



Universidad Autónoma del Estado de México
Facultad de Geografía
Doctorado en Geografía y Desarrollo Geotecnológico

Desarrollo de un índice espacial dinámico de vulnerabilidad ante COVID-19 en México

Tesis
Que para optar por el grado de:
Doctor en Geografía y Desarrollo Geotecnológico

Presenta:
Christian Ivan Sánchez Carrillo

Comité tutorial
Dra. en Geog. Giovanna Santana Castañeda
Dra. en Geog. Marcela Virginia Santana Juárez
Dra. en T. y SIG. Emmanuelle Quentin

Toluca, México. Septiembre, 2023

Índice

Introducción.....	1
Capítulo 1. Reflexiones acerca de la relación entre el lugar y la enfermedad, y los índices de vulnerabilidad.....	5
1.1 Relación entre el lugar y la enfermedad.....	6
1.1.1 Edad antigua.....	6
1.1.2 Edad media.....	6
1.1.3 Edad moderna.....	7
1.1.4 Edad contemporánea.....	8
1.2 Geotecnologías aplicadas en el estudio de la enfermedad.....	13
1.2.1 Geotecnologías precursoras en el estudio de la enfermedad y su utilidad.....	14
1.2.2 Tendencias geotecnológicas en el estudio de la enfermedad y su utilidad.....	16
1.3 Desarrollo de índices de vulnerabilidad ante enfermedades.....	23
1.3.1 Análisis de vulnerabilidad en América Latina.....	23
1.3.2 Determinantes Sociales de la Salud y su relación con el análisis de vulnerabilidad.....	26
1.3.3 Índices de vulnerabilidad social y ante COVID-19.....	28
1.4 Conclusiones teóricas.....	33
Capítulo 2. Metodología para el desarrollo de un índice espacial dinámico de vulnerabilidad ante COVID-19.....	34
2.1 Diseño y área de estudio.....	35
2.2 Selección de variables y fuentes de información.....	37
2.2.1 Estatus socioeconómico.....	37
2.2.2 Características de la población.....	38
2.2.3 Condiciones de vivienda e higiene.....	38
2.2.4 Factores epidemiológicos.....	39
2.2.5 Factores del sistema de salud.....	40
2.3 Procesamiento y análisis de datos.....	42
2.3.1 Estructuración de la base de datos.....	43
2.3.2 Análisis espaciotemporal.....	45
2.3.3 Análisis estadístico.....	46
2.3.4 Análisis de correlación.....	47
2.3.5 Análisis de factores.....	48
a) Preprocesamiento de datos.....	48
b) Análisis de Componentes Principales.....	51
2.3.6 Análisis de sensibilidad.....	53
2.4 Conclusiones metodológicas.....	54
Capítulo 3. Dinámica espaciotemporal de COVID-19 en México.....	55
3.1 Distribución espacial de COVID-19.....	56
3.2 Contexto temporal de COVID-19 y medidas de seguridad sanitaria.....	58
3.3 Conglomerados espaciotemporales de casos confirmados de COVID-19.....	61

3.4 Conglomerados espaciotemporales de defunciones de COVID-19	65
3.5 Conclusiones de la dinámica espaciotemporal de COVID-19	69
Capítulo 4. Contexto espacial y estadístico de factores de riesgo relacionados con COVID-19....	70
4.1 Distribución espacial de factores de riesgo relacionados con COVID-19.....	71
4.2 Estadísticas descriptivas de factores de riesgo relacionados con COVID-19	85
4.3 Correlación de factores de riesgo relacionados con COVID-19.....	87
4.4 Conclusiones del contexto espacial y estadístico de factores de riesgo relacionados con COVID-19	90
Capítulo 5. Índice espacial dinámico de vulnerabilidad ante COVID-19 en México.	91
5.1 Índice espacial dinámico de vulnerabilidad ante COVID-19 (2020-2022).....	92
5.2 Índice espacial dinámico de vulnerabilidad ante COVID-19 (por ola epidémica)..	94
5.3 Evaluación de la robustez del ÍEDVC19	100
5.4 Discusión de los hallazgos del ÍEDVC19	101
VI. Conclusiones	107
VI.1 Conclusiones de la relación entre el lugar y la enfermedad, y los índices de vulnerabilidad	107
VI.2 Conclusiones de la metodología para el desarrollo de un ÍEDVC19.....	108
VI.3 Conclusiones de los resultados del ÍEDVC19	109
VII. Recomendaciones	110
Referencias bibliográficas	112
Anexos.....	134

Índice de figuras

Figura 1. Acontecimientos acerca de la relación entre el lugar y la enfermedad	12
Figura 2. Geotecnologías aplicadas al estudio de la enfermedad y su utilidad	22
Figura 3. Marco conceptual de los Determinantes Sociales de la Salud.....	27
Figura 4. Modelo eco-social y encarnación de inequidad	28
Figura 5. México. Localización geográfica y escala de análisis	36
Figura 6. Esquema metodológico.....	43
Figura 7. Estructura de la base de datos	45
Figura 8. México. Distribución espacial de tasas de casos confirmados y tasas de defunciones de COVID-19 (febrero 2020-diciembre de 2022).....	57
Figura 9. México. Casos confirmados y defunciones de COVID-19, y medidas de seguridad sanitaria (febrero de 2020-diciembre de 2022).....	60
Figura 10. México. Conglomerados espaciotemporales de casos confirmados de COVID-19 (febrero 2020 - diciembre 2022).....	64
Figura 11. México. Conglomerados espaciotemporales de defunciones de COVID-19 (marzo 2020 - diciembre 2022).....	68
Figura 12. México. Dimensión: Estatus socioeconómico, 2020	72
Figura 13. México. Dimensión: Características de la población, 2020	74
Figura 14. México. Dimensión: Condiciones de vivienda e higiene, 2020	76
Figura 15. México. Dimensión: Factores epidemiológicos (egresos hospitalarios), 2020	79
Figura 16. México. Dimensión: Factores epidemiológicos (defunciones), 2020	82
Figura 17. México. Dimensión: Factores del sistema de salud, 2020	84
Figura 18. Matriz de correlación de Spearman de factores de riesgo relacionados con COVID-19	89
Figura 19. México. Índice espacial dinámico de vulnerabilidad ante COVID-19 (2020-2022).....	93
Figura 20. México. Índice espacial dinámico de vulnerabilidad ante COVID-19 (por ola epidémica)	99

Índice de cuadros

Cuadro 1. Estudios sobre índices de vulnerabilidad ante COVID-19.....	30
Cuadro 2. Dimensiones y factores de riesgo relacionados con COVID-19	40
Cuadro 3. Estadísticas descriptivas de factores de riesgo relacionados con COVID-19.....	86
Cuadro 4. Cifras del ÍEDVC19.....	94
Cuadro 5. Cifras del análisis de sensibilidad del ÍEDVC19	100

Resumen

Diversos factores de riesgo pueden hacer que determinados grupos sean más vulnerables a los resultados negativos de la pandemia de COVID-19 en México. Esta investigación plantea el desarrollo de un índice espacial dinámico que localice población vulnerable ante esta enfermedad. Se propone una metodología basada en análisis espaciotemporal y estadístico, utilizando datos estructurales y de salud de la población, y recuentos de casos acumulados mensuales de COVID-19 para ejecutar el modelo durante 2020-2022 y en cada ola epidémica. Además, el índice se validó estadísticamente mediante un análisis de sensibilidad. Los hallazgos muestran que la población más vulnerable se localiza en las regiones norte, este y península de Yucatán, así como en Oaxaca y la Ciudad de México (CDMX). En contraste, la parte centro (excepto CDMX), oeste y suroeste (Chiapas, Guerrero y Michoacán) exhiben una vulnerabilidad baja durante las oleadas de COVID-19. Este desarrollo geotecnológico para crear un índice de vulnerabilidad específico de la localización de población susceptible a lo largo de un evento pandémico, puede servir como apoyo para los funcionarios de salud pública en la toma de decisiones equitativas para el cuidado de los lugares particularmente afectados y prevenir futuros escenarios adversos.

Palabras clave: factores de riesgo, COVID-19, vulnerabilidad, índice

Abstract

Several risk factors may make certain groups more vulnerable to the negative outcomes of the COVID-19 pandemic in Mexico. This research proposes the development of a dynamic spatial index that locates the population vulnerable to this disease. A methodology based on spatiotemporal and statistical analysis, using structural and population health data, and monthly cumulative COVID-19 case counts to run the model during 2020-2022 and in each epidemic wave. In addition, the index was statistically validated using sensitivity analysis. The findings show that the most vulnerable population is located in the northern, eastern and Yucatan peninsula regions, as well as in Oaxaca and Mexico City (CDMX). In contrast, the central part (except CDMX), west and southwest (Chiapas, Guerrero and Michoacan) exhibit low vulnerability during COVID-19 surges. This geotechnological development to create a location-specific vulnerability index of susceptible populations throughout a pandemic event can support public health officials in making equitable decisions to care for particularly affected locations and prevent future adverse scenarios.

Key words: risk factors, COVID-19, vulnerability, index

Introducción

A partir del primer brote de coronavirus SARS-CoV-2 que causa la COVID-19 en Wuhan (China) en diciembre de 2019, la población, los gobiernos, los sistemas de salud y la economía han resentido los embates de esta enfermedad. Sin embargo, las personas que viven en núcleos urbanos han resultado más afectados, debido a que la propagación se da cuando una persona infectada está en contacto cercano con otra u otras, como lo señala la Organización de las Naciones Unidas (ONU, 2020) “el 90% de los casos de COVID-19 se concentra en las zonas urbanas del mundo”.

Además de las áreas urbanas, diversos factores estructurales y de salud de la población inciden en la vulnerabilidad ante COVID-19. En particular, el estatus socioeconómico (Gorris et al., 2021; Macharia et al., 2020), las características de la población (Gomes 2020; Zhou et al., 2020; COVID-19 NERC et al., 2020), las condiciones de vivienda e higiene (Kamis et al., 2021; Rosenthal et al., 2020), los factores epidemiológicos que se han asociado con un mayor riesgo de resultados graves de COVID-19 y en algunos casos la muerte (Wang et al., 2020; Macharia et al., 2020; COVID-19 NERC et al., 2020). Así como los factores relacionados con el sistema de salud (Gallegos, 2020; Barrera-Algarín et al., 2020).

En la región de las Américas, México se encuentra entre los países más afectados debido a la pandemia. De acuerdo con estimaciones de la Universidad Johns Hopkins, en junio de 2023 ocupó el cuarto lugar de casos confirmados acumulados con 7,483,444 y el tercero en defunciones (333,188), este último puesto por detrás de Estados Unidos y Brasil, que registraron 1,123,836 y 699,310 muertes, respectivamente (JHU, 2023). No obstante, durante el primer año de pandemia, México tuvo una de las tasas de prueba de COVID-19 per cápita más bajas, con alrededor de 17 pruebas por cada 1,000 personas (Pérez, 2020), factor que puede inferir en subregistros de esta enfermedad.

Desde la visión espacial se han desarrollado índices de vulnerabilidad ante COVID-19 como apoyo a la planificación y priorización de lugares particularmente afectados, a nivel global destacan el COVID-19 Pandemic Vulnerability Index (PVI) (NIEHS, 2021), Time-varying community vulnerability index (Gorris et al., 2021) y Dynamic Social Vulnerability Index (DySoVI) (Sierra-Alcocer et al., 2022), debido a que iniciaron con la implementación de índices variables en el tiempo.

Al inicio de esta investigación, solo se tenía conocimiento de índices estáticos como Overall COVID-19 vulnerability index (Acharya y Porwal, 2020), Social Epidemiological Vulnerability Index (Macharia et al., 2020), índice de vulnerabilidad ante el COVID-19 (Suárez et al., 2020), entre otros. Sin embargo, con el avance de la pandemia también mejoraron los análisis, en específico, el DySoVI fue el primero que abordó la dinámica de la vulnerabilidad ante COVID-19 en México durante el primer año de pandemia (febrero 2020-febrero 2021).

En este contexto, se plantea el desarrollo un Índice Espacial Dinámico de Vulnerabilidad ante COVID-19 (ÍEDVC19) que, en términos generales, se refiere a la susceptibilidad de la población frente a los resultados negativos de la pandemia y brotes de enfermedades infecciosas, como la carga de enfermedad y las pérdidas humanas. Además, complementa la visión estática de la vulnerabilidad y aumenta la temporalidad de análisis en México, para responder a las siguientes interrogantes referentes a COVID-19:

¿Dónde hubo más casos confirmados?, ¿Dónde hubo más defunciones?, ¿Dónde se localizó la población en riesgo y durante cuánto tiempo estuvieron más expuestos a enfermar o morir?, ¿Cómo se distribuyen los factores de riesgo?, ¿Cómo se distribuye la población vulnerable?, ¿Dónde se encuentra la población más vulnerable?, ¿Dónde se encuentra la población menos vulnerable?, ¿Qué características socioeconómicas y de salud tienen los territorios más vulnerables?, ¿Cuántas olas epidémicas hubo de 2020 a 2022?, y ¿En qué ola epidémica se registró más población vulnerable?

La hipótesis que se plantea es la siguiente: En México, la conjunción de factores de riesgo relacionados con los casos confirmados y muertes por COVID-19 influyen en ciertos sectores de población que los hace más vulnerables, y temporalmente la distribución de estos grupos fue heterogénea en el territorio.

A partir de lo anterior, el objetivo general radica en desarrollar un índice que identifique la dinámica espaciotemporal de la población vulnerable ante COVID-19, mediante el uso de geotecnologías aplicadas al análisis de esta enfermedad y de sus posibles factores de riesgo, para localizar municipios susceptibles que a la postre sean resilientes ante eventos de esta naturaleza.

Para lograr el objetivo previo, se plantearon los siguientes objetivos particulares:

- i. Analizar la dinámica espaciotemporal de casos confirmados y defunciones de COVID-19, para describir su patrón de comportamiento.
- ii. Examinar la distribución espacial de posibles factores de riesgo relacionados con COVID-19, para explicar su incidencia en el territorio.
- iii. Desarrollar un índice de vulnerabilidad ante COVID-19, para localizar población susceptible en el espacio y en el tiempo.
- iv. Realizar un análisis de sensibilidad del índice de vulnerabilidad ante COVID-19, para determinar su confiabilidad.

Dado que la pandemia de COVID-19 ha representado el mayor reto sanitario para los gobiernos mundiales en el siglo XXI, es necesario contar con herramientas que localicen grupos de población vulnerables y conocer qué los hace estar en esta condición. Por lo anterior, la finalidad del ÍEDVC19 es aportar conocimiento e información geoespacial útil para que los funcionarios de salud pública diseñen estrategias de manera eficiente y acorde a la realidad territorial, además que la sociedad disminuya su susceptibilidad y sean más resilientes ante eventos de este tipo, porque esta pandemia no será la última.

La estructura capitular está dividida en cinco momentos. El capítulo 1, crea una reflexión acerca la relación entre el lugar y la enfermedad, y la utilidad de los índices de vulnerabilidad, a partir de los principales supuestos teóricos de las escuelas del pensamiento y la ciencia geográfica; la identificación de las geotecnologías que se han empleado en estudios de enfermedades (precursoras y tendencias); y de la conexión causal de los determinantes sociales de la salud y las desigualdades en salud, que son base para el desarrollo de índices de vulnerabilidad ante COVID-19.

El segundo capítulo describe la metodología aplicada para el desarrollo del ÍEDVC19, mediante la definición del diseño y área de estudio; la explicación analítica de las variables seleccionadas que han sido asociadas con esta enfermedad en diversos estudios; así como la mención de las fuentes de información de donde se obtuvieron las bases de datos; por último, se explican las técnicas y herramientas geotecnológicas empleadas en cada etapa que integran el apartado "procesamiento y análisis de los datos".

El capítulo 3, expone un panorama de la dinámica espaciotemporal de COVID-19, de acuerdo con mapas de distribución de las tasas de casos confirmados y defunciones

(acumulados); así como de su serie temporal (febrero 2020-diciembre 2022) y de las medidas de seguridad sanitaria impuestas por el Gobierno de México. Además, se muestran mapas de conglomerados espaciotemporales de tasas altas de ambas condiciones de salud, que permitieron identificar agrupaciones tanto en el espacio como en el tiempo y durante cuánto tiempo ocurren.

El cuarto capítulo refleja el contexto espacial y estadístico de factores de riesgo relacionados con COVID-19, a partir de mapas de distribución de 25 indicadores divididos en cinco dimensiones (estatus socioeconómico, características de la población, condiciones de vivienda e higiene, factores epidemiológicos y factores del sistema de salud). Asimismo, se muestran las estadísticas descriptivas y los resultados de la prueba de normalidad Shapiro-Wilk, así como los resultados de la matriz de correlación de Spearman, estas técnicas son utilizadas para analizar la distribución de los datos y descartar indicadores que presenten falta excesiva de datos y redundancia de información.

El capítulo 5, revela los resultados del ÍEDVC19, en primera instancia se muestra un mapa de distribución del índice durante el periodo 2020-2022; posteriormente, se evidencia la dinámica espaciotemporal de la vulnerabilidad ante COVID-19, a través de cinco mapas de distribución del ÍEDVC19 definidos por la duración de cada ola epidémica. El capítulo finaliza con los resultados de la validación del índice y la discusión de los hallazgos. Finalmente, se plantean las conclusiones de la investigación y se proponen algunas recomendaciones.

Capítulo 1. Reflexiones acerca de la relación entre el lugar y la enfermedad, y los índices de vulnerabilidad.

La intención de este capítulo es crear una reflexión acerca de la importancia de la ubicación geográfica (lugar donde vivimos) en el estudio de la enfermedad, a partir de los acontecimientos que han marcado una pauta en esta línea de investigación, aunado a la relevancia de los índices de vulnerabilidad ante enfermedades, en específico, ante COVID-19, que tiene sus orígenes en el análisis de la vulnerabilidad social en salud y el enfoque conceptual de los determinantes sociales de la salud.

1.1 Relación entre el lugar y la enfermedad

1.1.1 Edad antigua

Al comienzo de la historia de la humanidad, la manera de abordar las enfermedades había sido una mezcla de empirismo, magia y religión. Laín (1970) y Rodríguez (2015) refieren que “los sacerdotes eran los únicos intermediarios entre la divinidad y el hombre, los administradores exclusivos de la curación de las afecciones, que se llevaba a cabo en los grandes templos de Grecia durante el siglo V”.

Con la necesidad de sanar a los enfermos que acudían a los templos y fuera de ellos donde recurrían a prácticas supersticiosas, nace una medicina racional que sienta bases del conocimiento científico (López, 1986). La escuela de Cos o hipocrática, fundada por el médico griego Hipócrates (460 a.C. - 370 a.C.) quien tiempo después sería nombrado el padre de la medicina moderna.

Esta escuela del pensamiento rechazó la idea acerca de las creencias populares, que indicaban a las fuerzas sobrenaturales o divinas, como causantes de las enfermedades. Tisnés (2014) plantea que “su argumento principal fue que la enfermedad no era un castigo infligido por los dioses, sino la consecuencia del estilo de vida y factores ambientales de los lugares”.

Jori (2013) añade que “esta escuela elaboró una teoría ambiental de base fisiológica según la cual determinados agentes del medio físico especialmente la temperatura y la humedad pueden condicionar el equilibrio interno de los humores, siendo; por lo tanto, causas eficientes de la enfermedad y la muerte”.

La obra “el Corpus Hippocraticum” incluye el tratado de los aires, las aguas y los lugares, donde el sabio griego discute el surgimiento de determinadas afecciones, a partir de la observación cuidadosa del medio ambiente físico donde se había producido la enfermedad, es decir, factores geográficos como el lugar, el estado de la atmósfera, la estación del año, entre otros (Curto, 1985; Peña et al., 2013).

1.1.2 Edad media

Los avances en la medicina que se tenían gracias a la escuela hipocrática sufrieron un retroceso y se volvió a las creencias empírico-religiosas de la enfermedad. Tavera (2005) argumenta que “se debió a la influencia del oscurantismo (siglos VI-XIV): absolutismo religioso de la Edad Media, impuesto por las religiones imperantes, donde

el dogma de la fe recayó también sobre la ciencia la cual era toda una potencial amenaza para las verdades constituidas”.

Durante este suceso la idea de que el contagio era una fuente de enfermedad, común a casi todos los pueblos antiguos, fue paulatinamente desplazada por creencias religiosas donde la salud y la enfermedad significaban el castigo o el perdón divinos (Szelezsán, 2006; Pan-Montojo, 2020). Las personas que practicaban ciencia durante el oscurantismo eran consideradas paganos, brujos o hechiceros.

1.1.3 Edad moderna

Tiempo después, durante los siglos XV-XVI surge en Florencia-Italia un movimiento de transformación cultural que buscaba nuevos horizontes científicos en el campo de las artes, las ciencias naturales y humanas. El renacimiento: proceso de transformación que dirigió sus estudios en la fe, en la razón, en la naturaleza y, sobre todo, en el hombre y no en el absolutismo religioso, este proceso se caracterizó por el resurgimiento del hipocratismo (García, 2001; García, 2012).

