedi, H., Ahmadi, M., & Niakan Kalhori, S. R. (2020). Predicting COVID-19 Incidence Using Google Trend and Data Mining Techniques: A case study of Iran. *JMIR*, 6(2). <https://doi.org/10.2196/preprints.18828>
- Molina-Torres, R., Nolasco-Jáuregui, O., Rodriguez-Torres, E. E., Itzá-Ortiz, B. A., & Quezada-Téllez, L. A. (2021). A comparative analysis of urban development, economic level, and COVID-19 cases in Mexico City. *Journal of Urban Management*, 10(3), 265–274. <https://doi.org/10.1016/j.jum.2021.06.007>
- Mollalo, A., Vahedi, B., & Rivera, K. M. (2020). GIS-based spatial modeling of COVID-19 incidence rate in the continental United States. *Science of the Total Environment*, 728. <https://doi.org/10.1016/j.scitotenv.2020.138884>
- Moneer Yahya, B., Samier Yahya, F., & Ghazi Thannoun, R. (2021). COVID-19 prediction analysis using artificial intelligence procedures and GIS spatial analyst: a case study for Iraq. *Applied Geomatics*, 481–491. <https://doi.org/10.1007/s12518-021-00365-4>/Published
- Morens, D. M., North, M., & Taubenberger, J. K. (2010). Eyewitness accounts of the 1918 influenza pandemic in Europe. *Lancet*, 376(9756), 1894–1895. [https://doi.org/10.1016/S0140-6736\(10\)62204-0](https://doi.org/10.1016/S0140-6736(10)62204-0)
- Mukandavire, Z., Nyabadza, F., Malunguza, N. J., Cuadros, D. F., Shiri, T., & Musuka, G. (2020). Quantifying early COVID-19 outbreak transmission in South Africa and exploring vaccine efficacy scenarios. *PLoS ONE*, 15(7 July). <https://doi.org/10.1371/journal.pone.0236003>

- Murgante, B., Borruso, G., Balletto, G., Castiglia, P., & Dettori, M. (2020). Why Italy first? Health, geographical and planning aspects of the COVID-19 outbreak. *Sustainability (Switzerland)*, *12*(12). <https://doi.org/10.3390/su12125064>
- Nielsen, J., Nørgaard, S. K., Lanzieri, G., Vestergaard, L. S., & Moelbak, K. (2021). Sex-differences in COVID-19 associated excess mortality is not exceptional for the COVID-19 pandemic. *Scientific Reports*, *11*(1). <https://doi.org/10.1038/s41598-021-00213-w>
- Nurhisannah, S., & Hasyim, H. (2022). Environmental health risk assessment of sulfur dioxide (SO₂) at workers around in combined cycle power plant (CCPP). *Heliyon*, *8*(5). <https://doi.org/10.1016/j.heliyon.2022.e09388>
- Olivera, A. (1993). *Geografía de la salud* (Síntesis).
- Omran, A. R. (1971). The epidemiologic transition: A Theory of the epidemiology of population change. *The Milbank Memorial Fund Quarterly*, *49*(4), 509–538.
- Organización Mundial de la Salud. (2023, abril). *La OMS mantiene su firme compromiso con los principios establecidos en el preámbulo de la Constitución*. <https://www.who.int/es/about/governance/constitution>
- Organización Panamericana de la Salud. (2020, marzo 11). *La OMS caracteriza a COVID-19 como una pandemia*. La OMS caracteriza a COVID-19 como una pandemia. <https://www.paho.org/es/noticias/11-3-2020-oms-caracteriza-covid-19-como-pandemia>
- Oropeza, M., & Díaz, N. (2007). La geotecnología y su inserción en el pensamiento geográfico. *Terra Nueva Etapa*, *XXIII*(34), 71–95.
- Ortega Valcárcel, J. (2000). La geografía moderna: una ciencia de las relaciones hombre-medio. En *Los horizontes de la geografía Teoría de la geografía* (Ariel, S.A, pp. 149–181).
- Patel, J. A., Nielsen, F. B. H., Badiani, A. A., Assi, S., Unadkat, V. A., Patel, B., Ravindrane, R., & Wardle, H. (2020). Poverty, inequality and COVID-19: the forgotten vulnerable. *Public Health*, *183*, 110–111. <https://doi.org/10.1111/j.1475>

- Petersen, E., Ntoumi, F., Hui, D. S., Abubakar, A., Kramer, L. D., Obiero, C., Tambyah, P. A., Blumberg, L., Yapi, R., Al-Abri, S., Pinto, T. de C. A., Yeboah-Manu, D., Haider, N., Asogun, D., Velavan, T. P., Kapata, N., Bates, M., Ansumana, R., Montaldo, C., ... Zumla, A. (2022). Emergence of new SARS-CoV-2 Variant of Concern Omicron (B.1.1.529) - highlights Africa's research capabilities, but exposes major knowledge gaps, inequities of vaccine distribution, inadequacies in global COVID-19 response and control efforts. En *International Journal of Infectious Diseases* (Vol. 114, pp. 268–272). Elsevier B.V. <https://doi.org/10.1016/j.ijid.2021.11.040>
- Pham, Q. V., Nguyen, D. C., Huynh-The, T., Hwang, W. J., & Pathirana, P. N. (2020). Artificial Intelligence (AI) and Big Data for Coronavirus (COVID-19) Pandemic: A Survey on the State-of-the-Arts. En *IEEE Access* (Vol. 8, pp. 130820–130839). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2020.3009328>
- Pierdicca, R., & Paolanti, M. (2022). GeoAI: a review of artificial intelligence approaches for the interpretation of complex geomatics data. En *Geoscientific Instrumentation, Methods and Data Systems* (Vol. 11, Número 1, pp. 195–218). Copernicus GmbH. <https://doi.org/10.5194/gi-11-195-2022>
- Pillet Capdepón, F. (2004). La geografía y las distintas acepciones del espacio geográfico. *Investigaciones geográficas*, 34, 141–154.
- Pourghasemi, H. R., Pouyan, S., Farajzadeh, Z., Sadhasivam, N., Heidari, B., Babaei, S., & Tiefenbacher, J. P. (2020a). Assessment of the outbreak risk, mapping and infection behavior of COVID-19: Application of the autoregressive integrated-moving average (ARIMA) and polynomial models. *PLoS ONE*, 15(7 July). <https://doi.org/10.1371/journal.pone.0236238>
- Pourghasemi, H. R., Pouyan, S., Farajzadeh, Z., Sadhasivam, N., Heidari, B., Babaei, S., & Tiefenbacher, J. P. (2020b). Assessment of the outbreak risk, mapping and infection behavior of COVID-19: Application of the autoregressive integrated-moving average (ARIMA) and polynomial models. *PLoS ONE*, 15(7 July). <https://doi.org/10.1371/journal.pone.0236238>

- Ramírez-Aldana, R., Gomez-Verjan, J. C., Bello-Chavolla, O. Y., & García-Peña, C. (2021). Spatial epidemiological study of the distribution, clustering, and risk factors associated with early COV-19 mortality in Mexico. *PLoS ONE*, *16*(July). <https://doi.org/10.1371/journal.pone.0254884>
- Razavi-Termeh, S. V., Sadeghi-Niaraki, A., & Choi, S. M. (2022). Coronavirus disease vulnerability map using a geographic information system (GIS) from 16 April to 16 May 2020. *Physics and Chemistry of the Earth*, *126*. <https://doi.org/10.1016/j.pce.2021.103043>
- Reche Cruz, A. (1987). Aproximación teórico-cognoscitiva a una nueva tendencia geográfica La geografía neopositivista. *Paralelo 37*, 8–9, 471–482.