Peset (2018) señala que “la noción de la enfermedad como una alteración de los humores volvió a tomar fuerza a partir de enfermedades heredadas y la aparición de otras, destacando la sífilis, que se relacionó con el Nuevo Mundo”. Pan-Montojo (2020) ratifica el resurgimiento de los postulados de la escuela de Cos, destacando que “las enfermedades empezaron de nuevo a observarse como el resultado de la interacción entre ser humano y naturaleza”.

En la segunda mitad del siglo XVII Thomas Sydenham (1624-1689) revalorizó la influencia del medio ambiente en la salud y enfermedad de las personas, retomando la obra de Hipócrates. Sydenham agregó sus propias observaciones sobre las condiciones meteorológicas de Londres, para relacionar el origen de tipos específicos de enfermedades con factores geográficos de esta ciudad como: determinadas alteraciones atmosféricas, climáticas, telúricas e incluso con las condiciones particulares de los individuos (Bascuñán, 2015).

Sus ideas y la de otros médicos como Johann Peter, Edwin Chadwick, Rudolf Virchow, entre otros, sobre la observación clínica y los factores geográficos en la constitución de endemias y epidemias se difundieron rápidamente en Europa y América dando origen a una corriente de pensamiento. El higienismo (siglo XVIII), como una

revalorización de los conceptos hipocráticos, sobre todo ante la necesidad de comprender las causas generales de las enfermedades (Santana, 2009; Rogers, 2021).

Fue hasta entonces que las autoridades comenzaron a preocuparse por las condiciones de vida y la salud de los ciudadanos. Alanís (2020) destaca que “una población sana era esencial, pues se necesitaban brazos fuertes para consolidar los nacientes estados nación, tanto para su defensa, como para la generación y comercialización de riqueza en un amplio sentido”, lo anterior al paso del inicio de la revolución industrial (1760-1840).

Los higienistas criticaban la falta de salubridad en las ciudades industriales, así como las condiciones de vida y trabajo de los empleados fabriles, proponiendo diversas medidas de tipo higiénico-social, pretendían contribuir a la mejora de la salud y las condiciones de existencia de la población, especialmente aquella conformada por las clases más bajas, trabajadores, obreros y sus familias, cuyas insalubres condiciones de vida y de trabajo se convertían en focos de enfermedad permanentes (Urteaga, 1980; Alcaide, 1990; Santana, 2009).

Bajo la perspectiva del higienismo se realizaron estudios denominados topografías o geografías médicas que perduraron hasta inicios del siglo XIX, estos informes detallaban las condiciones de salud, los datos meteorológicos e hidrológicos, las plantas y el modo de vida de los habitantes en una comunidad. Lo anterior servía para determinar la influencia que pudieran ejercer estos factores sobre la salud de la población, a partir de la combinación de estudios epidemiológicos, sanitarios y sociales (Cuéllar y Gutiérrez, 2014).

Los contenidos de las topografías médicas han sido considerados de gran interés teórico y epistemológico al incorporar factores físicos, biológicos y sociales relativos a la salud en un lugar determinado. De tal manera que pronto se convertirían en métodos de investigación para analizar problemas de salud en las comunidades europeas, especialmente realizadas por médicos alemanes, franceses e ingleses, y posteriormente se expandieron a otras regiones del mundo (Casco, 2001; Gutiérrez y García-Ramos, 2018).

1.1.4 Edad contemporánea

Buzai (2021) refiere un estudio importante realizado en el marco de la transición desde el paradigma higienista al bacteriológico, la investigación sobre la epidemia de

cólera en Londres realizada por John Snow (1813-1858), quien aportó grandes conocimientos en el estudio de la epidemiología moderna y la representación cartográfica de enfermedades.

En 1854 Snow demostró que el cólera era causado por el consumo de aguas contaminadas con materias fecales al comprobar que los casos se agrupaban en las zonas donde el agua consumida estaba contaminada (Palomero y Alvariño, 2016). A partir de la cartografía de los pozos de agua del distrito de Soho, localizando como culpable el existente en la calle Broad. Luego, a la luz de lo observado en el mapa, recomendó a la comunidad clausurar las bombas de agua, de donde era obtenida para beber (Parkes, 2014).

En el siglo XX, en tiempos de posguerra (1948), 61 países crearon la Organización Mundial de la Salud, con la finalidad de cooperar entre ellos y con otros en la promoción de la salud (Gómez, 2009). Dentro del preámbulo se reemplazó el concepto de "ausencia de enfermedad", que hasta ese momento se aceptaba para definir a la salud, con otro, que habría de renovar la práctica médica. Desde entonces salud sería "un estado de bienestar donde influyen, en el más amplio sentido, aspectos físicos, mentales y aún sociales" (Tisnés, 2014).

Este concepto permeó en las ciencias médicas, pero también tomó fuerza en la geografía con la denominación de una nueva disciplina, la geografía médica en el Congreso de la Unión Geográfica Internacional (UGI) realizado en Lisboa-Portugal, en su primera etapa entre 1930 y 1970 basó sus métodos y objetivos en el estudio de la distribución de los complejos patógenos de Maximilien Sorre (1880-1962).

En su investigación "Complexes pathogènes et géographie médicale", Sorre demostró la importancia de la geografía como instrumento esencial para estudiar aquellos problemas de salud donde el paisaje es un elemento indisoluble en los ciclos del desarrollo de enfermedades (Pickenhayn, 2008).

Este estudio dio paso a la primera vertiente de la geografía médica, la ecología de las enfermedades infecciosas, Carter (2016) plantea que proponía una mirada holística a las afecciones, como un producto de relaciones complejas entre el lugar y el ser humano, donde el hombre es un integrante más del complejo, importante y especial, pero uno más (Sorre, 1933; citado en Curto, 1983).

Jacques May, en 1950, amplía la definición de los complejos patógenos con los “complejos geógenos” (aspectos sociodemográficos y económicos). El objetivo seguía siendo determinar las áreas de enfermedad y cartografiar su distribución espacial, principalmente, en el mundo subdesarrollado de clima tropical, para May la geografía médica consistía en el estudio sistémico de las enfermedades y de la población (Barcellos et al., 2018).

En la segunda mitad del siglo XX y con la idea de reconfigurar a la geografía como una ciencia exacta de procesos espaciales nace una segunda línea de investigación la epidemiología espacial iniciada por Torsten Hägerstrand en los años 1960, aplicada a la búsqueda de leyes de la difusión de enfermedades a través del espacio y del tiempo, para construir modelos y darles apoyo a los programas de salud (Carter, 2016)

Siguiendo esta línea, se realizaron estudios sobre difusión espacial de enfermedades, donde se destacó la importancia de la aplicación de análisis espaciales y el uso de los sistemas de información geográfica para comprender los patrones de difusión de enfermedades y de los servicios de salud (Pyle, 1969; McGlashan, 1972; Arroz, 1977; Gesler, 1986). Pese a los esfuerzos de sus impulsores la geografía médica no tenía mucha relevancia.

Carter (2016) considera que fue un campo subestimado tanto por la geografía como por las ciencias de la salud, con pocos estudiantes, y entonces, una falta de masa crítica que permitiera su despegue. Sin embargo, con la introducción de métodos cuantitativos y la búsqueda de modelos y leyes científicas que brindan las pautas de distribución espacial (Barcellos et al., 2018), se produjo una revolución geográfica que permeo en los métodos de análisis de enfermedades, incorporando modelos multicausales para estudios de nivel individual y modelos de riesgo colectivo.

A la par de la revolución geográfica, en 1976 durante la conferencia realizada en Tokio-Japón el grupo de trabajo en geografía médica, bajo la presidencia de la geógrafa Yola Verhasselt, evolucionó hacia geografía de la salud incluyendo un análisis integrado de las condiciones sociales que influyen en la salud de las poblaciones, desde los equipamientos asistenciales al contexto social, cultural y económico (Curto, 2008).

Íñiguez (1998) y Barcellos et al. (2018) plantean que “la geografía de la salud incluye dos líneas de investigación bien definidas. Por un lado, la geografía de las enfermedades (geografía médica tradicional) encargada de la identificación y análisis de

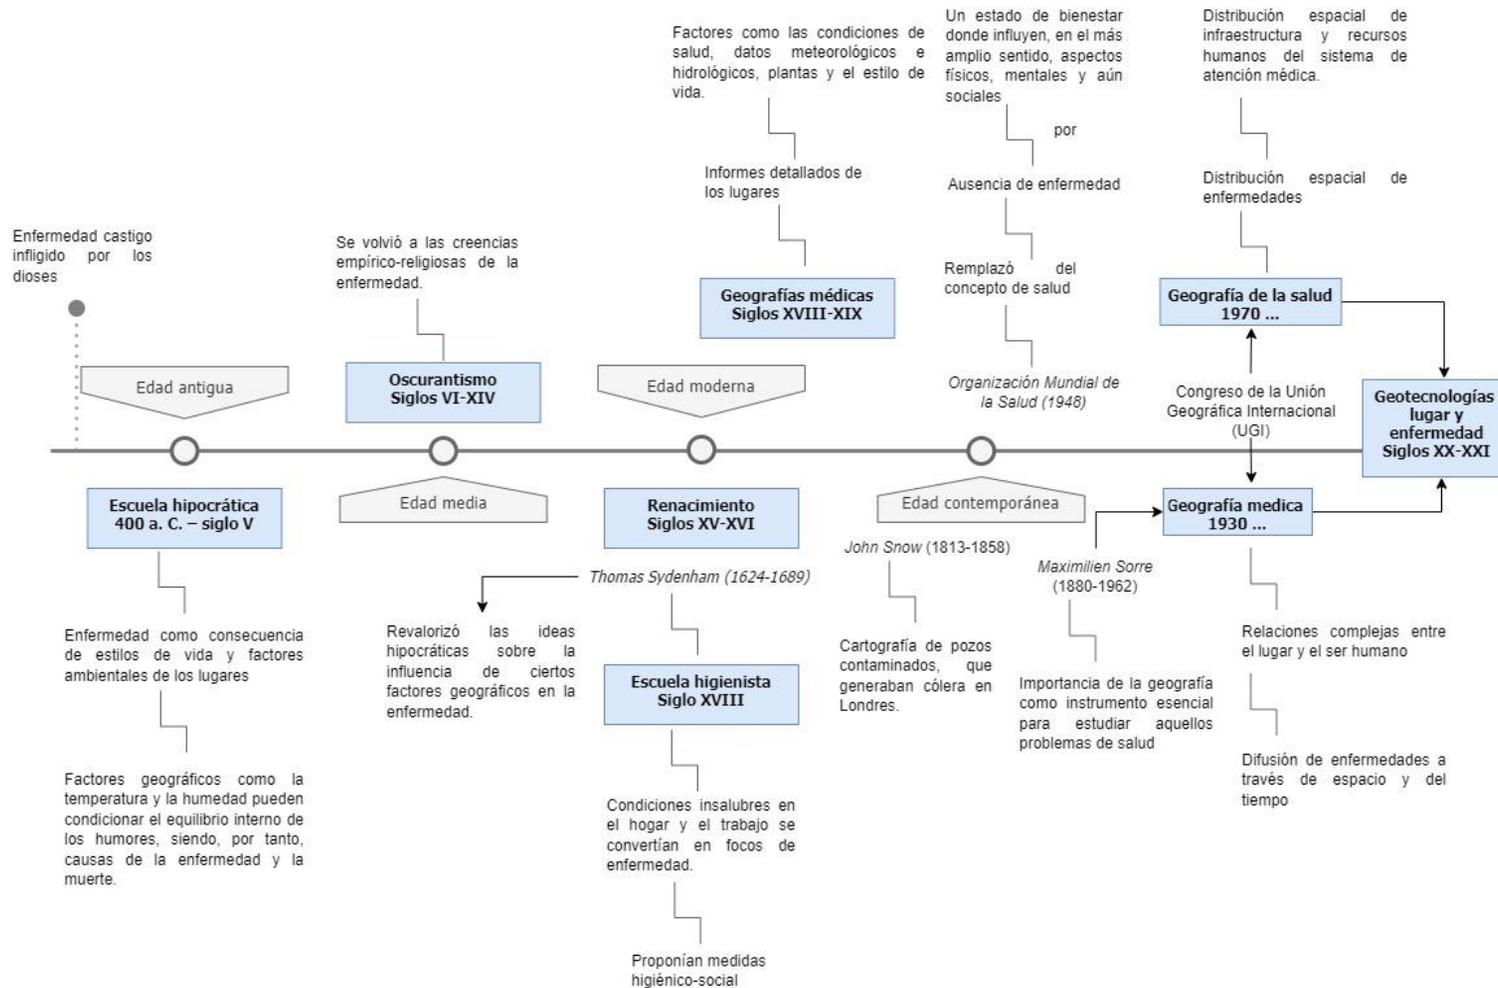
patrones de distribución espacial de enfermedades y por el otro, la geografía de los servicios de salud (geografía de la atención médica) ocupada de la distribución y planteamiento de componentes infraestructurales y de recursos humanos del sistema de atención médica”.

Ambas líneas tienen la finalidad de comprender el contexto en el que ocurren los problemas de salud y enfermedad, para poder actuar sobre territorios, no sobre los individuos ni sobre los organismos (Barcellos et al., 2018).

Santana (2014), señala que “la geografía de la salud busca comprender la dinámica del proceso salud-enfermedad y enfermedad-atención, para proporcionar conocimientos que sirvan para comprender las relaciones que se establecen entre las condiciones de salud y de la organización de los servicios de salud de las poblaciones y sus consecuencias en el desarrollo del territorio”.

Actualmente, la geografía médica y la geografía de la salud con apoyo de las tecnologías geoespaciales analizan eventos en salud como las enfermedades. Los Centers for Disease Control and Prevention (CDC, 2019) indican que bajo esta perspectiva la geografía y líneas de investigación a fines se centran en el lugar y el espacio, mirando qué, dónde y por qué ocurren los fenómenos, como los aspectos espaciales de la salud y la enfermedad (figura 1).

Figura 1. Acontecimientos acerca de la relación entre el lugar y la enfermedad



Fuente: Elaboración propia con base en Urteaga (1980); Tavera (2005); Pickenhayn (2008); Santana (2009); Jori (2013); Cuellar y García (2014); Parkes (2014); Tisnés (2014); Bascuñan (2015); Carter (2016); Barcellos et al. (2018); Centers for Disease Control and Prevention (2019).

1.2 Geotecnologías aplicadas en el estudio de la enfermedad

Las geotecnologías también nombradas tecnologías geoespaciales surgen como un nuevo paradigma o enfoque en geografía y campos relacionados a partir de la revolución tecnológica que se dio dentro de esta ciencia a finales del siglo XX, los avances permitieron nuevas posibilidades de análisis, transformando y enriqueciendo algunas de las técnicas y herramientas tradicionales de la geografía cuantitativa (Yang et al., 2010; Buzai, 2014).

En particular, las geotecnologías son un conjunto de herramientas que permiten recopilar, procesar, analizar y proporcionar información de referencia geográfica (Rosa, 2011; Cruz et al., 2017); incluyen los avances en la electrónica, computación, telecomunicaciones, desarrollo de nuevos sensores, entre otros (Moreno, 2015); que han generado una valorización de la geografía, así como de sus técnicas y métodos de análisis.

Moreno (2015) hace hincapié en que “el presente y futuro de esta ciencia resulta inconcebible sin ese potente y versátil conjunto de aparatos y sistemas con los que conviven a diario científicos, profesionales y, cada vez más, ciudadanos”. Dangermond y Goodchild (2020) refieren que la tecnología geoespacial permite a sus usuarios “ver lo que otros no pueden”, mediante el uso de mapas y estadísticas para revelar lo que de otro modo no sería visible, apreciado o entendido.

Actualmente, las geotecnologías se extienden a prácticamente todas las áreas de la actividad humana, ayudando a resolver problemas y tomar decisiones, predecir resultados, así como descubrir y explicar cómo funcionan los sistemas ambientales y sociales de la Tierra (Dangermond y Goodchild, 2020). Un área de estudio es la salud de la población, Richardson et al. (2013) plantean que “la difusión de estas tecnologías está permitiendo la creación de datos espaciales y temporales altamente precisos relevantes para la investigación en salud”.

Shaw y McGuire (2017) añaden que “estas nuevas tecnologías y las que están en desarrollo pueden mejorar significativamente la calidad y la eficiencia de la investigación en salud, debido a que se pueden establecer conexiones sustanciales entre la salud de una población y su ubicación geográfica”.

En este contexto, la utilidad de las geotecnológicas en el estudio de eventos de salud es amplia y cada vez más explorada por científicos geoespaciales, por lo anterior se describe la importancia de su utilidad en el estudio de enfermedades, desde las

precursoras como los Sistemas de Información Geográfica (SIG) y la teledetección hasta las nuevas tendencias que incluyen dos líneas de investigación como la geoanalítica y la Inteligencia Artificial Geoespacial y sus derivados.

1.2.1 Geotecnologías precursoras en el estudio de la enfermedad y su utilidad

Los SIG son la geotecnología con mayor aplicabilidad en estudios de salud pública, epidemiología y planificación de la salud, debido a que proporcionan los medios para almacenar, compartir, analizar y visualizar datos espaciales de salud archivados y en tiempo real. No obstante, en los años 80 hay pocos ejemplos del uso de estos sistemas, su funcionalidad se expandió rápidamente durante la década de 1990 y su crecimiento continúa en el siglo XXI (Cromley y McLafferty, 2012)

Buckeridge et al. (2002) consideran que “los SIG son recursos potencialmente poderosos para la salud de la comunidad por muchas razones, incluida su capacidad para integrar datos de fuentes dispares para producir nueva información, y sus funciones inherentes de visualización, que pueden promover la resolución creativa de problemas y decisiones acertadas con impactos positivos y duraderos en las vidas de las personas”.

Mediante los SIG se pueden analizar enfermedades específicas y otros eventos de salud se pueden modelar en relación con el entorno que los rodea y las infraestructuras sociales y de salud. Esta información, cuando se mapea en conjunto, crea una herramienta poderosa para el monitoreo y manejo de enfermedades (Vinnakota y Lam, 2006; Richardson et al., 2013).

Los resultados que proporcionan los SIG son precisos de los lugares donde se agrupan y distribuyen las enfermedades, esto nos ayuda a comprender dónde se propagan y cómo se pueden minimizar o detener, a partir de métodos sistemáticos que vinculan los datos sobre enfermedades con las características del entorno que influyen en el territorio (Wall y Devine, 2000; Shaw y McGuire, 2017).

Desde el punto de vista de Blatt (2015), la experiencia y las herramientas de los geógrafos son esenciales en el desarrollo de sistemas de vigilancia de enfermedades, principalmente en nuestra comprensión de los procesos de detección y difusión. Por ejemplo, el modelo de vigilancia de enfermedades transmisibles con apoyo de SIG que formuló el Maryland Department of Health and Mental Hygiene en 1998.

Años después se crearon sistemas de vigilancia del dengue en países en desarrollo como Cuba, Nicaragua y México, donde a partir del mapeo de esta enfermedad se

ubicaron sitios de alto riesgo de transmisión (Álvarez et al., 2007; Chang et al., 2009; Martínez y Sánchez, 2016).

Otra utilidad de estos sistemas se centra en el análisis de asociación espacial entre factores de riesgo y enfermedades como lo argumenta el Spatial Sciences Institute (2021), el lugar donde las personas viven y trabajan puede tener correlaciones significativas con su susceptibilidad a enfermedades o lesiones.

Rushton (1998) y Gao et al. (2008) señalan que “los SIG permiten la aplicación de análisis espacial y en conjunto examinan la relación entre la incidencia de enfermedades e información que está georreferenciada de manera distinta a los datos de la enfermedad, como los datos sociales, demográficos, ambientales, entre otros”.

Hipp y Chalise (2015) añaden que “el análisis espacial incluye métodos de regresión a nivel territorial y han ganado una atención creciente en los últimos años, debido a que este enfoque permite un análisis de posibles factores de riesgo que a menudo no están disponibles a nivel individual debido a restricciones de privacidad”.

La visualización SIG permitió identificar asociaciones espaciales entre datos sociales y meteorológicos con casos notificados de tuberculosis en China (Zhang et al., 2019; Liao et al., 2020); en EE. UU. se ha demostrado la relación estadística entre diabetes y pobreza, así como la población no blanca, la cual varía en función de la ubicación (Siordia et al., 2012; Hipp y Chalise, 2015); otro factor de riesgo que ha registrado asociación con la diabetes son las personas mayores y depende en gran medida del lugar de residencia (Kauhl et al., 2016).

De manera similar, se han asociado variables socioeconómicas y la contaminación del aire con tipos de cáncer en EE. UU. y China (Thatcher et al., 2021; Xing et al., 2019); en países de África Oriental el VIH/SIDA ha tenido correlaciones significativas con factores de riesgo sociales y conductuales (Chimoyi y Musenge, 2014; Barankanira et al., 2015; Nutor et al., 2020).

La teledetección es otra geotecnología pionera en el estudio de enfermedades, como lo plantean Beck et al. (2000) “un número cada vez mayor de estudios de salud ha utilizado datos de teledetección para el seguimiento, la vigilancia o el mapeo de riesgos, en particular de las enfermedades transmitidas por vectores”. Específicamente analizan las relaciones entre los factores patológicos (agentes causantes, vectores y huéspedes, personas) y sus entornos geográficos (Cromley, 2003).