- Rosenberg, M. (2016). Health geography II: ‘Dividing’ health geography. *Progress in Human Geography*, *40*(4), 546–554. <https://doi.org/10.1177/0309132515581094>
- Rose-Redwood, R., Kitchin, R., Apostolopoulou, E., Rickards, L., Blackman, T., Crampton, J., Rossi, U., & Buckley, M. (2020). Geographies of the COVID-19 pandemic. *Dialogues in Human Geography*, *10*(2), 97–106. <https://doi.org/10.1177/2043820620936050>
- Rozo, M., & Gronvall, G. K. (2015). The reemergent 1977 H1N1 strain and the gain-of-function debate. *mBio*, *6*(4). <https://doi.org/10.1128/mBio.01013-15>
- Ruan, Y. J., Wei, C. L., Ee, L. A., Vega, V. B., Thoreau, H., Yun, S. T. S., Chia, J. M., Ng, P., Chiu, K. P., Lim, L., Tao, Z., Peng, C. K., Ean, L. O. L., Lee, N. M., Sin, L. Y., Ng, L. F. P., Ren, E. C., Stanton, L. W., Long, P. M., & Liu, E. T. (2003). Comparative full-length genome sequence analysis of 14 SARS coronavirus isolates and common mutations associated with putative origins of infection. *Lancet*, *361*(9371), 1779–1785. [https://doi.org/10.1016/S0140-6736\(03\)13414-9](https://doi.org/10.1016/S0140-6736(03)13414-9)
- Sánchez, D. C. (2010). El positivismo, el empirismo lógico y las ramas de la matemática que incidieron en la geografía. *Geografía y Sistemas de Información Geográfica*, *2*, 20–53. <http://www.gesig-proeg.com.ar>

- Sanfilippo-Borrás, J. (2010). Algunas enfermedades y epidemias en torno a la Revolución Mexicana. *Revista Médica del Instituto Mexicano del Seguro Social*, 48(2), 163–166.
- Sanyaolu, A., Okorie, C., Marinkovic, A., Patidar, R., Younis, K., Desai, P., Hosein, Z., Padda, I., Mangat, J., & Altaf, M. (2020). Comorbidity and it's impact on patients with COVID-19. *Comprehensive Clinical Medicine*, 2, 1069–1076. <https://doi.org/10.1007/s42399-020-00363-4>/Published
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. En *SN Computer Science* (Vol. 2, Número 3). Springer. <https://doi.org/10.1007/s42979-021-00592-x>
- Secretaría de Salud. (2020, abril 11). *Comunicado Técnico Diario Información internacional y nacional sobre nuevo coronavirus con corte al 11 de marzo de 2020*. Conferencia 11 de marzo. <https://coronavirus.gob.mx/2020/03/11/conferencia-11-de-marzo/>
- Secretaría de Salud. (2023). *Informe Integral de COVID-19 en México*.
- Sheppard, E. (2001). Quantitative geography: Representations, practices, and possibilities. *Environment and Planning D: Society and Space*, 19(5), 535–554. <https://doi.org/10.1068/d307>
- Sierra-Alcocer, R., López-Ramírez, P., & González-Farías, G. (2022). A Dynamic Social Vulnerability Index to COVID-19 in Mexico. En *Advances in Geospatial Data Science* (pp. 177–193). *Advances in Geospatial Data Science*. https://doi.org/10.1007/978-3-030-98096-2_13
- Sinclair, H. M. (2016). White Plague, Mexican menace: Migration, race, class, and gendered contagion in El Paso, Texas, 1880-1930. En *Pacific Historical Review* (Vol. 85, Número 4, pp. 475–505). University of California Press. <https://doi.org/10.1525/phr.2016.85.4.475>
- Singh, A. K., Gupta, R., Ghosh, A., & Misra, A. (2020). Diabetes in COVID-19: Prevalence, pathophysiology, prognosis and practical considerations. *Diabetes and Metabolic Syndrome: Clinical Research and Reviews*, 14(4), 303–310. <https://doi.org/10.1016/j.dsx.2020.04.004>

- Sino Biological. (2023). *Hong Kong Flu (1968 Influenza Pandemic)*.