La mayor utilidad de esta geotecnología radica en la capacidad de adquirir información climática, meteorológica (temperatura, humedad, precipitaciones) y ecológica de la superficie terrestre que permiten la viabilidad de ciertos patógenos en la naturaleza (Rotela et al., 2014).

Correia et al. (2004) añaden que “esta información junto con los estudios de campo apropiados se puede utilizar para identificar y cartografiar los posibles hábitats de parásitos y vectores de enfermedades; predecir alteraciones en poblaciones de vectores y parásitos, monitoreando alteraciones cuantitativas y cualitativas en los respectivos hábitats; y planificar programas de control, indicando áreas de mayor y menor riesgo de la enfermedad”.

En este sentido, a través de la teledetección se ha demostrado correlaciones significativas entre enfermedades parasitarias como la malaria y la esquistosomiasis con variables ambientales en Filipinas (Leonardo et al., 2005; Walz et al., 2015). Asimismo, se han explorado patrones espaciotemporales de la enfermedad de Lyme para probar la hipótesis de las relaciones entre el clima y esta enfermedad a partir del cálculo de índices espectrales (Brownstein et al., 2005; Ozdenerol, 2015).

1.2.2 Tendencias geotecnológicas en el estudio de la enfermedad y su utilidad

Desde mediados de la década de 1980, el mundo ha experimentado una explosión sin precedentes en la capacidad de producir, almacenar y comunicar datos, principalmente en formatos digitales. Al mismo tiempo, el acceso a las tecnologías informáticas en forma de PC personal, teléfono inteligente y otros dispositivos portátiles ha reflejado este crecimiento (Hilbert y López, 2011; Austin y Kusumoto, 2016).

Estas tecnologías, la inteligencia artificial y el big data pueden ayudar a manejar la enorme cantidad de datos derivados de la vigilancia de la salud pública, el monitoreo de brotes epidémicos en tiempo real, pronósticos de tendencias actuales, información periódica sobre la situación y actualización de instituciones y organismos gubernamentales, e información sobre la utilización de los recursos sanitarios (Bragazzi et al., 2020).

Boulos y Koh (2021) consideran que con los avances tecnológicos los enfoques tradicionales de investigación en SIG se han vuelto más inteligentes, y señalan dos áreas de rápido crecimiento con aplicaciones prometedoras en la formulación y monitoreo de intervenciones de salud pública, la geoanalítica y la GeoAI.

La geoanalítica es definida como la combinación de macrodatos (big data) basados en la ubicación con funcionalidades de análisis avanzadas en un sitio web o aplicación (de escritorio o móvil), lo que permite la consulta, el análisis y la visualización de datos interactivos. Estos conjuntos de datos se caracterizan por su alto volumen, velocidad, variedad, exhaustividad, resolución e indexicalidad, relacionalidad y flexibilidad (Kitchin, 2013; Boulos y Koh, 2021).

La tecnología para capturar y administrar datos y la geoanalítica están evolucionando a un ritmo espectacular en la academia, en el sector industrial, financiero y sanitario. La lente geoespacial ha transformado las formas de pensar sobre la enfermedad, el medio ambiente, la socioeconomía y la salud (Greenough y Nelson 2019; Yang et al., 2020).

La geoanalítica se apoya de big data, entendido como la integración de datos que es difícil de manejar con las herramientas de gestión de bases de datos existentes, que tiene tanto características masivas como características de complejidad, como los datos de salud (Yang et al., 2020). El uso de big data ofrece una multitud de posibilidades para obtener nuevos conocimientos sobre los datos de salud mediante nuevos procesos basados en datos para abordar los problemas actuales de este sector (Rüping, 2015).

Austin y Kusumoto (2016) plantean que “la revolución de big data en el cuidado de la salud está en marcha, impulsada por un crecimiento exponencial de los datos disponibles recopilados en registros electrónicos o sensores portátiles. Estos datos se recopilarán, almacenarán y analizarán con la esperanza de descubrir secretos que conduzcan a una mejor calidad de vida y a la cura de enfermedades”.

La utilidad de big data ha sido reflejada en estudios como, Emilsson et al. (2015) donde señalan que en Suecia se inició con el primer registro sanitario en 1975 y para 2015 se contaba con 103,000, lo que llevo a hallazgos tales como la asociación espacial del tabaquismo y la artritis reumatoide; en EE. UU. el American College of Cardiology creó en 1997 el Registro Nacional de Datos Cardiovasculares, desde entonces hasta 2015 contaba con 15,000,000 registros de pacientes con alguna cardiopatía (Weintraub, 1998; Austin y Kusumoto, 2015).

Un estudio en marcha utiliza big data para reducir enfermedades cardiacas, a través de métricas en tiempo real adquiridas en sensores usados por el paciente, aplicaciones móviles, redes sociales y un portal web dedicado (Health eHeart, 2021);

Twitter es una de las redes sociales más utilizadas, y que ahora se utiliza en el análisis de big data para rastrear enfermedades transmitidas por alimentos y animales (Kuehn, 2014; Sun et al., 2020).

Por otra parte, la inteligencia artificial (IA), referida como los sistemas o máquinas que imitan la inteligencia humana para realizar tareas y pueden mejorar iterativamente a partir de la información que recopilan (Oracle, 2021) se ha utilizado cada vez más en la salud y la asistencia sanitaria, en particular con el aumento de las capacidades de computación en la nube y de alto rendimiento (Topol, 2019),

La IA combinada con SIG crean la Inteligencia Artificial Geoespacial (GeoAI por sus siglas en inglés) con principal énfasis en el cuidado de la salud mediante la ubicación o el lugar. Boulos et al. (2019) señalan que “los lugares en los que vivimos, trabajamos y pasamos nuestro tiempo están asociados con factores, que incluyen, entre otros, el entorno construido, las exposiciones ambientales y los determinantes sociales, que pueden afectar nuestra salud”.

La GeoAI cubre una gama de tecnologías para extraer información significativa y conocimiento de macrodatos geoespaciales utilizando inteligencia artificial y métodos de ciencia de datos, como data mining, machine learning, deep learning, entre otros, para apoyar a resolver problemas complejos y obtener conocimientos más profundos de forma innovadora (Boulos y Koh, 2021; Esri, 2021).

Las herramientas y aplicaciones de GeoAI tienen como objetivo utilizar todos estos métodos según sean relevantes para obtener información y conocimientos valiosos a partir de macrodatos espaciales para necesidades analíticas específicas (Goodfellow et al., 2016). GeoAI representa un dominio enfocado dentro de la inteligencia de salud que incorpora la ubicación para derivar información procesable que puede usarse para mejorar la salud humana (Boulos et al., 2019).

En este orden, Data Mining (DM) es el proceso computacional que a menudo se aplica para analizar grandes conjuntos de datos, descubrir patrones, extraer conocimiento procesable y predecir resultados de eventos futuros o desconocidos (Bellinger et al., 2017). Aunado a la exploración de patrones a partir de grandes conjuntos de datos para hacer recomendaciones apropiadas (Boulos et al., 2019).

Si bien los enfoques tradicionales de DM son los más utilizados en los estudios de salud, con la reevaluación de los datos espaciales existe una tendencia a incorporar

enfoques de la minería de datos (González y Pérez, 2013) con apoyo de imágenes de satélite, smartphone, redes de sensores y dispositivos GPS que han facilitado la recopilación de datos referenciados en el espacio y tiempo (Bogorny y Shekhar, 2010).

Bellinger et al. (2017) indican que “la minería de datos es una rama de DM que toma en cuenta la localización de los objetos y sus relaciones topológicas”. En este proceso se utilizan métodos basados en la generalización, en el reconocimiento de patrones de agrupamiento (González y Pérez, 2013).

En este contexto, se han desarrollado estudios de asociaciones espaciales y temporales (minería de reglas de asociación) entre variables socioeconómicas y la contaminación del aire con determinados tipos de cáncer en EE. UU. (Vinnakota y Lam 2006); en Brasil se encontró asociación espaciotemporal entre enfermedades como la malaria y leishmaniasis y la ocurrencia de incendios (Schroeder et al., 2020).

Además, en Utrecht (Países Bajos) se evaluó el rendimiento de un algoritmo de DM (reconocimiento de patrones) basado en el historial clínico electrónico para detectar el estado de tabaquismo en una población cardiovascular, la extracción de datos mostró un gran potencial para recuperar información sobre esta adicción (Katrien et al., 2020).

Machine learning (ML) es otro método de ciencia de datos utilizado en estudios de salud, incluye métodos y algoritmos de inteligencia artificial para que las computadoras obtengan conocimiento extrayendo y aprendiendo iterativamente de los patrones ocultos en los datos sin procesar (Goodfellow et al., 2016). ML utiliza un conjunto más amplio de técnicas estadísticas que las que se utilizan normalmente en salud (Panch et al., 2018).

Beam y Kohane (2018) indican que “ML amplía las técnicas estadísticas existentes, utilizando métodos que no se basan en suposiciones a priori sobre la distribución de los datos, y pueden encontrar patrones en los datos que a su vez pueden usarse para formular hipótesis y pruebas de hipótesis”.

En particular, un estudio generó una hipótesis relacionada con la etiología de nacimientos prematuros en EE. UU. se utilizó ML (agrupación de K-medias) para determinar los patrones espaciotemporales de la edad gestacional en el momento del parto para 145 millones de nacimientos en más de 3000 condados (Byrnes et al., 2015).

Hernández et al. (2013) modelaron la distribución espacial de los vectores de la enfermedad de Chagas mediante una encuesta a hogares rurales, esta información se

combinó con datos ambientales obtenidos de sensores remotos, mapas de uso de la tierra y datos topográficos, utilizando el algoritmo de ML "Random Forests".

Por su parte, Deep Learning (DL) se percibe ampliamente como un tipo de aprendizaje automático de vanguardia que permite a las computadoras simular la función cerebral para comprender conceptos complejos en el mundo real de manera más efectiva (Goodfellow et al., 2016). DL permite alimentar una máquina con grandes cantidades de datos brutos y descubrir las representaciones necesarias para su detección o clasificación (Panch et al., 2018).

Raví et al. (2017) indican que "DL se basa en redes neuronales artificiales y está surgiendo en los últimos años como una herramienta poderosa para el aprendizaje automático, que promete remodelar el futuro de la inteligencia artificial y su aplicabilidad a la salud".

En particular, un estudio utilizó redes neuronales convencionales en imágenes de Google Maps y Google Places para extraer elementos naturales y modificados del entorno construido (edificios, cruces de peatones, zonas verdes de las calles) para estudiar la relación con la obesidad a nivel del distrito censal y su prevalencia en los EE. UU. (Maharana y Nsoesie, 2018).

Wang et al. (2019) descubrieron a través de algoritmos de DL e imágenes de Street View que las percepciones del entorno del vecindario (rico, seguro, animado, deprimente, aburrido y hermoso) están asociadas con la disposición de los residentes a realizar actividad física en Guangzhou (China).

Otra tendencia geotecnológica en el estudio de la enfermedad son los lenguajes de programación, Jalal et al. (2017) indican que "a medida que aumenta la complejidad de las aplicaciones de la ciencia de la toma de decisiones en salud, estos lenguajes de alto nivel se adoptan cada vez más para análisis estadísticos y cálculos numéricos".

El lenguaje de programación es una herramienta que permite desarrollar software o programas para computadora, se emplea para diseñar e implementar programas encargados de definir y administrar el comportamiento de los dispositivos físicos y lógicos de una computadora (CUADED-UNAM, 2017).

Devin et al. (2019) plantean que "en la toma de decisiones en salud los lenguajes de programación modernos como R y Python facilitan el desarrollo de modelos que son,

clínicamente realistas; capaces de cuantificar la incertidumbre de la decisión; transparentes y reproducibles; reutilizables y adaptables”.

R y su extensa colección de paquetes relevantes para el análisis estadístico permite a los usuarios realizar tanto la estimación de parámetros (incluida la síntesis de evidencia) como la posterior simulación de la progresión y los resultados de la enfermedad en un entorno de software (Newton et al., 2012; Devin et al., 2019).

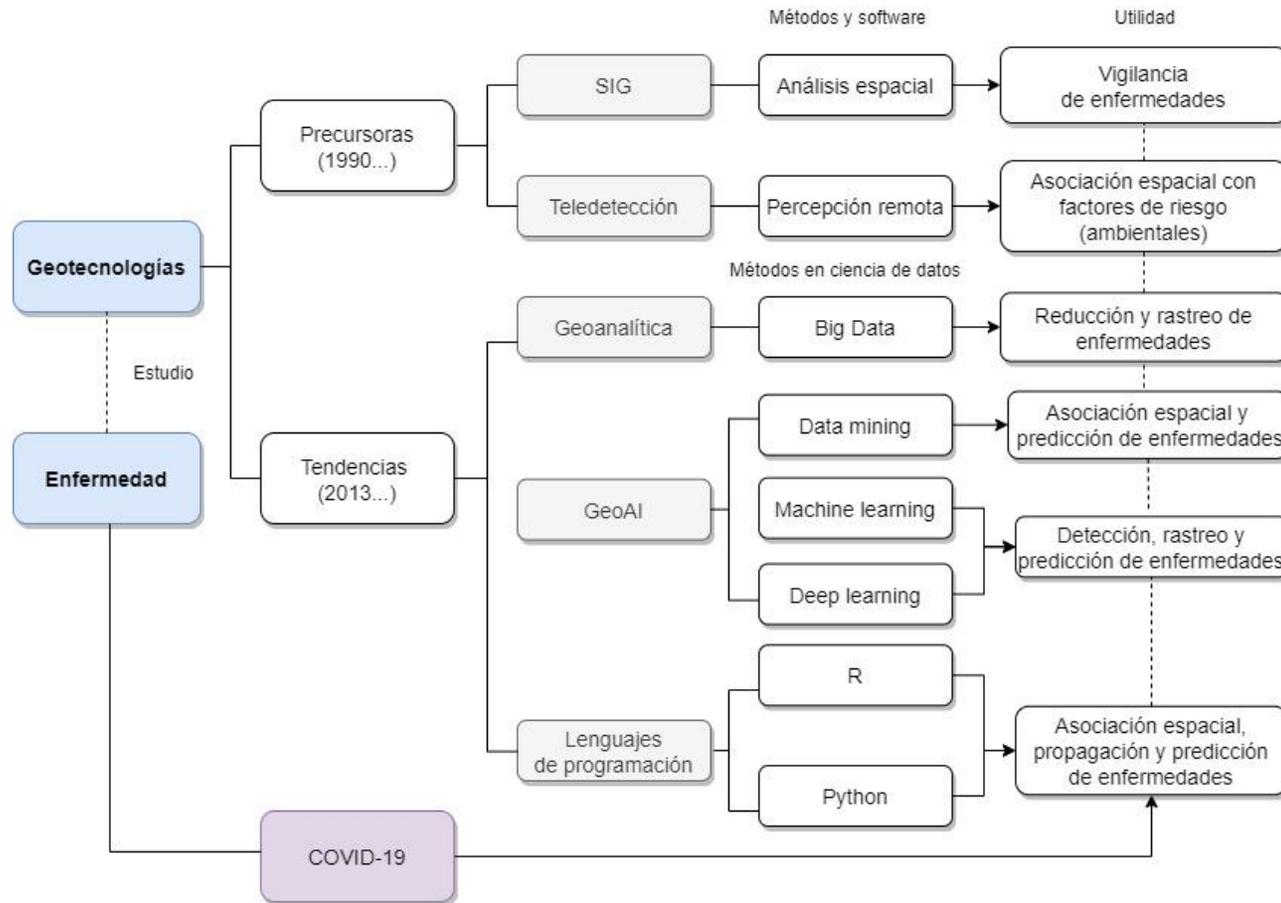
Por ejemplo, Readhead et al. (2020) describieron la distribución espacial de la incidencia de tuberculosis en el condado de Los Ángeles (EE. UU.), a partir de la utilización de R y R Studio, y una variedad de paquetes para administrar, analizar datos y crear mapas. En Pakistán, se aplicó un modelo lineal generalizado a factores climáticos, sociales y geográficos involucrados con el dengue para analizar la propagación espaciotemporal de esta enfermedad (Shabbir, Pilz y Naeem, 2020).

Python también ha sido aplicado en el estudio de la enfermedad, debido a que permite trabajar más rápidamente e integrar sus sistemas de manera más efectiva (Python, 2021). El código generado en este lenguaje de programación ha apoyado a desarrollar y evaluar estimadores que predicen qué pacientes en el conjunto de datos tiene mayor riesgo de hospitalización de una enfermedad, entre otras aportaciones (Doupe et al., 2019).

En particular, Ye et al. (2020) predijeron la mortalidad en pacientes diabéticos en estado crítico mediante un modelo predictivo de mortalidad generado con conjuntos de prueba y entrenamiento utilizando paquetes Python (scikit-learn) para aprendizaje automático y análisis estadístico. Rois et al. (2021) de manera similar, utilizaron scikit-learn en Python y un algoritmo (Boruta) en R Studio para identificar la prevalencia y factores de predicción del estrés percibido entre los estudiantes universitarios de Bangladesh.

En síntesis, las geotecnologías son herramientas importantes para el estudio de la enfermedad, desde las precursoras como los SIG y la teledetección, hasta los métodos en ciencia de datos y los lenguajes de programación, su utilidad se aplica cada vez más en análisis en ciencias médicas, epidemiología y geografía, esta última ha registrado aportaciones básicas como la vigilancia o mapeo de enfermedades y otros complejos como el rastreo y predicción de afecciones (figura 2).

Figura 2. Geotecnologías aplicadas al estudio de la enfermedad y su utilidad



Fuente: Elaboración propia con base en Cromley (2003); Richardson et al. (2013); Byrnes et al. (2015); Walz et al. (2015); Maharana y Nsoesie (2018); Devin et al. (2019); Zhang et al. (2019); Liao et al. (2020); Schroeder et al. (2020); Ye et al. (2020); Boulos y Koh (2021).

1.3 Desarrollo de índices de vulnerabilidad ante enfermedades

Antes del desarrollo de índices de vulnerabilidad social y ante enfermedades, es necesario conceptualizar ¿Qué es un índice? y ¿Qué es vulnerabilidad? En este sentido, "índice" en términos generales es un indicio o señal de algo (RAE, 2021), en estadística, es una medida compuesta a partir de múltiples datos que sirve para describir y comparar, de manera sucinta y clara, el comportamiento de ese conjunto de datos a lo largo del tiempo y entre los sujetos evaluados (IMCO, 2014).

En la práctica existen dos tipos de índices: el simple y el compuesto, el primero se refiere a la variación de una sola variable en el tiempo o espacio, mientras que el compuesto sintetiza la información de un conjunto seleccionado de indicadores y variables (Nardo y Saisana, 2009; Seffino y Etcheverría, 2020), es decir, son índices sintéticos de múltiples indicadores individuales.

El índice compuesto, a su vez, puede ser clasificado en ponderado y no ponderado. La principal diferencia entre estos es que a menudo, cuando calculamos un índice compuesto, queremos asignarles una importancia mayor a los cambios producidos en alguna de las variables más que en otras. En este caso, se utilizan índices ponderados (Seffino y Etcheverría, 2020).

Entre los índices compuestos se encuentran los índices de vulnerabilidad ante algún tipo de amenaza, sean eventos de origen físico como sequías, terremotos, inundaciones, enfermedades, o amenazas antropogénicas como contaminación, accidentes, hambrunas o pérdida del empleo (Ruiz, 2012).

1.3.1 Análisis de vulnerabilidad en América Latina

En América Latina, el análisis de vulnerabilidad se remonta al decenio de los setenta dentro de las ciencias naturales, en específico, en investigaciones en torno a desastres naturales y en 1979 la United Nations Disaster Relief Organization (UNDRO) propuso una de las primeras definiciones de vulnerabilidad (García y Tello, 2020; Cardona, 1993).

La definición incluía "el grado de pérdida de un determinado elemento en riesgo o conjunto de dichos elementos resultante de la ocurrencia de un fenómeno natural de determinada magnitud y expresado en una escala de 0 (sin daño) a 1 (pérdida total)" (UNDRO, 1979).

No obstante, el análisis de vulnerabilidad era dirigido hacia el detonante del desastre y la amenaza, y no hacia las condiciones que favorecen la ocurrencia de la crisis. A partir de 1980 y en especial en 1990, estudiosos de ciencias aplicadas, debatieron la postura de los naturalistas, postulando que, para producirse un desastre tiene que haber un impacto medible en el medio ambiente, sociedad o economía (Maskrey, 1998; Cardona, 2001).

De esta manera, el análisis de vulnerabilidad tomó un rumbo hacia las condiciones y disparidades físicas que favorecen los escenarios de desastres, Davis (1978) refiere que "se enfatizó en que los impactos asociados con las amenazas, en vez de ser homogéneos, demuestran grandes irregularidades en el espacio y el tiempo".

En particular, las ciencias aplicadas incorporaron a la vulnerabilidad en sus modelizaciones, mientras que los naturalistas se enfocaban a la amenaza, Cardona (1993) definió a la vulnerabilidad como la predisposición intrínseca de un elemento expuesto a ser afectado o de ser susceptible a sufrir un daño ante la ocurrencia de un suceso con una intensidad.