<https://www.sinobiological.com/research/virus/1968-influenza-pandemic-hong-kong-flu>
- Snacken, R., Kendal, A., Haaheim, L., & Wood, J. (1999). The Next Influenza pandemic: Lessons from Hong Kong, 1997. *Emerging Infectious Diseases*, 5(2), 195–203.
<https://doi.org/10.3201/eid0502.990202>
- Song, J., Lu, M., Zheng, L., Liu, Y., Xu, P., Li, Y., Xu, D., & Wu, W. (2018). Acute effects of ambient air pollution on outpatient children with respiratory diseases in Shijiazhuang, China. *BMC Pulmonary Medicine*, 18(1). <https://doi.org/10.1186/s12890-018-0716-3>
- Song, Y., Zhang, Y., Wang, T., Qian, S., & Wang, S. (2021). Spatio-temporal Differentiation in the Incidence of Influenza and Its Relationship with Air Pollution in China from 2004 to 2017. *Chinese Geographical Science*, 31(5), 815–828.
<https://doi.org/10.1007/s11769-021-1228-2>
- Su, D., Chen, Y., He, K., Zhang, T., Tan, M., Zhang, Y., & Zhang, X. (2020). Influence of socio-ecological factors on COVID-19 risk: a cross-sectional study 1 based on 178 countries/regions worldwide. *medRxiv*. <https://doi.org/10.1101/2020.04.23.20077545>
- Teller, J. (2021). Urban density and Covid-19: towards an adaptive approach. *Buildings and Cities*, 2(1), 150–165. <https://doi.org/10.5334/bc.89>
- Thai, P. Q., Choisy, M., Duong, T. N., Thiem, V. D., Yen, N. T., Hien, N. T., Weiss, D. J., Boni, M. F., & Horby, P. (2015). Seasonality of absolute humidity explains seasonality of influenza-like illness in Vietnam. *Epidemics*, 13, 65–73.
<https://doi.org/10.1016/j.epidem.2015.06.002>
- Tiwari, A., Dadhania, A. V., Rangunathrao, V. A. B., & Oliveira, E. R. A. (2021). Using machine learning to develop a novel COVID-19 Vulnerability Index (C19VI). *Science of the Total Environment*, 773. <https://doi.org/10.1016/j.scitotenv.2021.145650>
- Torres, J. (2020). *Python Deep Learning: Introducción práctica con Keras y TensorFlow 2* (Primera edición). Alfaomega.

- Truong, N., & Asare, A. O. (2021). Assessing the effect of socio-economic features of low-income communities and COVID-19 related cases: An empirical study of New York City. *Global Public Health*, 16(1), 1–16. <https://doi.org/10.1080/17441692.2020.1850830>
- Veiga, J., Cabo, D. E., De, E., Fuente Díez, L. A., & Zimmermann Verdejo, M. (2008). Modelos de estudios en investigación aplicada: conceptos y criterios para el diseño. *Medicina y Seguridad del Trabajo*, 210, 81–88.