Desde otro punto de vista, en EE. UU. se desarrollaron estudios en ciencias sociales que abordaron los desastres naturales bajo esta perspectiva, investigaciones como la de Cutter et al. (2003) pusieron en la órbita científica un nuevo concepto, la vulnerabilidad social, definida como, "el producto de las desigualdades sociales, esos factores sociales que influyen o dan forma a la susceptibilidad de varios grupos al daño y que también gobiernan su capacidad de respuesta".

Este enfoque, plantea que la vulnerabilidad tiene un carácter social y no solamente está referida al daño físico potencial o a determinantes demográficas (Katzman 2000; Pizarro, 2001). En 1998 la Red de Estudios Sociales en Prevención de Desastres en América Latina (la RED) plantearon que la vulnerabilidad se configura socialmente y es el resultado de procesos económicos, sociales y políticos.

Incluidos estos procesos, a partir del año 2000 la Comisión Económica para América Latina y el Caribe (CEPAL) comenzó a desarrollar estudios utilizando el concepto de vulnerabilidad social, que se describe con mayor frecuencia utilizando las características individuales de las personas (edad, raza, salud, ingresos, tipo de unidad de vivienda, empleo) (Cutter et al., 2003).

Actualmente los CDC y la Agency for Toxic Substances and Disease Registry (CDC/ATSDR, 2021) conciben a la vulnerabilidad social como, "los posibles efectos negativos en las comunidades causados por tensiones externas sobre la salud humana. Tales tensiones incluyen desastres naturales o provocados por el hombre, o brotes de enfermedades. La reducción de la vulnerabilidad social puede reducir tanto el sufrimiento humano como las pérdidas económicas".

No obstante, la diversidad de definiciones depende de la dimensión analítica y áreas posibles de intervención, dada la variedad de fenómenos a los que se asocia y desde la perspectiva de uso en las ciencias. Por ejemplo, Busso (2001) plantea que "se generan condiciones diferenciales de vulnerabilidad a la pobreza, discriminación, enfermedad, incapacidad de satisfacer necesidades básicas, al acceso a empleos lícitos, entre otros".

El interés de esta investigación se centra en la vulnerabilidad a la enfermedad que es un tema implícito en el marco conceptual de la vulnerabilidad social con una connotación dirigida a la salud humana. Tal como lo plantean Cabieses et al. (2016) "la vulnerabilidad social, relacionada con la salud, tiene que ver con cómo la situación social en la que me encuentro como individuo influye e impacta en la gestión y acceso a las herramientas necesarias para afrontar diversas amenazas a mi propia salud".

Juárez et al. (2014) y Araujo (2015) indican que "en toda sociedad hay comunidades, familias e individuos cuya probabilidad de enfermar, morir o accidentarse es mayor que la de otros". Se ha dicho que tales grupos son especialmente vulnerables. Los que tienen menos ingresos son más vulnerables a eventos de salud negativos implicando que la posición socioeconómica es un hecho que parece ser generalizado para estos grupos (Ortiz et al., 2015).

Asociado a lo anterior, el Instituto Nacional de Salud Pública (INSP, 2020) a través de la línea de investigación en salud y grupos vulnerables, conciben a la vulnerabilidad social en salud como, "un resultado de las desiguales condiciones de vida, exposición y capacidades diferenciales para el manejo de riesgos, movilización de recursos y redes sociales, disponibilidad y acceso a servicios de salud, entre otras categorías que determinan la salud de los grupos sociales".

La falta de protección de grupos poblacionales específicos que presentan problemas de salud particulares, así como a las desventajas que enfrentan para resolverlos, en comparación con otros grupos (Juárez et al., 2014). Se adicionan al

conjunto de determinantes que inciden en la salud de la población que los hace vulnerables ante cualquier enfermedad o contingencia sanitaria.

1.3.2 Determinantes Sociales de la Salud y su relación con el análisis de vulnerabilidad

Otero y Zunzunegui (2011) plantean que “la conexión causal entre los Determinantes Sociales de la Salud (DSS) y las desigualdades en salud se expresa a través de una diferente exposición al daño, de una diferente vulnerabilidad y/o de las diferentes consecuencias del proceso de enfermar que tienen los distintos grupos o estratos sociales”.

Bajo esta perspectiva organizaciones como CDC, ATSDR, INSP proponen que, a través del marco de los DSS, concebidos 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 la vida cotidiana (OPS/OMS, 2021) se analice la vulnerabilidad social en salud.

Estas instituciones, refieren que los desastres naturales y los brotes de enfermedades infecciosas pueden representar una amenaza para la salud de una comunidad. Las poblaciones socialmente vulnerables están especialmente en riesgo durante las emergencias de salud pública debido a factores como el nivel socioeconómico, la composición del hogar, el estado de minoría o el tipo de vivienda, transporte, entre otros (INSP, 2020; CDC/ATSDR, 2021).

En este contexto, se han desarrollado modelos explicativos de DSS, de los cuales destacan el modelo de la Organización Mundial de la Salud (OMS, 2008), creado por la Comisión sobre Determinantes Sociales de la Salud, cuyo objetivo era acopiar datos para mejorar la salud y lograr que esté distribuida de forma más justa en todo el mundo, y para promover un movimiento mundial en favor de la consecución de esos objetivos.

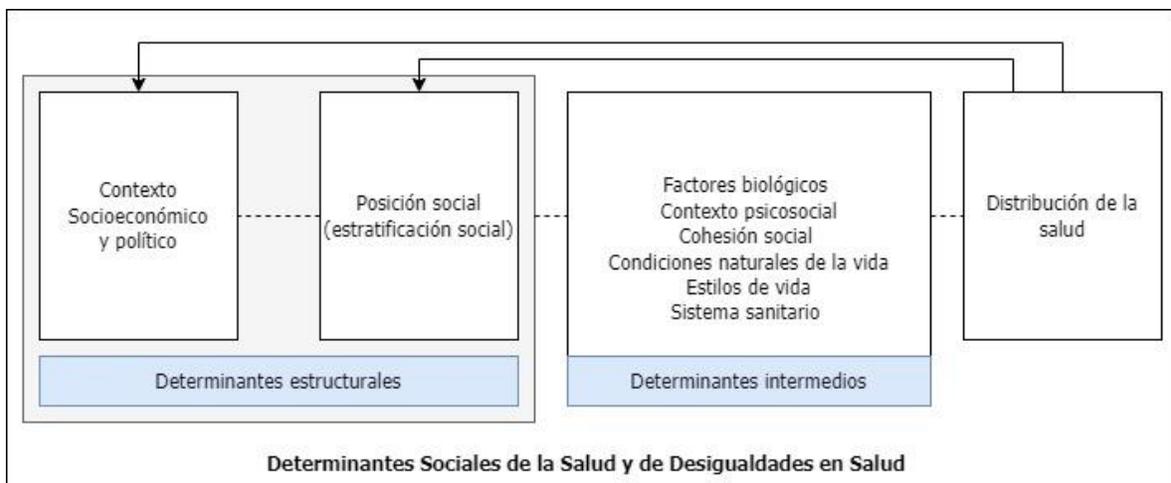
Este modelo está influenciado por otro desarrollado por Marc Lalonde y publicado por el Ministerio de Sanidad Canadiense en 1974, el cual supuso un apoyo pedagógico muy útil para agrupar y describir los diversos factores y condiciones que influyen en el proceso salud-enfermedad, tanto a nivel individual como poblacional. En él se agrupan los distintos determinantes en cuatro grandes apartados: biología humana, estilo de vida, medio ambiente y sistema sanitario (Lalonde, 1981; Otero y Zunzunegui, 2011).

No obstante, la OMS propone un modelo conceptual y causal en que el determinante central del proceso que conduce a una distribución desigual de la salud y el

bienestar en la población es la posición social de los individuos de ese lugar. Esta división de la sociedad está influenciada por el contexto socioeconómico y político en el que vive dicha población (Borrel y Malmusi, 2010).

Otero y Zunzunegui (2011) y Cárdenas et al. (2017) indican que la posición social, el contexto socioeconómico y político reciben el nombre de determinantes estructurales. Los determinantes intermedios, denominados así para resaltar su posición en la cadena causal entre la posición social y las desigualdades en salud, se refieren a las condiciones materiales de la vida diaria, factores psicosociales, estilos de vida, factores biológicos y el propio sistema sanitario (figura 3).

Figura 3. Marco conceptual de los Determinantes Sociales de la Salud

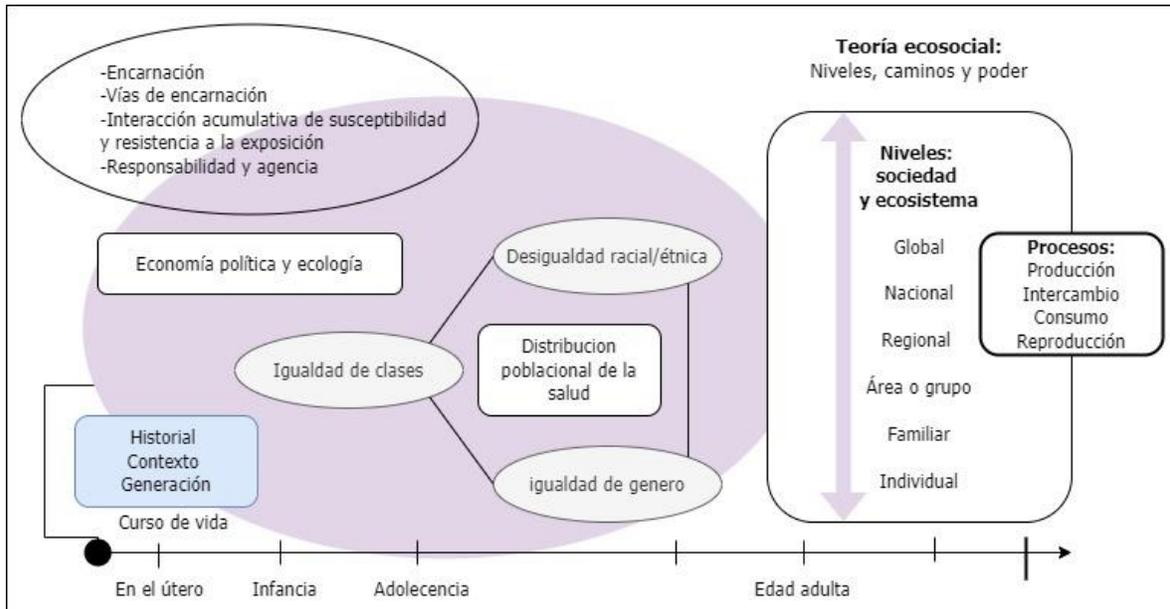


Fuente: Elaboración propia con base en Otero y Zunzunegui (2011); Cárdenas et al. (2017).

Otro constructo planteado por Krieger (2008-2011) es el modelo ecosocial de la distribución de la enfermedad, el cual se ocupa de cómo los DSS, en múltiples niveles y escalas espaciotemporales, se incorporan a lo largo de la vida, produciendo así patrones poblacionales de salud, enfermedad y bienestar (Krieger, 2009; Eslava et al., 2016).

Krieger (2001) señala que "este modelo se basa en la teoría ecosocial que dirige sus análisis a los patrones actuales y cambiantes de salud, enfermedad y bienestar en relación a cada nivel de organización biológica, ecológica y social (por ejemplo, célula, órgano, organismo individual, familia, comunidad, población, sociedad, ecosistema) como se manifiestan en cada escala, sean relativamente pequeños y rápidos o amplios y lentos, por ejemplo, infección y renovación de los susceptibles para una enfermedad infecciosa específica" (figura 4).

Figura 4. Modelo eco-social y encarnación de inequidad



Fuente: Elaboración propia con base en Krieger (2011); Morales et al. (2017).

1.3.3 Índices de vulnerabilidad social y ante COVID-19

Conceptualmente, un Índice de Vulnerabilidad Social (ÍVS) es una medida relativa de la vulnerabilidad social general de cada condado para el caso de EE. UU. (Cutter, 2003); para Spielman et al. (2020) es un indicador cuantitativo único que pretende medir la vulnerabilidad social de un determinado lugar; el Hazards & Vulnerability Research Institute (HVRI, 2021) lo define como una métrica comparativa que facilita el examen de las diferencias en vulnerabilidad social entre áreas de estudio.

En la práctica, el primer ÍVS fue desarrollado por Cutter et al. (2003) en EE. UU. se utilizaron datos socioeconómicos y demográficos a nivel de condado para construir el ÍVS ante peligros ambientales, basado en datos de 1990. Spielman et al. (2020) señalan que “este índice se usa con frecuencia cuando se comparan unidades geográficas en términos de sus niveles relativos de vulnerabilidad, donde los límites superior e inferior corresponden a los niveles de vulnerabilidad altos y bajos en un área de estudio”.

No obstante, el impacto del índice no se limita a la literatura académica, ha sido ampliamente utilizado en evaluaciones basadas en el lugar por organismos gubernamentales. En particular, el Índice de Vulnerabilidad Social de los CDC (CDC SVI, 2018) creado por el Programa de Investigaciones, Análisis y Servicios Geoespaciales (GRASP), en su primera versión en 2011, a fin de facilitarles a los

profesionales de salud pública la identificación y planificación rápida y precisa de asistencia para las poblaciones socialmente vulnerables a lo largo de todo un evento peligroso.

El CDC SVI ha sido empleado en diversos estudios, que han analizado la distribución espacial del dengue en Brasil, demostraron la asociación de la vulnerabilidad social y los resultados de salud relacionados con el calor, evaluaron la vulnerabilidad a un brote de enfermedades infecciosas, entre otros (Oviedo et al., 2014; Lehnert et al., 2020; Yedinak et al., 2021).

Otro ejemplo, es el Índice de Vulnerabilidad Social (SoVI®) 2010-14 desarrollado por el HVRI (2021), herramienta valiosa para los encargados de formular políticas y los profesionales porque ilustra gráficamente la variación geográfica en la vulnerabilidad social. Aunado a que muestra dónde existe una capacidad desigual de preparación y respuesta y dónde se pueden utilizar los recursos de manera más eficaz para reducir la vulnerabilidad preexistente.

Con la pandemia de COVID-19 se han desarrollado índices en torno a la vulnerabilidad ante esta enfermedad, que han acentuado la importancia de la localización geográfica de grupos susceptibles. Acharya y Porwal (2020) plantean que “este tipo de índices sirven para identificar regiones vulnerables y ayudar a preparar respuestas a nivel local y estrategias de mitigación de riesgos”.

Macharia et al. (2020) añaden que “la lucha contra la pandemia de COVID-19 exige una salud pública precisa que refleje nuestra mejor comprensión de quién es más vulnerable y qué los hace más vulnerables, dónde se está propagando la enfermedad o es probable que se propague más rápido, y dónde las intervenciones actuales pueden no funcionar según lo previsto”.

En consecuencia, un índice que mida de forma preventiva la vulnerabilidad de diferentes comunidades y ayude a retrasar el crecimiento exponencial de la enfermedad, reduzca el pico pandémico y disminuya el número de incidentes, puede ser una herramienta fundamental para prevenir futuras pandemias (Saghapour et al., 2021).

La aplicación de índices de vulnerabilidad ante COVID-19 y la identificación de personas y regiones vulnerables son novedosas. Se han desarrollado estudios a nivel mundial y un pequeño número en México. A continuación, se muestran los más importantes al momento de escribir este texto (cuadro 1).

Cuadro 1. Estudios sobre índices de vulnerabilidad ante COVID-19

Autor	Objetivo	Aporte	Conclusión
Investigaciones sobre índices de vulnerabilidad ante COVID-19			
Sierra-Alcocer et al., 2022	Proponer un novedoso Índice Dinámico de Vulnerabilidad Social ante COVID-19 (DySoVI) en México.	Captar la dinámica de la interacción entre las distintas dimensiones de la vulnerabilidad y la evolución de la pandemia.	Mientras que la vulnerabilidad estática destaca las regiones que podrían experimentar un fuerte impacto, la vulnerabilidad dinámica destaca las regiones donde existe una fuerte relación entre las condiciones estructurales fijas y la epidemia en evolución.
Gorris et al., 2021	Calcular un índice de vulnerabilidad variable en el tiempo a nivel de condado en Nuevo México, EE. UU.	A diferencia de otras medidas de vulnerabilidad estática, este enfoque variable en el tiempo permite que la vulnerabilidad de una comunidad cambie en respuesta a un desastre en curso.	El índice sirvió para identificar qué comunidades pueden estar en mayor riesgo de resultados sociales negativos a medida que avanzaba la pandemia de COVID-19.
Tiwari et al., 2021	Proponer un índice de vulnerabilidad (C19VI) basado en el aprendizaje automático, utilizando los temas sociodemográficos y específicos de COVID-19 de los CDC.	Implementación de la técnica de aprendizaje automático Random Forest (RF) para calcular el C19VI. También se desarrolló un algoritmo de "Evaluación del impacto de COVID-19" utilizando técnicas de análisis de homogeneidad y de evaluación de la tendencia temporal para entrenar el modelo RF.	En nuestro índice, los datos de entrada se procesan de forma no lineal, con alta precisión de prueba de entrenamiento y validez interna favorable para generar un índice de vulnerabilidad COVID-19 de los Estados Unidos.
Daras et al., 2021	Evaluar la asociación entre la mortalidad por COVID-19 en cada área y cinco medidas de vulnerabilidad.	Se utilizaron estimaciones de modelos de regresión de Poisson multivariantes para derivar un índice de vulnerabilidad de áreas pequeñas.	El índice indica aquellas comunidades que probablemente serán más vulnerables. Sin acciones mitigadoras, son estos lugares los que experimentarán un mayor exceso de mortalidad.
Saghapour et al., 2021	Generar un índice flexible de vulnerabilidad ante la pandemia	Propuso una herramienta para mapear áreas vulnerables y asignar una	Un índice flexible se adapta a los contextos espaciales locales y podría

Autor	Objetivo	Aporte	Conclusión
	de COVID-19 a nivel de área y evaluar su correlación con los casos confirmados en Australia.	cantidad adecuada de equipo y personal médico y asociado con suficiente anticipación.	aplicarse en otros lugares para identificar las poblaciones en riesgo que requieren una intervención temprana y específica.
Macharia et al., 2020	Crear tres índices; índice de vulnerabilidad social, índice de vulnerabilidad epidemiológica y un compuesto de los dos (índice de vulnerabilidad epidemiológica social), a nivel de subcondado (municipal) en Kenia.	Identificación de grupos vulnerables y de las inequidades en salud para el apoyo a la respuesta de salud pública mediante la localización y el mapeo de las comunidades que probablemente necesitarán un mayor apoyo.	Los índices creados son herramientas relevantes para el gobierno y las partes interesadas para priorizar y mejorar la planificación. La heterogeneidad de los índices apunta a la necesidad de acciones focalizadas y priorizadas basadas en las necesidades en los subcondados.
Acharya y Porwal., 2020	Diseñar un índice compuesto de vulnerabilidad ante la pandemia de COVID-19 en India.	Apoyo a los planificadores y formuladores de políticas a priorizar eficazmente las regiones para la asignación de recursos y adoptar estrategias de mitigación para una mejor preparación y respuesta.	Los índices de vulnerabilidad informados en este estudio están destinados a identificar espacialmente las regiones vulnerables y ayudar a la comunidad a prepararse, mitigar, responder y recuperarse de la pandemia.
Suárez et al., 2020	Mostrar los resultados de la elaboración de un índice de vulnerabilidad ante COVID-19 en México que integra los aspectos demográficos, socioeconómicos y de salud de la población, a nivel municipal.	Identificación de la distribución espacial de los diferentes factores (demográficos, socioeconómicos y de salud) que generan mayor susceptibilidad al daño o las consecuencias adversas que pueden tener las personas.	Todos somos vulnerables ante COVID-19; sin embargo, la distribución y combinación de varios factores en el territorio nacional demuestran que los niveles de vulnerabilidad de la población difieren considerablemente.

Tableros interactivos sobre índices de vulnerabilidad ante COVID-19

National Institute of Environmental Health Sciences (NIEHS), 2021.	Diseñar un índice de vulnerabilidad pandémica de COVID-19, centrado en el ser humano para transmitir y destilar datos complejos de alta dimensión en EE. UU.	La visualización de datos en este tablero ofrece un medio eficaz de comunicar datos a científicos, responsables políticos y al público.	Los datos a nivel de población son un recurso poderoso para comprender cómo se está propagando el virus y qué comunidades están en riesgo.
Foundation Surgo, 2021.	Elaborar un índice de vulnerabilidad comunitaria para evaluar qué comunidades de EE. UU. pueden ser menos resistentes	Identificación de regiones vulnerables y ayudar a preparar respuestas a nivel local y estrategias de mitigación de riesgos.	Aprovechar el poder de los datos para comprender cómo y por qué las comunidades son vulnerables, de modo

Autor	Objetivo	Aporte	Conclusión
Ávila-Ortega y Flores-Santana, 2020	a los impactos de la pandemia de COVID-19. Desarrollar un índice de riesgo a nivel de municipio para México, con el objetivo de identificar lugares con alto riesgo de vulnerabilidad debido a la comorbilidad de la población y la infraestructura hospitalaria deficiente.	Identificación de lugares con alto riesgo de vulnerabilidad debido a la comorbilidad de la población y la infraestructura hospitalaria deficiente.	que podamos desarrollar soluciones para ayudarlas. El índice sirve como una herramienta de política de planificación para implementar acciones preventivas en esas regiones vulnerables.
Ressler et al., 2020	Desarrollar un índice de vulnerabilidad al COVID-19 a nivel municipal con base en datos socioeconómicos/sociodemográficos y de infraestructura de salud.	El índice de vulnerabilidad discutido en este documento es parte del tablero interactivo de CONABIO que brinda información diaria sobre el desarrollo de COVID-19 a nivel municipal y estatal.	El índice brinda información útil para los tomadores de decisiones durante una crisis sanitaria como la del COVID-19 para preparar mejor la infraestructura municipal (por ejemplo, camas de hospital) y la población para futuras pandemias.

Fuente: Elaboración propia con base en Acharya y Porwal (2020); Ávila-Ortega y Flores-Santana (2020); Macharia et al. (2020); Ressler et al. (2020); Suárez et al. (2020); Daras et al. (2021); Foundation Surgo (2021); Gorris et al. (2021); National Institute of Environmental Health Sciences (2021); Saghapour et al. (2021); Sierra-Alcocer et al. (2022); Tiwari et al. (2021).

1.4 Conclusiones teóricas

Este capítulo estableció los fundamentos teóricos y conceptuales para el desarrollo del ÍEDVC19. Creó una reflexión sobre la relación entre la ubicación geográfica (lugar donde vivimos) y la propagación de enfermedades, a partir de la revisión de las principales escuelas del pensamiento, ciencias y especialistas que han abordado esta relación a través del tiempo. En particular, la geografía ha aportado conocimiento desde el siglo XVIII con las topografías médicas hasta la actualidad con la geografía médica y la geografía de la salud, que enfocan sus estudios en la distribución espacial de enfermedades y de los sistemas de salud.

En el segundo apartado, se menciona la aplicabilidad de las geotecnologías en investigación sobre enfermedades, a partir de la revisión de estudios que señalan la utilidad de estas herramientas tecnológicas para desarrollar análisis más avanzados. Particularmente, los SIG y la teledetección fueron las primeras geotecnologías utilizadas y en la actualidad los métodos en ciencia de datos y los lenguajes de programación han aportado nuevas técnicas de análisis de datos de salud que han revalorizado la funcionalidad de la geografía en este tipo de análisis, esta ciencia ha registrado aportaciones básicas como la vigilancia o mapeo de enfermedades y otras complejas como el rastreo y predicción de afecciones.

El capítulo finaliza con la revisión del origen del análisis de vulnerabilidad en América Latina que tiene sus inicios en la ciencias naturales en 1970 y actualmente se desarrollan estudios referentes a vulnerabilidad dependiendo de la disciplina de análisis, por ejemplo, en ciencias sociales, que a partir del enfoque conceptual de los determinantes sociales de la salud se han creado índices de vulnerabilidad social y ante enfermedades para mostrar variaciones geográficas dependiendo de factores estructurales y de salud de la población, como el desarrollado en esta investigación.

Con estas bases, se procede a diseñar e implementar la metodología para el desarrollo del ÍEDVC19, que se detalla en el siguiente capítulo.

Capítulo 2. Metodología para el desarrollo de un índice espacial dinámico de vulnerabilidad ante COVID-19.

Actualmente la ciencia geográfica dispone de herramientas geotecnológicas para analizar diversas enfermedades, un claro ejemplo es COVID-19. En este sentido, el capítulo 2 describe la metodología para el desarrollo del ÍEDVC19, considerando tres apartados: primero se menciona el diseño y área de estudio; después se señala la importancia de los indicadores seleccionados, así como las fuentes de información; por último, se detalla la aplicación de técnicas espaciotemporales y estadísticas que apoyaron en el análisis de datos referentes a COVID-19, y factores estructurales y de salud de la población.

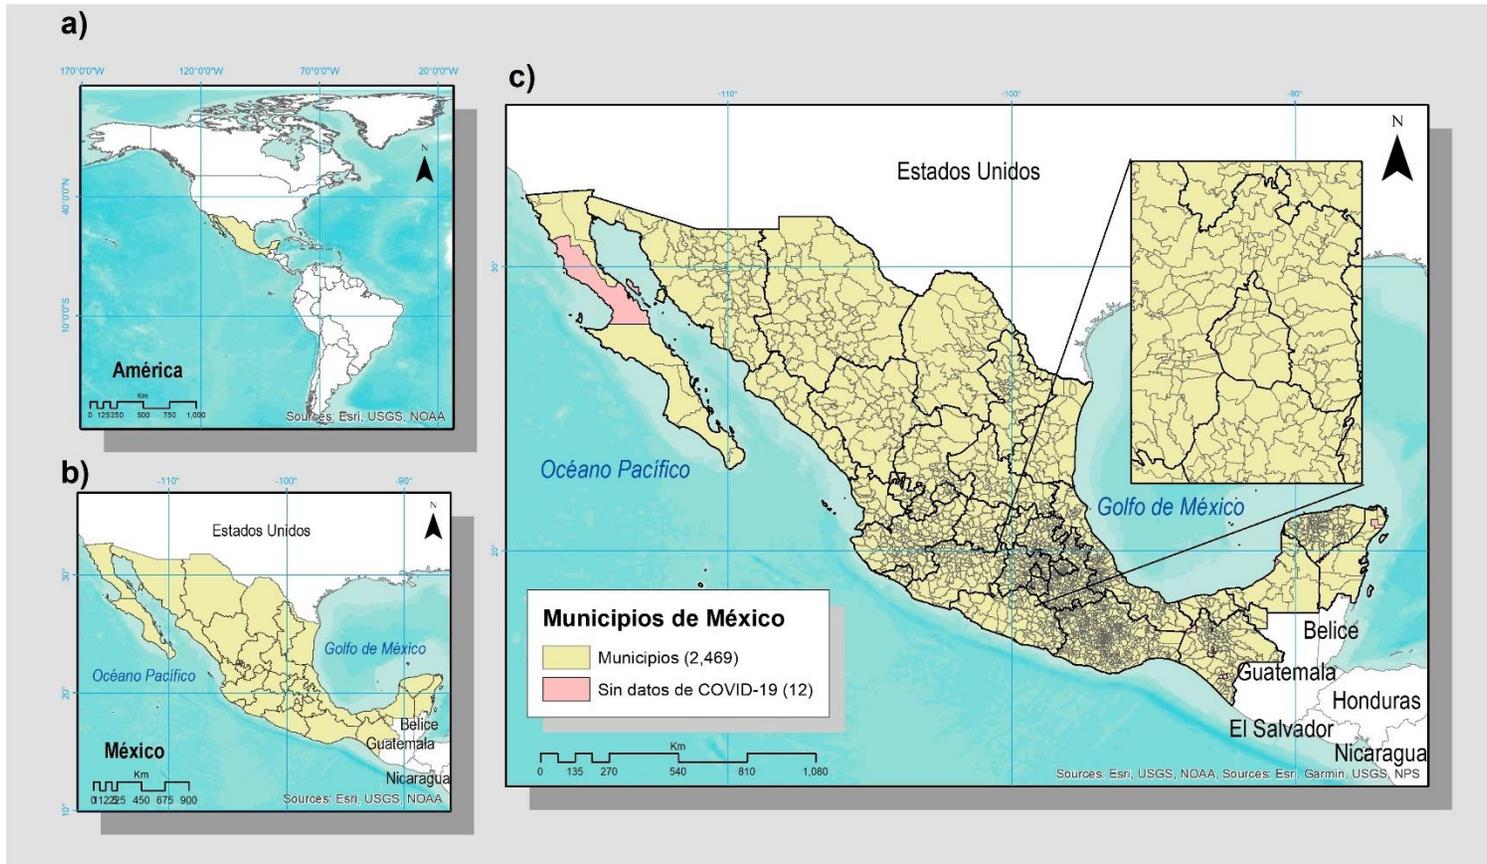
2.1 Diseño y área de estudio

El diseño de estudio es ecológico, debido a que su unidad de observación es a nivel de población en diferentes áreas geográficas (p. ej. población total por municipio), más que a nivel individual (Munnangi y Boktor, 2022). Borja-Aburto (2000) señala que, en este tipo de estudios “la comparación entre diversas áreas permite la evaluación de múltiples niveles de exposición, lo cual puede ser imposible en una sola área geográfica cuando se tienen exposiciones casi homogéneas”.

México, cuyo nombre oficial es Estados Unidos Mexicanos (GM, 2021) es el área de estudio, se localiza en la porción norte del continente americano y limita al norte con Estados Unidos; este, Golfo de México; sur, Belice y Guatemala; oeste, Océano Pacífico (figura 5a). Territorialmente, está dividido en 32 estados o entidades federativas, la ciudad de México es la capital nacional y sede de los tres poderes de gobierno: ejecutivo, legislativo y judicial (figura 5b y anexo 1). Asimismo, cada entidad se constituye por municipios (figura 5c), de acuerdo con el Instituto Nacional de Estadística y Geografía para el año 2020 (INEGI, 2020) sumaron 2,469.

No obstante, los datos de COVID-19 no estaban disponibles para los municipios de Capitán Luis Ángel Vidal, Rincón Chamula San Pedro, El Parral, Emiliano Zapata, Mezcalapa y Honduras de la Sierra en Chiapas; Coatetelco, Xoxocotla y Hueyapan en Morelos; Puerto Morelos en Quintana Roo; San Quintín en Baja California; y Seybaplaya en Campeche. Estos lugares se eliminaron del análisis, lo que resultó en un total de 2,457 municipios que es la escala de análisis de esta investigación (figura 5c).

Figura 5. México. Localización geográfica y escala de análisis



Fuente: Elaboración propia con base en INEGI, 2020.

2.2 Selección de variables y fuentes de información

Inicialmente, se obtuvieron datos de casos confirmados y defunciones desde el 01 de febrero de 2020 hasta el 31 de diciembre de 2022 de la principal fuente de información sobre COVID-19, que es la plataforma datos abiertos (base histórica) que pone a disposición la Secretaría de Salud a través de la Dirección General de Epidemiología (SS/DGE, 2022).

Posteriormente, se compiló una lista de 25 posibles factores de riesgo (indicadores) que pueden hacer que la población sea más vulnerable a los resultados negativos de la pandemia, con base en COVID-19 Community Vulnerability Index (Foundation Surgo, 2021), COVID-19 Pandemic Vulnerability Index (NIEHS, 2021) e índices previos (cuadro 1), que a su vez se basan en el índice de vulnerabilidad social para la gestión de desastres de los CDC (Flanagan et al., 2011).

Los factores se vinculan a temas (dimensiones) sobre estatus socioeconómico, características de la población, condiciones de vivienda e higiene, factores epidemiológicos y del sistema de salud. Además de la SS/DGE, otras fuentes de información consultadas fueron: el Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL, 2020), el Instituto Nacional de Geografía y Estadística (INEGI, 2020), y la Secretaría de Salud/Dirección General de Información en Salud (SS/DGIS, 2020), donde se obtuvieron datos sobre registros de egresos hospitalarios y defunciones, además de datos del sistema de salud. A continuación, se describe la importancia de cada indicador para la construcción del índice.

2.2.1 Estatus socioeconómico

Se utilizaron tres indicadores para definir la dimensión de estatus socioeconómico que representan la desigualdad social y económica de la población para prevenir y hacer frente a COVID-19 (cuadro 2). Es poco probable que las personas en situación de pobreza tengan recursos para la prevención de enfermedades, como mascarillas, agua y desinfectantes, lo que los coloca en mayor riesgo de contraer la enfermedad (Gorris et al., 2021; Macharia et al., 2020).

Las personas con niveles educativos bajos pueden carecer de información confiable entorno a las medidas de prevención y los medios de propagación de enfermedades. Tierney (2006) y Flanagan et al. (2011) destacan que “es más probable que

las personas con niveles educativos más altos tengan acceso a información variada sobre desastres y actúen sobre ella desde la preparación hasta la recuperación”.

Las personas sin afiliación a servicios de salud tienen más probabilidades de no ser contadas en las estadísticas de infecciones y pueden tener resultados más graves debido a la falta de tratamiento (NIEHS, 2021). En específico, el acceso a testeos, atención médica, internación, entre otros, pueden influir de manera significativa en el tratamiento y en la sobrevivencia a la enfermedad (Cruz y Monteiro, 2021).

2.2.2 Características de la población

La dimensión de características de la población incluye tres indicadores relacionados con la dinámica de la población (cuadro 2). Las edades más avanzadas se han asociado con resultados más graves de la infección por COVID-19 (Gomes 2020; Zhou et al., 2020; COVID-19 NERC et al., 2020), especialmente después de los 60 años (Jordan et al., 2020).

Asimismo, se espera que a medida que aumenta la densidad de población, aumenta la tasa de transmisión de enfermedades infecciosas (NIEHS, 2021), porque más personas están más cerca unas de otras, en concreto, existe menor distanciamiento social (Dutta et al., 2021; Sánchez et al., 2022). Caso contrario sucede en zonas con menos densidad de población (áreas rurales) donde la tasa puede resultar más baja (Macharia et al., 2020).

Los grupos minoritarios (afrodescendientes e indígenas) tienen niveles desproporcionadamente más altos de condiciones de salud subyacentes, como enfermedades cardíacas y diabetes, o sufren trastornos por el uso de sustancias como el alcohol y el tabaquismo que los pondrían en riesgo de complicaciones por COVID-19 (Dyer, 2020). Ortiz-Hernández y Pérez-Sastré (2020) señalan que “en México tener menor posición socioeconómica, ser indígena y vivir en los estados del sur se relaciona con mayor riesgo de presentar formas graves de esta afección”

2.2.3 Condiciones de vivienda e higiene

Para definir la dimensión condiciones de vivienda e higiene se seleccionaron tres indicadores que reflejan la exposición de las personas que viven en hogares con carencias particulares que determinan su salud (cuadro 2). En este sentido, la Organización Panamericana de la Salud (OPS, 2021) destaca que “las condiciones de la vivienda pueden promover o limitar la salud física, mental y social de sus residentes”.

La población que vive en hogares con más personas que dormitorios pueden ser más vulnerables a la transmisión de enfermedades infecciosas, esta problemática es conocida como hacinamiento. Krieger et al. (2020) señalan que “el hacinamiento puede contribuir al impacto de COVID-19 de varias maneras. A nivel individual, plantea riesgos para la salud al contribuir a la humedad interior, que proporciona entornos hospitalarios para los virus, mohos y plagas”. Por lo tanto, la proximidad de personas en hogares hacinados puede exacerbar la propagación de enfermedades contagiosas (Kamis et al., 2021).

Además, no disponer de agua limpia, de accesorios y de las instalaciones adecuadas para lavarse las manos puede representar un riesgo en la propagación de enfermedades, Rosenthal et al. (2020) indican que “los hogares deben tener acceso a una instalación básica para lavarse las manos, jabón y detergentes como primera línea de protección contra infecciones”. Sin embargo, las últimas estimaciones revelan que tres de cada 10 personas de todo el mundo no podían lavarse las manos con agua y jabón en su hogar durante la pandemia de COVID-19 (UNICEF, 2021).

2.2.4 Factores epidemiológicos

Doce indicadores de la dimensión factores epidemiológicos se seleccionaron de acuerdo con las directrices de los CDC y la fundación Surgo, que identifican como poblaciones de alto riesgo a los adultos mayores y a las personas con afecciones subyacentes, como enfermedades respiratorias, enfermedades cardíacas, obesidad, diabetes y afecciones relacionadas con la inmunodeficiencia (cuadro 2).

Estas comorbilidades se han asociado con un mayor riesgo de resultados graves de COVID-19 y en algunos casos la muerte (Wang et al., 2020; Macharia et al., 2020; COVID-19 NERC et al., 2020). Particularmente, en México, Benita y Gasca-Sánchez (2021) hallaron que “los trastornos metabólicos, como la obesidad o la diabetes, pueden exacerbar las infecciones y las muertes”.

La enfermedad renal crónica, la enfermedad cardiovascular, la hipertensión arterial y la diabetes están entre las comorbilidades que mayor riesgo implican para una presentación clínica grave en pacientes con la COVID-19, seguidas en importancia por las inmunodeficiencias, hábito de fumar, enfermedad respiratoria crónica y enfermedad hepática crónica (Plasencia-Urizarri et al., 2020).

2.2.5 Factores del sistema de salud

Por último, se seleccionaron cuatro indicadores de la dimensión factores del sistema de salud como medida de la capacidad y la preparación del sistema sanitario en relación con la respuesta frente a COVID-19 (cuadro 2). Debido a que, la declaración de emergencia sanitaria por parte de la OMS represento un gran desafío para los países con sistemas sanitarios fragmentados y con escasa inversión en recursos humanos e infraestructura (Gallegos, 2020).

Culebras et al. (2020) plantean que “durante los puntos altos de la pandemia, el ingreso masivo de pacientes en los hospitales hace que se manifieste una insuficiencia de equipos humanos y materiales que agrava la situación”. En otras palabras, la falta de equipamiento y personal de salud cualificado puede empeorar la situación de los pacientes.

Barrera-Algarín et al. (2020) hallaron relaciones vinculadas con el sistema sanitario y COVID-19 en países de Europa, destacaron que “a menor número de camas hospitalarias disponibles para la población, así como una baja cobertura de médicos se registró un mayor número de muertes por esta enfermedad”. En México, los servicios de salud pública llegaron a saturarse a pesar de los esfuerzos gubernamentales, lo que implica resultados negativos en la población que no tiene acceso a servicios de calidad, pues el acceso a ellos depende de la capacidad adquisitiva de las personas (Ortiz-Hernández y Pérez-Sastré, 2020).

Cuadro 2. Dimensiones y factores de riesgo relacionados con COVID-19

Dimensión	Variable (s)	Indicador (s)	Fuente
Estatus socioeconómico	Pobreza	% población en situación de pobreza	Pobreza a nivel de municipio (CONEVAL, 2020)
	Sin estudios universitarios	% población de 18+ sin educación posbásica	Principales resultados por localidad (INEGI, 2020)
	Sin seguro médico	% población sin afiliación a servicios de salud	
Características de la población	Mayores de 65 años	% población de 65 años y más	Principales resultados por localidad (INEGI, 2020)
	Grupos minoritarios	% población minoritaria	
	Concentración de población	Densidad de población	

Dimensión	Variable (s)	Indicador (s)	Fuente
Condiciones de vivienda e higiene	Hacinamiento	% viviendas particulares habitadas en condición de hacinamiento	Principales resultados por localidad y viviendas (INEGI, 2020)
	Acceso a tuberías interiores	% viviendas particulares habitadas sin agua entubada	
	Acceso a tuberías interiores	% viviendas particulares habitadas sin tinaco	
Factores epidemiológicos	Condiciones cardiovasculares	Tasa de egresos cardiovasculares	Egresos hospitalarios (SS/DGIS, 2020)
	Condiciones respiratorias	Tasa de egresos respiratorios	
	Inmunodeprimidos	Tasa de egresos cáncer	
		Tasa de egresos VIH	
	Condiciones de obesidad	Tasa de egresos obesidad	
	Condiciones de diabetes	Tasa de egresos diabetes	
	Muertes cardiovasculares	Tasa de defunciones cardiovasculares	Defunciones (SS/DGIS, 2020)
	Muertes respiratorias	Tasa de defunciones respiratorias	
	Inmunodeprimidos	Tasa de defunciones cáncer	
		Tasa de defunciones VIH	
	Muertes por obesidad	Tasa de defunciones obesidad	
	Muertes por diabetes	Tasa de defunciones diabetes	
Factores del sistema de salud	Capacidad del sistema de salud	Tasa de camas hospitalarias	Recursos (SS/DGIS, 2020)
		Tasa de camas en unidades de cuidados intensivos	
		Tasa de médicos generales	
		Tasa de enfermeros generales	

Fuente: Elaboración propia con base en Acharya y Porwal (2020); Macharia et al. (2020); Daras et al. (2021); Foundation Surgo (2021); Gorris et al. (2021); National Institute of Environmental Health Sciences (2021); Saghapour et al. (2021); Tiwari et al. (2021).

2.3 Procesamiento y análisis de datos

Esta metodología fue construida y probada en seis etapas desarrolladas en el entorno de software gratuito para gráficos y computación estadística R versión 4.2.2 (R Core Team, 2022); el entorno de desarrollo integrado RStudio versión 2022.02.4; en SaTScan™ versión 10.1, que analiza datos a partir de estadísticas de escaneo espacial, temporal y espaciotemporal; la cartografía se elaboró en ArcGIS® versión 10.8.

La estructuración de la base de datos principal (BDP) conformó la primera etapa, en R y RStudio se importaron las bases de datos de las fuentes de información y a partir de funciones integradas se obtuvieron los indicadores de COVID-19 (tasa de casos confirmados y tasa de defunciones), además de 25 indicadores que representan los factores de riesgo relacionados con esta enfermedad (figura 6).