- Vílchez, F. F., Jiménez, A. Á., González, O. N., & Pérez, M. G. G. (2022). Geographic Information Systems and spatial distribution of COVID 19 cases in Mexico. *Anales de Geografía de la Universidad Complutense*, 42(1), 65–83. <https://doi.org/10.5209/aguc.81796>
- Vopham, T., Hart, J. E., Laden, F., & Chiang, Y. Y. (2018). Emerging trends in geospatial artificial intelligence (geoAI): Potential applications for environmental epidemiology. En *Environmental Health: A Global Access Science Source* (Vol. 17, Número 1). BioMed Central Ltd. <https://doi.org/10.1186/s12940-018-0386-x>
- Wang, S. (2016). CyberGIS and spatial data science. *GeoJournal*, 81(6), 965–968. <https://doi.org/10.1007/s10708-016-9740-0>
- Wang, T., Zhang, Y., Liu, C., & Zhou, Z. (2022). Artificial intelligence against the first wave of COVID-19: evidence from China. *BMC Health Services Research*, 22(1). <https://doi.org/10.1186/s12913-022-08146-4>
- Weber-Chuliá, N., Bazán-Miranda, G., Cruz Maldonado, L. G., & Ángeles-Castellanos, A. M. (2022). Aspectos relevantes de las epidemias y pandemias en México: desde la perspectiva del derecho sanitario. *Revista de la Facultad de Medicina*, 65(4), 40–46. <https://doi.org/10.22201/fm.24484865e.2022.65.4.06>
- Weston, R. (2012). Whooping cough: A brief history to the 19th Century. *Canadian Bulletin of Medical History*, 29(2), 329–349. <https://doi.org/10.3138/cbmh.29.2.329>
- Wheelis, M. (2002). Biological Warfare at the 1346 Siege of Caffa. *Emerging Infectious Diseases*, 8(9). <https://doi.org/10.3201/eid0809.010536>

- Wolkoff, P., Azuma, K., & Carrer, P. (2021). Health, work performance, and risk of infection in office-like environments: The role of indoor temperature, air humidity, and ventilation. En *International Journal of Hygiene and Environmental Health* (Vol. 233). Elsevier GmbH. <https://doi.org/10.1016/j.ijheh.2021.113709>
- Woo, P. C. Y., Lau, S. K. P., Yip, C. C. Y., Huang, Y., & Yuen, K. Y. (2009). More and more coronaviruses: Human coronavirus HKU1. En *Viruses* (Vol. 1, Número 1, pp. 57–71). <https://doi.org/10.3390/v1010057>
- World Health Organization. (2003, marzo). *Global Alert: Severe Acute Respiratory Syndrome (SARS)*. Epidemiological Bulletin. https://www3.paho.org/English/dd/ais/be_v24n1-SARS.htm
- World Health Organization. (2020a, marzo 11). *WHO Director-General's opening remarks at the media briefing on COVID-19 - 11 March 2020*. WHO Director-General. <https://www.who.int/director-general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020>
- World Health Organization. (2020b, diciembre 23). *A year without precedent: WHO's COVID-19 response*. World Health Organization. <https://www.who.int/news-room/spotlight/a-year-without-precedent-who-s-covid-19-response>
- World Health Organization. (2020c, diciembre 23). *World Health Organization. A year without precedent: WHO's COVID-19 response*. <https://www.who.int/news-room/spotlight/a-year-without-precedent-who-s-covid-19-response>
- World Health Organization. (2023a). *Disease information Specific infectious diseases of potential risk for travellers*. <https://www.who.int/travel-advice/disease-information>
- World Health Organization. (2023b). *Severe Acute Respiratory Syndrome (SARS)*. https://www.who.int/health-topics/severe-acute-respiratory-syndrome#tab=tab_1
- Worldometers. (2022). *Worldometers COVID-19*. Worldometers. <https://www.worldometers.info/coronavirus/>