La segunda etapa se desarrolló en SaTScan™, se empleó la estadística retrospectiva de espacio-tiempo de Kulldorff (1997), que tiene la finalidad de identificar grupos tanto en el espacio como en el tiempo (Azage et al., 2015), además durante cuánto tiempo ocurren. Se debe mencionar, que esta investigación se enfocó a detectar conglomerados con tasas altas, debido a que el interés fue localizar la población en riesgo (figura 6).

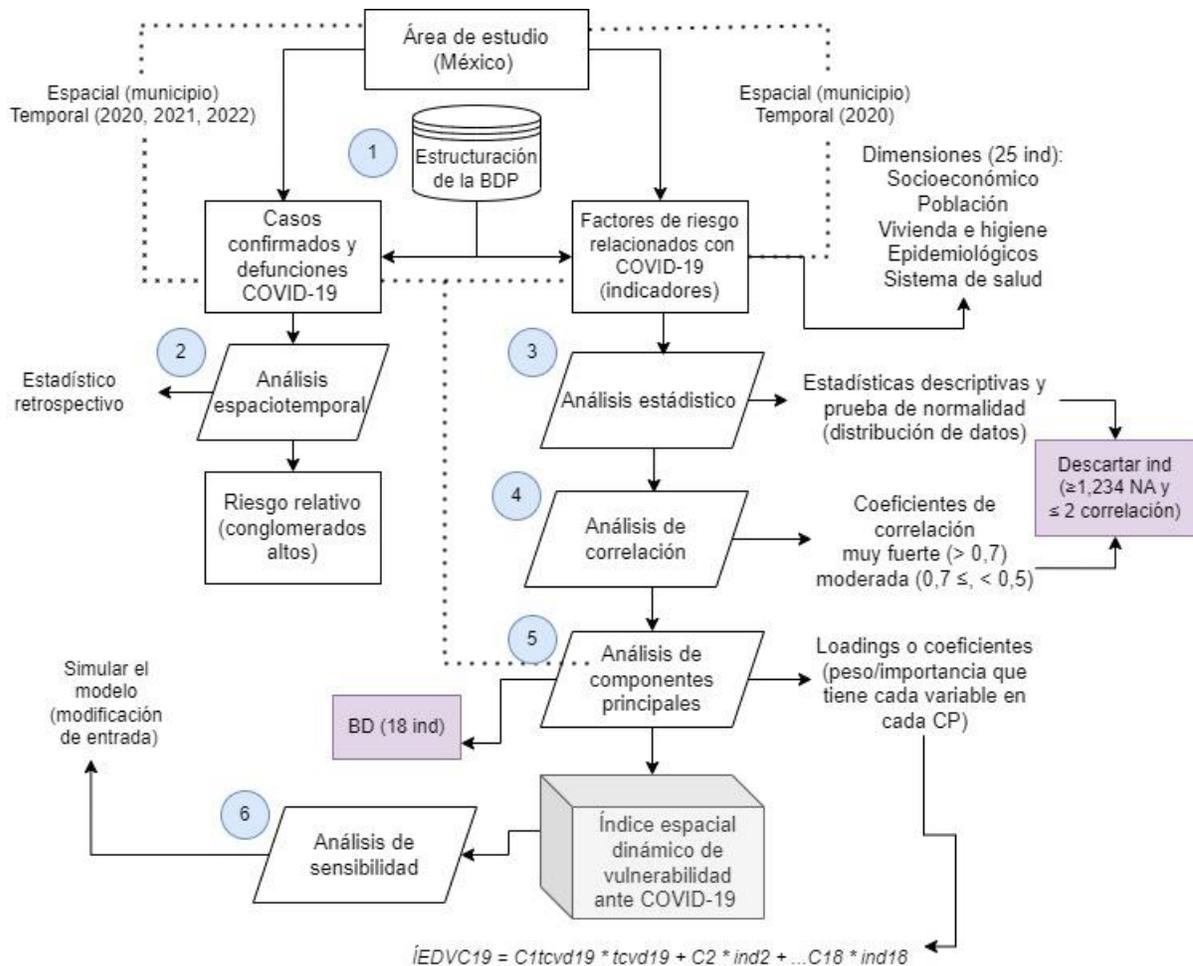
En tercer lugar, se analizaron las estadísticas básicas y descriptivas de los indicadores para descartar aquellos que no aporten suficiente información, debido a la falta excesiva de datos ($\geq 1,234$). Además, se aplicó la prueba de normalidad o "bondad de ajuste" Shapiro-Wilk, para identificar si los datos siguen o no una distribución normal (figura 6).

Teniendo en cuenta la distribución de los datos. La cuarta etapa, consistió en aplicar el coeficiente de correlación de Spearman (medida de asociación monótona) para descartar indicadores correlacionados y así evitar redundancia de información, Spearman se adopta cuando los datos continuos no se distribuyen normalmente (Schober et al., 2018; Rovetta, 2020; Quentin, 2022) (figura 6).

La quinta etapa consistió en la aplicación del Análisis de Componentes Principales para obtener los loadings de los indicadores del primer componente principal, he identificar cuales influyen en el componente, además de que son utilizados como pesos en la fórmula para obtener los valores del ÍEDVC19 (figura 6).

El análisis de sensibilidad conformó la última etapa y contribuyó al entendimiento de que tan robusto es el ÍEDVC19, es decir, si se modifican las variables de entrada, no debe haber un cambio significativo en el modelo de salida (Quentin, 2022). En este sentido, se modificaron los 18 indicadores (incremento del 1%) y se aplicó la misma cantidad de veces la fórmula para obtener un índice por cada indicador y con ello observar si los resultados representan o no una variación significativa ($\geq 15\%$) (figura 6).

Figura 6. Esquema metodológico



Fuente: Elaboración propia, 2022.

2.3.1 Estructuración de la base de datos

Para calcular las tasas de COVID-19 (anexo 2), se extrajeron los recuentos diarios de casos confirmados y defunciones del 01 de febrero de 2020 al 31 de diciembre de 2022 de las "bases de datos históricas COVID-19" de la SS/DGE y se obtuvo el acumulado mensual de ambas condiciones de salud. Posteriormente, se estimó la población de 2021 y 2022, mediante la tasa de crecimiento anual y la proyección de población anual

(ecuación 1 y 2), para este proceso se utilizaron datos de 2019 del Consejo Nacional de Población (CONAPO, 2019), mientras que para 2020 se obtuvieron del censo de población y vivienda del INEGI.

Ecuación 1.

Cálculo de la tasa de crecimiento anual

$$TCA = 1 + \frac{(P_f - P_i)}{P_i}$$

donde TCA es la tasa de crecimiento anual, P_f es la población final anual y P_i es la población inicial anual

Ecuación 2.

Cálculo de la proyección de población anual

$$P_t = TCA \times P_f$$

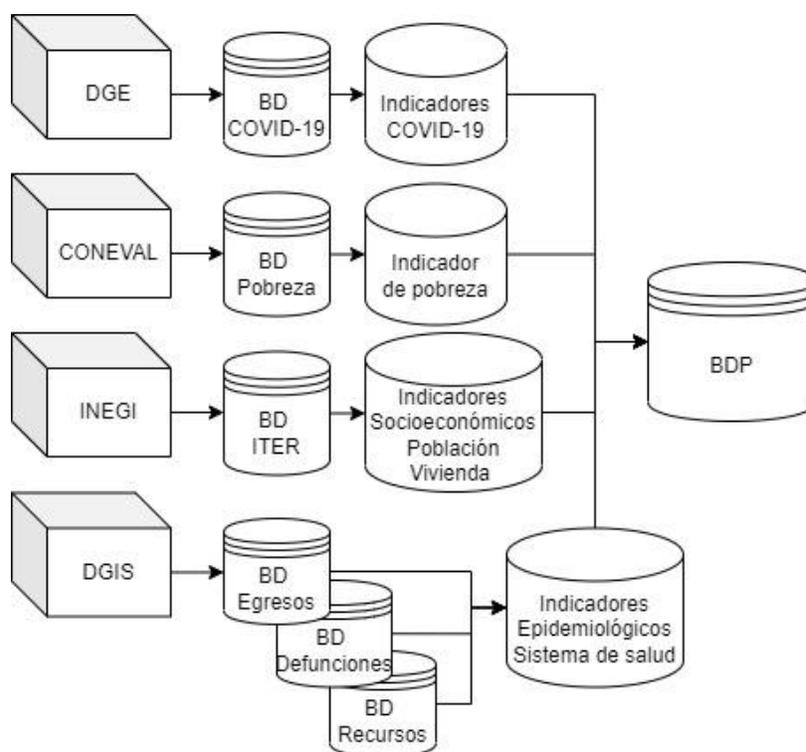
donde P_t es la población proyectada en el año t , TCA es la tasa de crecimiento anual y P_f es la población final anual

El indicador de porcentaje de población en situación de pobreza se extrajo de la base de datos "pobreza a nivel de municipio" del CONEVAL. La base de datos "principales resultados por localidad" (ITER) del INEGI contiene 221 variables del censo relacionadas con las características demográficas, socioeconómicas, culturales y de la vivienda, de estas se obtuvieron 10 para calcular siete indicadores. Se debe mencionar, que el ITER no cuenta con la variable viviendas particulares habitadas con más de 2.5 habitantes por dormitorio; por lo tanto, se consultó la base de datos "viviendas" para generar el indicador de hacinamiento (anexo 2).

Los indicadores de la dimensión factores epidemiológicos se calcularon a partir de las bases de datos de la SS/DGIS (egresos hospitalarios y defunciones), que además contienen información de las características individuales de los pacientes y personas fallecidas, como, sexo, edad, lugar de ocurrencia, lugar de residencia, entre otras variables. En este sentido, se extrajeron datos de egresos hospitalarios y defunciones por municipio de residencia de acuerdo con la Clasificación Internacional de Enfermedades (CIE-10): enfermedades cardiovasculares (I00x-I99x), enfermedades respiratorias (J00x-J989), cáncer (C000-C969), VIH (B200-B24x), obesidad (E660-E669), diabetes (E100-E149), por último, se aplicó una ecuación para obtener las tasas por 100,000 habitantes (anexo 2).

De manera similar, los datos sobre los factores del sistema de salud se obtuvieron de la base de datos “recursos” de la SS/DGIS, se extrajeron cuatro variables relacionadas con el capital humano y la infraestructura en salud; posteriormente, por medio del lenguaje de programación R se obtuvieron los indicadores mediante cálculos de normalización y se generó la base de datos principal (anexo 2 y figura 7).

Figura 7. Estructuración de la base de datos



Fuente: Elaboración propia, 2022.

2.3.2 Análisis espaciotemporal

En SaTScan™ se introdujeron cuatro conjuntos de datos: casos confirmados, defunciones, población total (censo 2020) y el archivo de coordenadas geográficas de cada municipio (centroide). Se seleccionó el tipo de análisis retrospectivo de exploración de espacio-tiempo y el modelo de probabilidad discreta de Poisson, debido a que COVID-19 se propaga de persona a persona y se espera un mayor número de casos en áreas más densamente pobladas, por esta razón, la población de cada municipio ajusta el modelo (Kim y Castro, 2020).

Para detectar los conglomerados espaciotemporales, el software utiliza una ventana cilíndrica de base geográfica circular que representa el espacio y la altura refleja el tiempo (Xia et al., 2017). La base se centra alrededor de uno de los posibles centroides

ubicados a lo largo de los municipios, con un radio que varía en tamaño continuamente desde cero hasta un valor máximo especificado (Kulldorff et al., 1998). La altura refleja cualquier intervalo de tiempo posible que incluye no solo el periodo total de estudio, sino también el intervalo menor o igual a la mitad del periodo de estudio (Kulldorff et al., 1998).

En esta investigación, se seleccionaron los recuentos mensuales de casos confirmados y defunciones de COVID-19 como intervalo de tiempo. Siguiendo a Kim y Castro (2020) el tamaño máximo del conglomerado espacial se fijó en el 5 % de la población en riesgo y el tamaño máximo del conglomerado temporal se fijó en 8 meses, que representa el 25 % de la duración total del periodo (35 meses) para evitar conglomerados extremadamente grandes. Además, se fijó en 10 el número mínimo de casos en conglomerados altos.

Por último, el riesgo relativo (ecuación 3) y la relación de probabilidad logarítmica (RPL) de cada conglomerado se calcularon en función de la prueba de razón de verosimilitud utilizando 999 repeticiones aleatorias de Monte Carlo (Xia et al., 2017), bajo las siguientes hipótesis nulas:

1) Riesgo relativo (RR).

H0: No hay diferencia en el RR de COVID-19 en el municipio analizado

Ha: Hay diferencias en el RR de COVID-19 en el municipio analizado

2) Razón de verosimilitud-probabilidad logarítmica (LR=L0/La)

L0: verosimilitud bajo la hipótesis nula

La: verosimilitud bajo la hipótesis alternativa

Ecuación 3.

Cálculo del riesgo relativo

$$RR = \frac{ob[c]/Esp[c]}{(C - c)/(Esp[C] - Esp[c])}$$

donde **RR** es el riesgo relativo, **c** es el número de casos observados dentro del conglomerado y **C** es el número total de casos en el conjunto de datos (Quentin, 2022).

2.3.3 Análisis estadístico

El análisis estadístico de los 25 indicadores se realizó en R y RStudio, a partir de la función 'stat.desc[pastecs]' (Grosjean e Ibanez, 2018), permitió analizar las estadísticas básicas y descriptivas; los valores mínimo y máximo; y la media y la mediana. Asimismo, se identificaron los indicadores que se descartaron de los siguientes análisis (correlación

y componentes principales) debido a la falta excesiva de datos, en este sentido, se excluyeron aquellos que cuentan con la mitad o más municipios ($\geq 1,234$) con valores perdidos (NA).

Para conocer la distribución de los datos y determinar el método apropiado para la ejecución del análisis de correlación (p. ej. Pearson o Spearman), se utilizó la función 'shapiro.test{stats}' (Gross y Ligges, 2015) que emplea la prueba de normalidad Shapiro-Wilk (ecuación 4) y se basa en el siguiente supuesto:

H0 (hipótesis nula): Los datos siguen una distribución normal.

H1 (hipótesis alternativa): Los datos no siguen una distribución normal.

Shapiro-Wilk fue la primera prueba que pudo detectar las desviaciones de la normalidad debidas a la asimetría o a la curtosis, o a ambas (Althouse et al., 1998). Esta prueba permite valores perdidos, pero el número de valores no perdidos debe estar entre 3 y 5000 (R Core Team, 2022).

Ecuación 4.

Cálculo de la prueba de normalidad Shapiro-Wilk

$$W = \frac{\{\sum_{i=1}^n a_i X_{(i)}\}^2}{\sum_{i=1}^n (X_i - \bar{X})^2},$$

donde $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$ son los valores ordenados de la muestra y a_i son constantes tabuladas. Se rechaza la normalidad para valores pequeños de W (Hanusz y Tarasińska, 2015), en otras palabras, si el p-value es inferior a un nivel alfa elegido (p. ej. 0.05) se rechaza H0; por lo tanto, los datos no siguen una distribución normal al nivel de confianza de 95% (Quentin, 2022).

2.3.4 Análisis de correlación

Derivado de la prueba de normalidad, se determinó que los indicadores no presentaban una distribución normal. En este sentido, el método de Spearman está diseñado para distribuciones no normales, pretende examinar la dirección y magnitud de la asociación entre dos variables cuantitativas, es decir, la intensidad de la relación entre las variables en cualquier tipo de asociación, no necesariamente lineal (Mondragón, 2014; Akoglu, 2018).

La función 'cor{stats}' (R Core Team. 2023) permitió calcular la correlación entre indicadores seleccionando el método de Spearman, mientras que la matriz de coeficientes de correlación de rango de Spearman (ecuación 5) para todos los posibles

pares de columnas se generó con 'rcorr{Hmisc}' (Harrell, 2022). Los coeficientes son estadísticos que cuantifican la correlación, van de -1 a +1 donde 0 indica que no hay una asociación monótona y 1 significa una correlación completa o perfecta (Martínez et al., 2009; Shober et al., 2018).

Ecuación 5.

Cálculo del coeficiente de correlación de rango de Spearman

$$rho = 1 - \frac{6S}{N(N^2 - 1)}$$

donde *rho* es el coeficiente de correlación de Spearman, *S* es la suma de los cuadrados de las diferencias de los rangos correspondientes y *N* es la cantidad de observaciones que se clasifican (Mondragón, 2014).

La interpretación de los coeficientes difiere significativamente entre las áreas de investigación científica (Akoglu, 2018). En particular, en ciencias médicas una correlación a menudo se define como muy fuerte (> 0,7), moderada (0,7 ≤, < 0,5), regular (0,5 ≤, ≤ 0,3) o mala (< 0.3) (Rovetta, 2020), mientras que en ciencias sociales se explica como perfecta (de 0.91 a 1.00), muy fuerte (de 0.75 a 0.90), considerable (de 0.51 a 0.75), media (de 0.11 a 0.50) y débil (de 0.01 a 0.10) (Hernández y Fernández, 1998).

En esta investigación se consideró la interpretación que propone Rovetta, como criterio para descartar los indicadores que registraron coeficientes de correlación en los umbrales muy fuerte (> 0,7) y moderada (0,7 ≤, < 0,5), además se eliminaron aquellos que se correlacionaban con dos o más indicadores para evitar la redundancia de información.

2.3.5 Análisis de factores

Una vez que se descartaron ocho indicadores en las etapas anteriores (análisis estadístico y análisis de correlación) se obtuvo la base de datos para ejecutar el Análisis de Componentes Principales (ACP). Sin embargo, algunos indicadores contaban con municipios con valores NA (≤ 50%); por lo tanto, fue necesario aplicar preprocesamiento a los datos, para que la base estuviera completa. Holland (2022) destaca que para la aplicación del ACP "los datos deben estar en forma de matriz estándar, con *n* filas de muestras y *p* columnas de variables. Además, no debe haber valores faltantes".

a) *Preprocesamiento de datos*

El preprocesamiento de los datos se realizó en tres fases, primero se estimó el número óptimo de componentes en el modelo de ACP, a partir de la función

'estim_ncpPCA {missMDA}' (Josse y Husson, 2016). Esta función proporciona el número de dimensiones S que se utilizarán en el algoritmo de imputación de datos a pesar de valores NA (Laura-Ochoa, 2019).

Los argumentos seleccionados fueron: número mínimo de componentes a probar (ncp.min = 0) a número máximo de componentes a probar (ncp.max = 17), que son igual al número de indicadores (sin contar el de COVID-19), además se eligió el argumento escala (scale = TRUE), para tener una varianza unitaria, (sdev = 1) que implica un mismo peso para cada indicador.

El método de validación cruzada seleccionado fue k-fold (method.cv = c("kfold")), debido a que permite reducir el tiempo computacional, en comparación con leave-one-out "loo" (por mencionar uno). K-fold consiste en eliminar más de un valor del conjunto de datos (p. ej. 10%) de las celdas y predecirlas simultáneamente (Josse y Husson, 2016).

Este método permite incorporar argumentos adicionales: pNA indica el porcentaje de valores perdidos insertados y predichos con PCA utilizando las dimensiones ncp.min a ncp.max, y el número de veces que se repite este proceso (nbsim).

La segunda fase, consistió en imputar los valores faltantes, a partir de la función 'imputePCA{missMDA}' (Josse y Husson, 2016) que utiliza el algoritmo PCA iterativo regularizado (method = c("Regularized")) con el número de componentes obtenidos en la fase anterior (15 en esta investigación). De igual manera, se escalaron los datos (scale = TRUE).

PCA iterativo regularizado es sugerido para evitar problemas de sobreajuste que son frecuentes cuando faltan muchos valores (Josse y Husson, 2013), el algoritmo fue propuesto por Josse et al. (2009) y se explica a continuación:

1. Inicialización $\ell = 0$:

Se sustituyen los valores faltantes con valores iniciales, como la media de las variables con entradas no ausentes, la matriz imputada se denota X^0 . Calcular M^0 , la matriz del vector que contiene la media de las variables de X^0 , repetida en cada fila de M^0 .

2. Paso $\ell \geq 1$:

- (a) Se realiza el ACP, es decir, la descomposición de valores singulares (SVD por sus siglas en inglés) de $(X^{\ell-1} - M^{\ell-1})$ para estimar los parámetros U^ℓ, V^ℓ y $(\Lambda^\ell)^{1/2}$.

- (b) Se mantienen las primeras dimensiones S y se construye la matriz ajustada (ecuación 6).

Ecuación 6.

Cálculo de la matriz ajustada del PCA iterativo regularizado

$$\hat{x}_{ij}^{\ell} = \sum_{s=1}^S \left(\sqrt{\lambda_s^{\ell} - (\sigma^2)^{\ell}} \right) u_{is}^{\ell} v_{js}^{\ell},$$

con la varianza del ruido estimada como $(\sigma^2)^{\ell} = \frac{\|X^{\ell-1} - U^{\ell} (\Lambda^{\ell})^{1/2} (V^{\ell})^T\|^2}{np - nS - pS + S^2}$, definimos el nuevo conjunto de datos imputados como $X^{\ell} = W * X + (1 - W) * \hat{x}^{\ell}$, donde 1 es una matriz de tamaño $n * p$ sólo con unos. Los valores observados son los mismos, pero los que faltan se reemplazan por los valores ajustados (regularizados).

- (c) A partir de la nueva matriz completada, se actualiza M^{ℓ} .

3. Los pasos (2.a), (2.b) y (2.c) se repiten hasta que el cambio en la matriz imputada desciende por debajo de un umbral predefinido $\sum_{ij} (\hat{x}_{ij}^{\ell-1} - \hat{x}_{ij}^{\ell})^2 \leq \mathcal{E}$, con \mathcal{E} igual a 10^{-6} por ejemplo (Josse y Husson, 2016).

En la fase tres, se agregó la tasa de casos confirmados (mediana de la tasa anual de 2020, 2021 y 2022) a la base de datos obtenida en las fases anteriores (1 y 2). Posteriormente, se escalaron los datos con la técnica min-max para ajustar los valores medios de diferentes escalas en una misma (Pandey y Jain, 2017). Min-max permitió realizar este proceso y escalar los datos de 0 a 1 (0 = menor vulnerabilidad y 1 = mayor vulnerabilidad) (ecuación 7).

Ecuación 7.

Cálculo de cambio de escala de los indicadores

$$V' = \frac{V - \min_A}{\max_A - \min_A} (\text{new_max}_A - \text{new_min}_A) + \text{new_min}_A$$

donde V es el valor a escalar, \min_A es el valor mínimo en el rango original, \max_A es el valor máximo en el rango original, new_max es el valor máximo en la nueva escala (1) y new_min es el valor mínimo en la nueva escala (0).

Se debe mencionar, que antes de aplicar la fórmula para obtener los valores del ÍEDVC19 se verificó que los indicadores tuvieran la misma relación, en otras palabras, altos valores son igual a alta vulnerabilidad, para el caso de los indicadores (tasa de camas hospitalarias, tasa de camas en UCI y tasa de médicos generales) que no cumplieron esta

relación (altos valores son igual a baja vulnerabilidad) se modificó la fórmula de manera inversa, para que siguieran el sentido de los demás (ecuación 8).

Ecuación 8.

Cálculo de cambio de escala de los indicadores relacionados de manera inversa

$$V' = \frac{V - \max_A}{\min_A - \max_A} (\text{new_max}_A - \text{new_min}_A) + \text{new_min}_A$$

donde V es el valor a escalar, \max_A es el valor máximo en el rango original, \min_A es el valor mínimo en el rango original, new_max es el valor máximo en la nueva escala (1) y new_min es el valor mínimo en la nueva escala (0).

b) Análisis de Componentes Principales

ACP es un método estadístico para la ordenación y reducción de dimensionalidad de conjuntos de datos multivariados (Camargo, 2022). La idea principal es utilizar menos variables, pero no correlacionadas para obtener la mayor cantidad de información posible sobre los datos originales (Boran et al., 2022). En este contexto, al término del preprocesamiento de los datos, se ejecutó ACP a la matriz de datos que incluye 18 indicadores (anexo 3), a partir de la función 'prcomp {stats}' (R Core Team, 2022) seleccionando, center = FALSE y scale = FALSE, debido a que los datos se escalaban anteriormente.

Siguiendo a Camargo (2022) y Holland (2022), el cálculo de los componentes principales (CP) son una combinación lineal de las variables originales ponderadas por vectores propios, las puntuaciones de los componentes son una transformación de las variables observadas (ecuación 9).

Ecuación 9.

Cálculo del primer componente principal

$$Y_1 = a_{11}X_1 + a_{12}X_2 + \dots + a_{1p}X_p$$

donde el primer CP Y_1 viene dado por una combinación lineal de las variables X_1, X_2, \dots, X_p

El primer CP se calcula de manera que represente la mayor variación posible de los datos. Mientras que el segundo CP se calcula de la misma manera, con la condición de que no está correlacionado con el primer CP (Suhr, 2005), en otras palabras, es perpendicular y representa la siguiente varianza más alta (ecuación 10).

Ecuación 10.

Cálculo del segundo componente principal

$$Y_2 = a_{21}X_1 + a_{22}X_2 + \dots a_{2p}X_p$$

donde el segundo CP Y_2 viene dado por una combinación lineal de las variables X_1, X_2, \dots, X_p

Esto continúa hasta que se haya calculado un total de p componentes principales, en otras palabras, el número de CP es el mismo que el número original de variables (Holland, 2022).

Suhr (2005) señala que “el modelo de ACP es”: $Y = XB$

donde Y es una matriz de variables observadas, X es una matriz de puntajes en los componentes, B es una matriz de vectores propios.

Las filas de la matriz B especifican la orientación de los componentes principales en relación con los indicadores originales. Los elementos de un vector propio, es decir, los valores dentro de una fila particular de la matriz B , son los pesos aij . Estos valores se denominan loadings o coeficientes, y describen cuánto contribuye cada variable a un CP particular (Lucas, 2022; Holland, 2022). Van de -1 a 1, un valor absoluto alto (hacia 1 o -1) describe que la variable influye fuertemente en el componente y valores cercanos a 0 indican que la variable tiene una influencia débil sobre el componente (Lucas, 2022).

A partir de los coeficientes de los indicadores ($c1, c2, c3, \dots c18$) del primer componente principal (valores constantes) y los valores originales de los indicadores ($ind1, ind2, ind3, \dots ind18$) se aplicó la fórmula general para obtener los valores del ÍEDVC19 durante 2020-2022, como se muestra en la siguiente ecuación.

Ecuación 11.

Cálculo para obtener los valores del ÍEDVC19

$$\text{ÍEDVC19} = c1_{tcvd19} * tcvd19 + c2 * ind2 + c3 * ind3 + \dots c18 * ind18$$

donde $c1_{tcvd19}$ es el coeficiente de la mediana de las tasas de casos confirmados anuales (2020, 2021, 2022) y $tcvd19$ es la mediana de las tasas de casos confirmados anuales de estos años.

Posteriormente, para capturar la dinámica espaciotemporal del ÍEDVC19 se seleccionó la duración de las cinco olas epidémicas (acumulado), primera ola: febrero-septiembre 2020; segunda: octubre 2020-mayo 2021; tercera: junio-noviembre 2021; cuarta: diciembre 2021-abril 2022; quinta: mayo-octubre 2022. Y se aplicó la fórmula

general para cada oleada, correspondiente. La ecuación 12 muestra el cálculo para obtener los valores del ÍEDVC19 en la primera ola y así ejemplificar los cálculos subsecuentes para obtener los valores del índice en las olas posteriores.

Ecuación 12.

Cálculo para obtener los valores del ÍEDVC19 en la primera ola

$$\text{ÍEDVC19}_{(ola1)} = c1_{tcvd19} * tcvd19_{ola1} + c2 * ind2 + c3 * ind3 + \dots c18 * ind18$$

donde $c1_{tcvd19}$ es el coeficiente de la mediana de las tasas de casos confirmados anuales (2020, 2021, 2022) y $tcvd19_{ola1}$ es el acumulado de las tasas de casos confirmados de la ola 1.

Esta etapa finaliza con la elaboración cartográfica, para poder comparar la vulnerabilidad durante el periodo 2020-2022 y por ola epidémica, los valores del ÍEDVC19 se clasificaron en quintiles que ilustran: vulnerabilidad 'muy baja' (<20%), 'baja' (20-40%), 'moderada' (40-60%), 'alta' (60-80%) y 'muy alta' (>80%).

2.3.6 Análisis de sensibilidad

La ejecución del análisis de sensibilidad del ÍEDVC19 se desarrolló en dos fases. En primer lugar, se modificó el valor original de los 18 indicadores que conformaron el ÍEDVC19 con un incremento del 1%, por ejemplo, si el valor original del indicador (*ind1*) del municipio *n* era de 80%, el nuevo valor resultó en 80.8% (ecuación 13).

Ecuación 13.

Cálculo del incremento porcentual en los indicadores al 1%

$$\text{Incremento} = \text{valor del ind1} * 1.01$$

En la segunda fase, se aplicó la fórmula general (apartado 2.3.5) para obtener los valores de los índices modificados, uno por cada indicador y se calculó el porcentaje de incremento entre el ÍEDVC19 y los índices modificados para determinar si los municipios registraron variación significativa (ecuación 14). En este sentido, se fijó un umbral de $\geq 15\%$, en otras palabras, los municipios que registraron porcentajes de incremento \geq al umbral representan un cambio significativo, por tal motivo, se determina que el ÍEDVC19 es sensible a cambios en esos municipios.

Ecuación 14.

Cálculo del porcentaje de incremento

$$\text{Incremento (\%)} = 100 * \frac{\text{índice modificado} - \text{ÍEDVC19}}{\text{ÍEDVC19}}$$

2.4 Conclusiones metodológicas

La adecuada selección de indicadores representativos de los factores de riesgo ante COVID-19 está asociada con la revisión de literatura y la disponibilidad de datos, de estos aspectos deriva en gran parte la idoneidad del modelo. Es necesario consultar índices validados para seleccionar los indicadores más significativos de la vulnerabilidad ante esta enfermedad, sin embargo, en ocasiones no se dispone de datos y se deben emplear alternativas como ajustar indicadores proxy (aproximación al indicador original) para estar en línea con los datos accesibles para México.

La metodología propuesta aporta conocimiento en el desarrollo de índices dinámicos de vulnerabilidad ante COVID-19 y brotes de enfermedades infecciosas. Las técnicas espaciotemporales y estadísticas empleadas contribuyen al procesamiento y análisis de datos relacionados con esta enfermedad, y con factores estructurales y de salud de la población que son la base para la creación del ÍEDVC19. En particular, el análisis espaciotemporal se desarrolló en SaTScan™ y los análisis estadísticos se ejecutaron en R y RStudio, una ventaja que comparten estos software es que son gratuitos.

Para ejecutar el ACP, es necesario contar con una matriz de datos que no tenga valores faltantes, de ser así, el preprocesamiento de datos es una técnica que apoya a completar la matriz y tener mejor calidad de información. El ACP ayuda a reducir la dimensionalidad de un conjunto de indicadores preservando la mayor información de los indicadores originales, este tipo de análisis es adecuado para crear índices de vulnerabilidad ante COVID-19, debido a que permite transformar datos multidimensionales (socioeconómicos, demográficos, vivienda, epidemiológicos, sistema de salud, entre otros) a una escala comparable en áreas geográficas específicas como los municipios de México.

Se debe señalar la importancia de la validación del índice, en este sentido los análisis de sensibilidad son adecuados para identificar la robustez del modelo, en teoría si los datos de las variables de entrada experimentan una modificación, no debe haber un cambio significativo en el modelo de salida, por lo tanto, se determina la idoneidad del índice y, en consecuencia, de los resultados.

Con la implementación de la metodología se procede a analizar los resultados del ÍEDVC19, que se detallan en los siguientes capítulos.

Capítulo 3. Dinámica espaciotemporal de COVID-19 en México.

El siguiente capítulo muestra los resultados de la dinámica espaciotemporal de COVID-19 mediante cuatro apartados: primero se muestra la distribución espacial de los casos confirmados y defunciones (tasas por 100,000 habitantes); posteriormente, se contextualiza la evolución temporal y se mencionan las principales medidas de seguridad sanitaria que implemento el Gobierno de México; los apartados siguientes analizan los conglomerados espaciotemporales de tasas altas, además se identifica el riesgo relativo, es decir, en que municipios fue más común la COVID-19 y en qué periodo de tiempo.

3.1 Distribución espacial de COVID-19

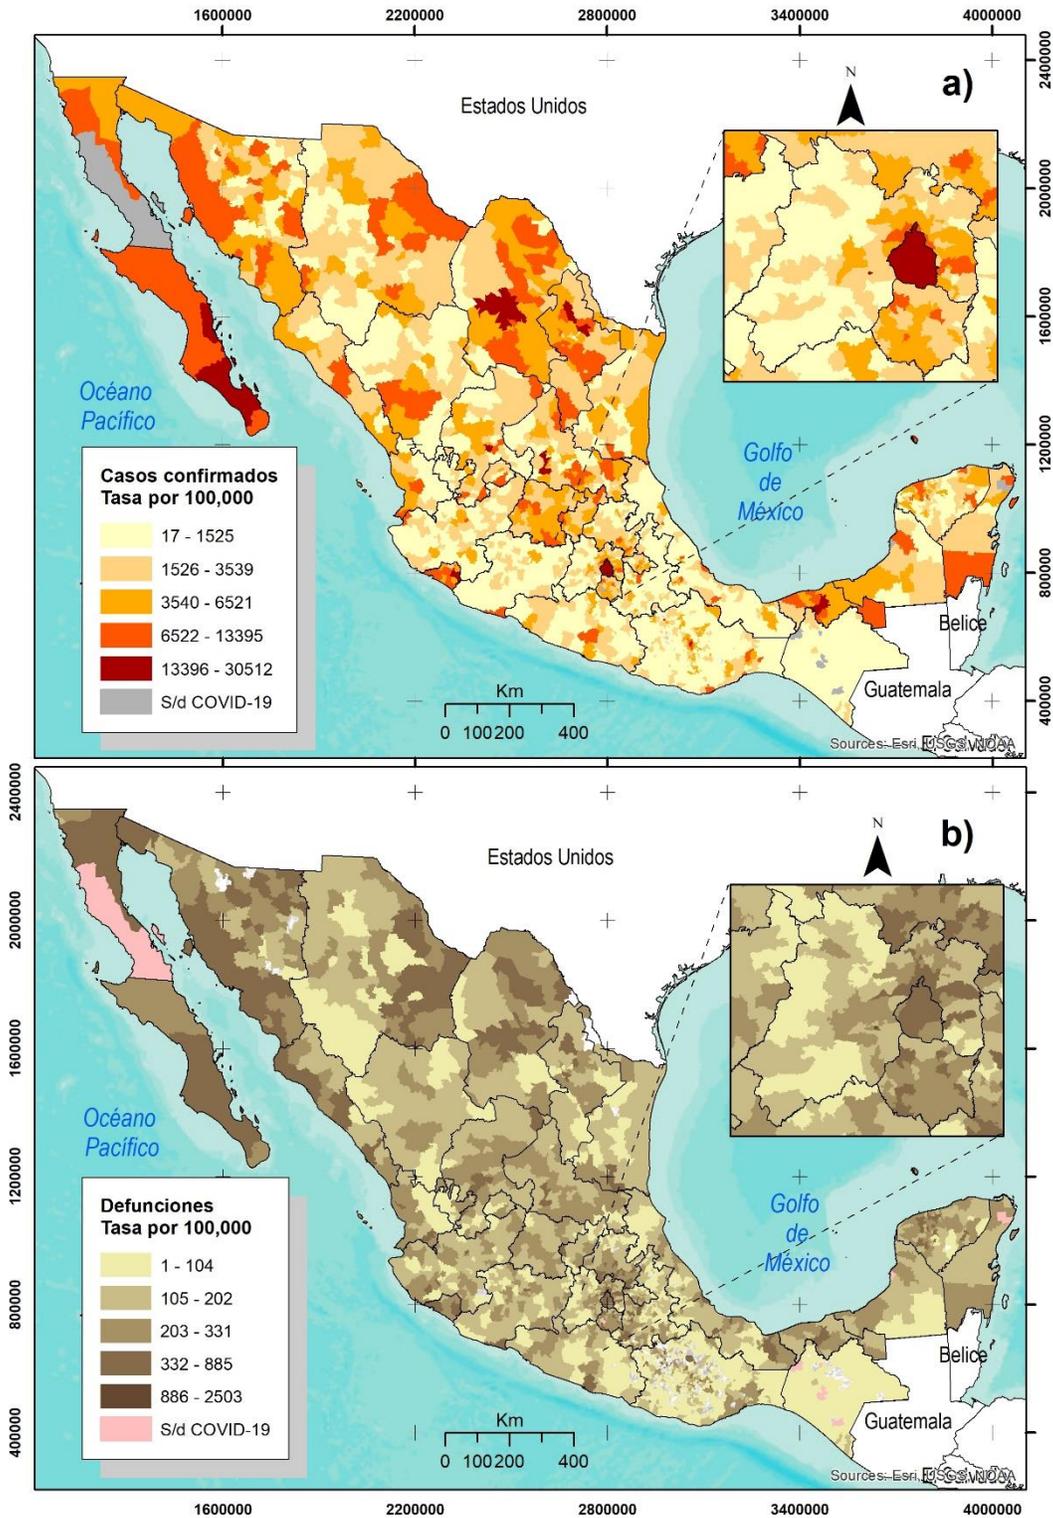
Del 01 de febrero de 2020 al 31 de diciembre de 2022, el número acumulado de casos confirmados de COVID-19 fue de 7,234,703. Las alcaldías Iztapalapa, Álvaro Obregón, Gustavo A. Madero y Tlalpan en CDMX encabezaron los primeros lugares con más casos (261,499, 231,631, 220,389, 175,194). En este orden, le siguen San Luis Potosí (SLP) en SLP, Puebla en Puebla, León en Guanajuato, Querétaro en Querétaro, Monterrey en Nuevo León (NL) y Centro en Tabasco con 150,587, 136,095, 132,168, 119,678, 113,989 y 109,106 casos, respectivamente.

Las tasas de casos confirmados más elevadas se registraron en ocho alcaldías de la CDMX, además de Loreto y La Paz en Baja California Sur (BCS). Álvaro Obregón, Milpa Alta, Tlalpan, Azcapotzalco y Tláhuac fueron las primeras cinco con 30,512.41, 25,282.77, 25,030.29, 23,103.62 y 22,413.74 casos por cada 100,000 habitantes. De manera distinta, 19 municipios de Oaxaca registraron 0 casos; por lo tanto, presentaron tasas con el mismo valor durante este periodo (figura 8a).

En relación con las defunciones de COVID-19, las primeras se registraron en marzo de 2020 y hasta diciembre de 2022 el número acumulado de muertes fue de 331,121. Los principales centros urbanos registraron el mayor número de defunciones, en específico, Iztapalapa en CDMX, Puebla en Puebla, Ecatepec de Morelos en el Estado de México (MEX), Gustavo A. Madero en CDMX, Guadalajara en Jalisco, Tijuana en Baja California (BC), León en Guanajuato, Monterrey en NL, Juárez en Chihuahua y Nezahualcóyotl en MEX con 8,588, 8,429, 6,956, 6,828, 6,755, 5,467, 5,336, 5,115, 4,703 y 4,484 defunciones, correspondientemente.

Las tasas de mortalidad más elevadas se registraron en Atizapán en MEX, Santa Magdalena Jicotlán y Tlatayapam en Oaxaca, además de Itzamal y Azcapotzalco en CDMX con 2,503.08, 2,469.14, 884.96, 687.68 y 679.08 defunciones por cada 100,000 habitantes, respectivamente. En cambio, 217 municipios de Chiapas, Oaxaca y Puebla, principalmente, registraron 0 defunciones de COVID-19 durante este periodo; por lo tanto, su tasa resultó con el mismo valor (figura 8b).

Figura 8. México. Distribución espacial de tasas de casos confirmados y tasas de defunciones de COVID-19 (febrero 2020-diciembre de 2022)



Fuente: Elaboración propia a partir de datos de la SS/DGE, 2020-2022.

3.2 Contexto temporal de COVID-19 y medidas de seguridad sanitaria

Para mitigar la transmisión de COVID-19 el Gobierno de México implementó medidas preventivas durante el transcurso de la pandemia. En este contexto, el primer caso de COVID-19 se registró el 27 de febrero de 2020, a partir de esa fecha la Secretaría de Salud informó a la población sobre las fases de la epidemia (hasta ese entonces). La fase 1. Importación del virus, se caracterizó por la importación de casos del extranjero, en otras palabras, las personas que enfermaron viajaron al exterior donde adquirieron la enfermedad y presentaron los síntomas a su regreso (figura 9).

La fase 2. Dispersión comunitaria, inició el 23 de marzo de 2020, se distinguió por la transmisión de persona a persona, además se implementó la "Jornada Nacional de Sana Distancia" (JNSD) que incluyó medidas preventivas como el distanciamiento social, la suspensión de eventos masivos en espacios cerrados y abiertos, la suspensión temporal de actividades no esenciales y escolares, entre otras. Nueve días después, el 1 de abril inició la fase 3. Contagio epidémico, de acuerdo con el INSP (2020) en esta fase "el número de casos aumentó a miles, los brotes fueron regionales y la dispersión de la enfermedad fue a nivel nacional" (figura 9).

Al mismo tiempo, la Secretaría de Educación Pública (SEP) informó que se adelantaron las vacaciones de "semana santa" (del 20 de marzo al 20 de abril) para estar en línea con las medidas de sana distancia. En junio del mismo año, México experimento un cambio de estrategia de prevención ante COVID19 denominada "La nueva normalidad", caracterizada por la reapertura gradual de actividades económicas sin descuidar la salud de la población, de acuerdo con un sistema de semáforo de riesgo epidemiológico semanal por regiones, estatal y municipal (figura 9).

No obstante, en julio de 2020, se registró el primer punto máximo de casos confirmados y defunciones mensuales de COVID-19 con 212,258 y 23,725, respectivamente. En diciembre de este año, inició el periodo vacacional decembrinas y la primera etapa de vacunación contra COVID-19 (24 de diciembre-20 de febrero de 2021) dirigida para trabajadores de salud, que estuvieron en la primera línea de atención, la aplicación de la vacuna comenzó de forma simultánea en la CDMX, Querétaro y Estado de México, después se extendió al resto de las entidades (figura 9).