- Xiang, Z., Wang, H., & Li, H. (2024). Comorbidity risk and distribution characteristics of chronic diseases in the elderly population in China. *BMC Public Health*, *24*(1). <https://doi.org/10.1186/s12889-024-17855-w>
- Xie, J., Teng, J., Fan, Y., Xie, R., & Shen, A. (2019). The short-term effects of air pollutants on hospitalizations for respiratory disease in Hefei, China. *International Journal of Biometeorology*, *63*(3), 315–326. <https://doi.org/10.1007/s00484-018-01665-y>
- Xu, M., Cao, C., Zhang, X., Shea, D. R., Lin, H., Yao, Z., Zhong, S., & Huang, Z. (2021). Fine-scale space-time cluster detection of COVID-19 in mainland China using retrospective analysis. *International Journal of Environmental Research and Public Health*, *18*(7). <https://doi.org/10.3390/ijerph18073583>
- Xu, R., He, J.-F., Evans, M. R., Peng, G.-W., Field, H. E., Yu, D.-W., Lee, C.-K., Luo, H.-M., Lin, W.-S., Lin, P., Li, L.-H., Liang, W.-J., Lin, J.-Y., & Schnur, A. (2004). Epidemiologic Clues to SARS Origin in China. *Emerging Infectious Diseases*, *10*(6), 1030–1037. <https://doi.org/10.3201/eid1006.030852>
- Yang, Z., Zeng, Z., Wang, K., Wong, S. S., Liang, W., Zanin, M., Liu, P., Cao, X., Gao, Z., Mai, Z., Liang, J., Liu, X., Li, S., Li, Y., Ye, F., Guan, W., Yang, Y., Li, F., Luo, S., ... He, J. (2020). Modified SEIR and AI prediction of the epidemics trend of COVID-19 in China under public health interventions. *Journal of Thoracic Disease*, *12*(3), 165–174. <https://doi.org/10.21037/jtd.2020.02.64>
- Youri Ghendon. (1994). Introduction to pandemic influenza through history. *European Journal of Epidemiology*, *10*, 451–453.
- Yuan, J., Yun, H., Lan, W., Wang, W., Sullivan, S. G., Jia, S., & Bittles, A. H. (2006). A climatologic investigation of the SARS-CoV outbreak in Beijing, China. *American Journal of Infection Control*, *34*(4), 234–236. <https://doi.org/10.1016/j.ajic.2005.12.006>
- Zaragoza Bastida, A., Hernández Tellez, M., Bustamante Montes, L. P., Medina Torres, I., Jaramillo Paniagua, J. N., Mendoza Martínez, G. D., & Ramírez Durán, N. (2012). Spatial and temporal distribution of tuberculosis in the state of Mexico, Mexico. *The Scientific World Journal*, *2012*. <https://doi.org/10.1100/2012/570278>

- Zárate, S., Taboada, B., Muñoz-Medina, J. E., Iša, P., Sanchez-Flores, A., Boukadida, C., Herrera-Estrella, A., Selem Mojica, N., Rosales-Rivera, M., Gómez-Gil, B., Salas-Lais, A. G., Santacruz-Tinoco, C. E., Montoya-Fuentes, H., Alvarado-Yaah, J. E., Molina-Salinas, G. M., Espinoza-Ayala, G. E., Enciso-Moreno, J. A., Gutiérrez-Ríos, R. M., Loza, A., ... Arias, C. F. (2022). The Alpha Variant (B.1.1.7) of SARS-CoV-2 Failed to Become Dominant in Mexico. *Microbiology Spectrum*, 10(2). <https://doi.org/10.1128/spectrum.02240-21>
- Zhang, D. S., He, J., Gao, S. H., Hu, B. K., & Ma, S. L. (2011). Correlation analysis for the attack of respiratory diseases and meteorological factors. *Chinese Journal of Integrative Medicine*, 17(8), 600–606. <https://doi.org/10.1007/s11655-011-0821-0>
- Zhang, R., Li, Y., Zhang, A. L., Wang, Y., & Molina, M. J. (2020). Identifying airborne transmission as the dominant route for the spread of COVID-19. *The Proceedings of the National Academy of Sciences (PNAS)*, 117(26), 14857–14863. <https://doi.org/10.1073/pnas.2009637117/-/DCSupplemental>
- Zhao, Q., Meng, M., Kumar, R., Wu, Y., Huang, J., Lian, N., Deng, Y., & Lin, S. (2020). The impact of COPD and smoking history on the severity of COVID-19: A systemic review and meta-analysis. *Journal of Medical Virology*, 92(10), 1915–1921. <https://doi.org/10.1002/jmv.25889>