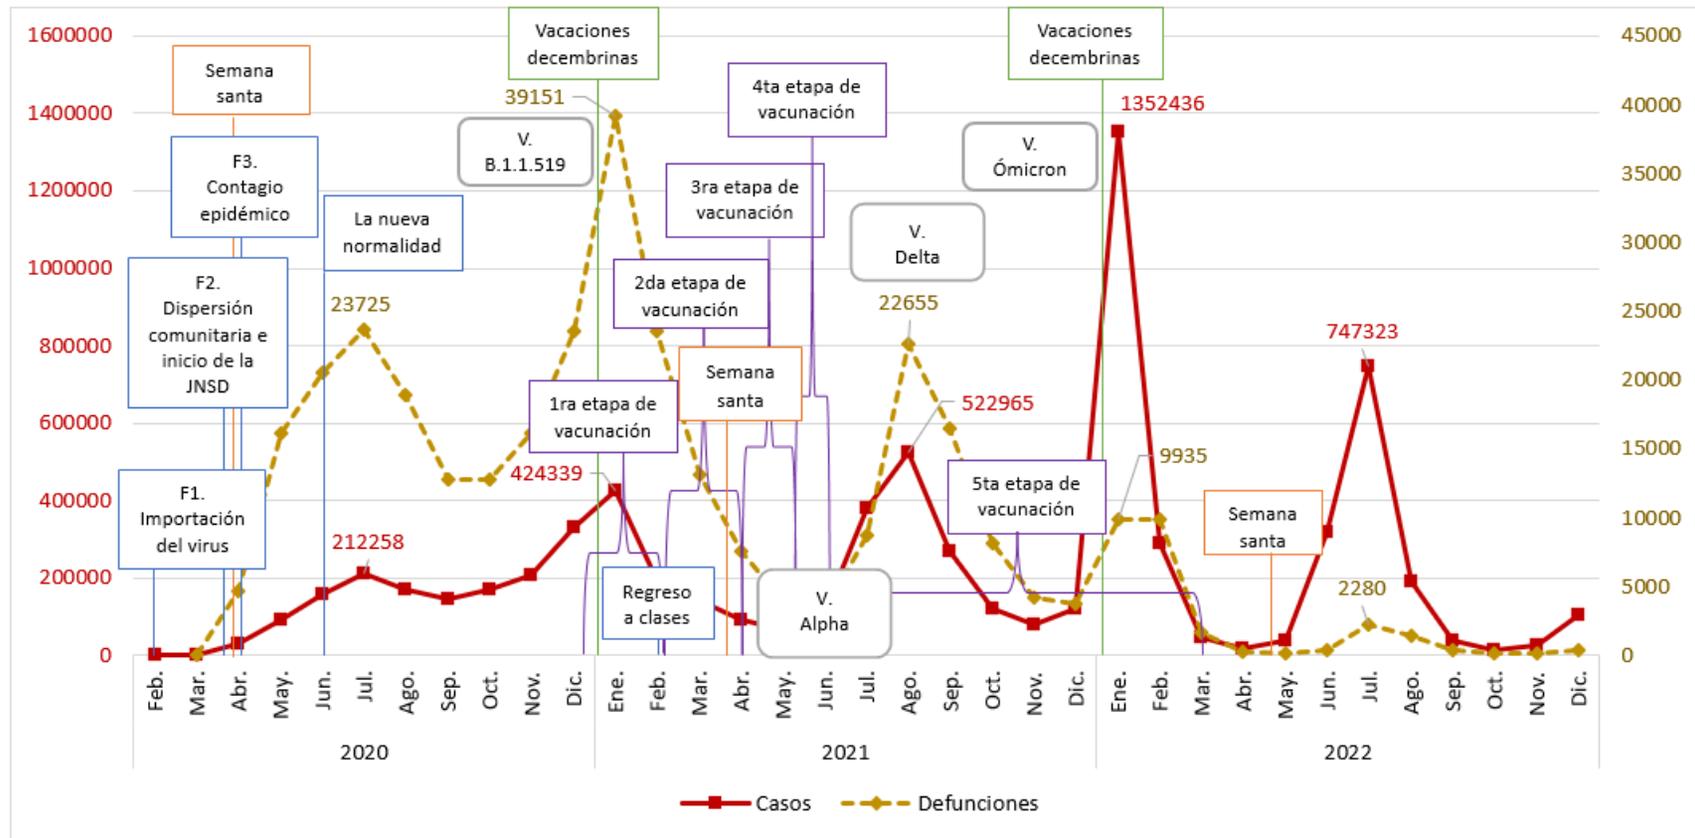
El inicio del 2021 no fue alentador, debido a que, en enero se registró el segundo punto máximo de casos confirmados mensuales con 424,339 y el mayor número de defunciones mensuales del periodo con 39,151. Un mes más tarde, la SEP anunció la reapertura de escuelas para el periodo escolar 2021-2022 señalando un regreso responsable y ordenado que incluía acciones de limpieza e higiene como jornadas de limpieza, filtros de corresponsabilidad (en casa, en la escuela y en el salón de clases), vacunación al personal educativo y el uso obligatorio de cubrebocas (figura 9).

La segunda etapa de vacunación (febrero-abril de 2021) fue dirigida al personal de salud restante y a la población de 60 años y más, mientras que el personal educativo inició con la aplicación de la primera dosis (20 de abril-28 de mayo), al mismo tiempo comenzó el periodo vacacional de "semana santa" de 2021. La campaña de vacunación continuó, de abril a mayo la vacuna fue dirigida a población de 50 a 59 años, la cuarta etapa (mayo-junio de 2021) incluyó a las personas de 40 a 49 años. Al mismo tiempo, la variante preponderante de COVID-19 fue Alpha (figura 9).

En agosto de 2021, se registró el tercer punto máximo de casos confirmados y defunciones mensuales de COVID-19 con 522,965 y 22,655, correspondientemente. Al mismo tiempo se realizaba la quinta etapa de vacunación (junio 2021-marzo 2022) dirigida al resto de la población y la variante Delta preponderaba en el país. En noviembre de 2021 la variante Ómicron apareció y en diciembre de este año dio inicio el periodo vacacional decembrinas. Posteriormente, en enero de 2022 se registró el cuarto punto máximo de casos confirmados con 1,352,436 (valor más elevado del periodo) y 9,935 defunciones (figura 9).

Durante 2022, la transmisión de COVID-19 disminuyó 55.25% en relación con el año anterior, sin embargo, en julio se registró el quinto punto máximo de casos confirmados y defunciones mensuales con 747,323 y 2,280, respectivamente (figura 9).

Figura 9. México. Casos confirmados y defunciones de COVID-19, y medidas de seguridad sanitaria (febrero de 2020-diciembre de 2022)



Fuente: Elaboración propia con base en el Gobierno de México (2020); Secretaría de Salud (2020); Secretaría de Gobernación (2020); Secretaría de Educación Pública (2021); Instituto Nacional de Salud Pública (2020), Ascencio-Montiel et al. (2022); Geosalud México (2023); Loza et al. (2023).

3.3 Conglomerados espaciotemporales de casos confirmados de COVID-19

Teniendo en cuenta el patrón de agrupación temporal, se observa que durante el 01 de mayo al 31 de agosto de 2021 se conformaron los primeros tres conglomerados (c18, c19 y c21) al suroeste, representados con un círculo verde; posteriormente, durante el 01 de enero al 30 de abril de 2022 se integraron cinco conglomerados (c7, c12, c23, c26 y c27) al noroeste, centro y suroeste (círculos amarillos); y durante el 01 de enero al 31 de agosto de 2022 se incorporaron 19 conglomerados (c1, c2, c3, c4, c5, c6, c8, c9, c10, c11, c13, c14, c15, c16, c17, c20, c22, c24, c25) que registraron la duración más larga (ocho meses), representado con un círculo rojo. Además, cada agrupación presentó un riesgo relativo diferente, el más alto resultó el c1 con 5.47 y el más bajo fue el c27 con 1.53 (figura 10).

Los conglomerados c18, c19 y c21 conformaron las primeras agrupaciones temporales (mayo-agosto de 2021), el c18 agrupó a Acapulco de Juárez, Tecoaapa, Chilpancingo de los Bravo (capital), Juan R. Escudero, Mochitlán y Quechultenango en Guerrero (RPL = 5188.39, $p < 0.001$), tuvo 19,870 casos y un riesgo relativo de 2.28; el c21 agrupó tres municipios de Guerrero y a Lázaro Cárdenas en Michoacán (RPL = 2804.06, $p < 0.001$), registró 7,265 casos y un riesgo relativo de 2.80; mientras que el c19 agrupó a Manzanillo y Minatitlán en Colima, 55 municipios de Jalisco y seis de Nayarit (RPL = 4687.92, $p < 0.001$), sumó 24,943 casos y un riesgo relativo de 1.98 (figura 10 y anexo 4).

Los conglomerados c7, c12, c23, c26 y c27 tuvieron una duración de enero a abril de 2022. El c7 se localizó al noroeste, agrupó nueve municipios de Aguascalientes, siete de Durango, 11 de Jalisco, ocho de Nayarit y 46 de Zacatecas (RPL = 26857.98, $p < 0.001$), incluidas sus capitales (excepto Jalisco), registró 75,342 casos y un riesgo relativo de 2.68; el c12 se situó en Guadalajara (octavo municipio más poblado, 1,385,629 habitantes) (RPL = 12788.50, $p < 0.001$) tuvo 29,803 casos y un riesgo relativo de 2.99 (figura 10 y anexo 4).

El c23 se situó en el centro del país, incluyó siete municipios de Hidalgo, seis de MEX y San Juan del Río en Querétaro (RPL = 848.28, $p < 0.001$), registró 8,410 casos y un riesgo relativo de 1.63; los conglomerados c26 y c27 se localizaron al sur, el primero agrupó 26 municipios de Guerrero, 42 de MEX incluido Toluca (capital), seis de Michoacán y 15 de Morelos (RPL = 289.36, $p < 0.001$), sumó 35,718 casos y un riesgo

relativo de 1.14; el c27 agrupó cuatro municipios de Guerrero y nueve de Oaxaca (RPL = 82.29, $p < 0.001$), registró 1,044 y el riesgo relativo más bajo de 1.53 (figura 10 y anexo 4).

La duración más larga (enero-agosto de 2022), se registró en 19 conglomerados incluido el más probable (c1), localizado en el centro del país, agrupó ocho alcaldías del norte de la CDMX (Miguel Hidalgo, Cuauhtémoc, Venustiano Carranza, Azcapotzalco, Gustavo A. Madero, Álvaro Obregón, Benito Juárez e Iztacalco) y Naucalpan de Juárez en MEX (RPL = 357594.99, $p < 0.001$), registró 335,027 más casos de los esperados, lo que resultó en 414,483 casos en total y el riesgo relativo más alto de 5.47 (figura 10 y anexo 4).

El c2 fue adyacente al c1, integró siete alcaldías de la CDMX, entre ellas Iztapalapa, segundo municipio más poblado (1,835,486 habitantes), además de nueve municipios de MEX y cinco de Morelos (RPL = 227241.58, $p < 0.001$), sumó 256,878 más casos de los esperados, lo que resultó en 339,695 casos en total y un riesgo relativo de 4.25; el c3 agrupó 17 municipios de Guanajuato incluido León (tercer municipio más poblado, 1,721,215 habitantes), Querétaro en Querétaro y 10 en SLP (RPL = 227241.58, $p < 0.001$), este conglomerado registró 230,977 casos y un riesgo relativo de 2.93 (figura 10 y anexo 4).

El c4 agrupó los cinco municipios que integran BCS, nueve de Chihuahua, 11 de Sinaloa y 25 de Sonora (RPL = 66633.92, $p < 0.001$), incluidas sus capitales (excepto Chihuahua), el total de casos fue de 193,138 con un riesgo relativo de 2.64; el c5 incorporó 22 municipios de NL, incluido Monterrey (capital y décimo municipio más poblado, 1,142,994 habitantes), además se agruparon Arteaga y Saltillo (capital) en Coahuila, Cedral y Vanegas en SLP, Mainero y Villagrán en Tamaulipas, Concepción del Oro y El Salvador en Zacatecas (RPL = 47185.68, $p < 0.001$), registró 187,611 casos y un riesgo relativo de 2.25 (figura 10 y anexo 4).

El c6 se localizó en el centro de Tabasco, incluyó a los municipios de Centro y Nacajuca (RPL = 29099.53, $p < 0.001$), registró 35,087 más casos de los esperados, lo que resultó en 47,262 casos en total y un riesgo relativo de 3.90; el c8 se localizó en 80% de los municipios de Yucatán y en municipios turísticos de Quintana Roo como Cozumel, Isla Mujeres, Benito Juárez, Lázaro Cárdenas, Solidaridad y Tulum (RPL = 20998.12, $p < 0.001$), sumó 95,266 casos y un riesgo relativo de 2.12 (figura 10 y anexo 4).

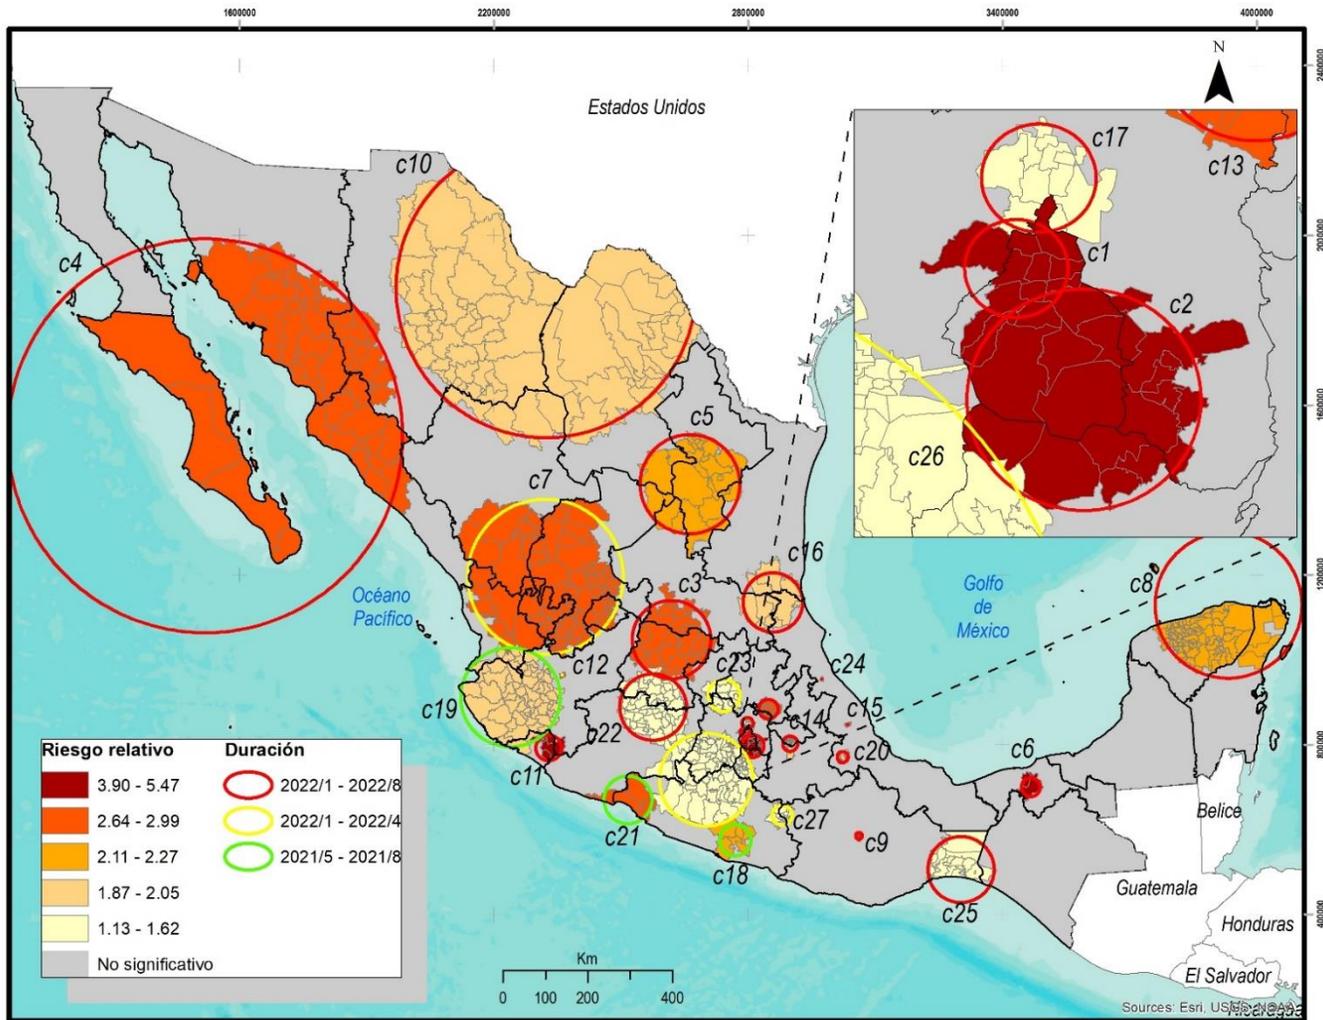
El c9 se ubicó en el centro de Oaxaca, incluyó los municipios de Guadalupe Etla, San Agustín Etla, San Andrés Huayápam, San Jacinto Amilpas, San Pablo Etla, Villa de Etla y Oaxaca de Juárez (capital) (RPL = 18166.47, $p < 0.001$), registró 18,357 más casos de los esperados, lo que resultó en 23,130 casos en total y un riesgo relativo de 4.86; el c10 integró gran parte de Coahuila y Chihuahua (28 y 42 municipios, respectivamente), además incluyó a Hidalgo, Mapimí, Ocampo y Tlahualilo en Durango (RPL = 17832.16, $p < 0.001$), el total de casos fue de 86,970 con un riesgo relativo de 2.05 (figura 10 y anexo 4).

El conglomerado c11 se localizó al oeste, agrupó a Colima (capital), Cuauhtémoc, Ixtlahuacán y Villa de Álvarez en Colima, además incluyó a Pihuamo en Jalisco (RPL = 16665.87, $p < 0.001$), registró 17,816 más casos de los esperados, lo que resultó en 22,902 casos en total y un riesgo relativo de 4.51; el c13 agrupó nueve municipios de Hidalgo, así como a Axapusco y Nopaltepec en MEX (RPL = 11909.43, $p < 0.001$), registró 30,206 casos y un riesgo relativo de 2.84 (figura 10 y anexo 4).

El c14 integró 23 municipios de Tlaxcala y seis de Puebla (RPL = 11431.32, $p < 0.001$), incluida Puebla (capital y cuarto municipio más poblado, 1,692,181 habitantes), este conglomerado registró 66,891 casos y un riesgo relativo de 1.92; el c15 se ubicó en Xalapa (capital de Veracruz) (RPL = 7816.54, $p < 0.001$), registró 20,050 casos y un riesgo relativo de 2.82; el c16 incluyó seis municipios de SLP, cinco de Tamaulipas, Pánuco, Pueblo Viejo y El Higo en Veracruz (RPL = 6956.38, $p < 0.001$), tuvo 39,085 casos y un riesgo relativo de 1.94 (figura 10 y anexo 4).

El c17 fue adyacente al c1, incluyó nueve municipios de MEX (RPL = 5862.86, $p < 0.001$), de los que destaca Ecatepec de Morelos (quinto municipio más poblado, 1,645,352 habitantes) sumó 87,943 casos y un riesgo relativo de 1.48; el c20 agrupó 13 municipios de Veracruz (RPL = 3306.64, $p < 0.001$) con 17,011 casos y un riesgo relativo de 2.01; el c22 integró 19 municipios del sur de Guanajuato y 36 de Michoacán (RPL = 1772.68, $p < 0.001$), incluida Morelia (capital), este conglomerado sumó 72,699 casos y un riesgo relativo de 1.26; el c24 se situó en Poza Rica de Hidalgo en Veracruz (RPL = 836.20, $p < 0.001$) y sumó 5,180 casos con un riesgo relativo de 1.87; el c25 incluyó 24 municipios de Oaxaca y Arriaga en Chiapas (RPL = 473.65, $p < 0.001$), sumó 8,439 casos y un riesgo relativo de 1.43 (figura 10 y anexo 4).

Figura 10. México. Conglomerados espaciotemporales de casos confirmados de COVID-19 (febrero 2020 - diciembre 2022)



Fuente: Elaboración propia a partir de datos de la SS/DGE, 2020-2022.

3.4 Conglomerados espaciotemporales de defunciones de COVID-19

En relación con las defunciones de COVID-19, se observó que durante el 01 de marzo al 31 de agosto de 2020 se conformaron los primeros tres conglomerados (c11, c15 y c19) al sureste y noreste, representados con un círculo rosa; posteriormente, durante el 01 de marzo al 31 de diciembre de 2020 (duración más larga) se incorporó el c12 localizado al noroeste (círculo morado); los conglomerados c6 y c13 se ubicaron al norte y tuvieron una duración del 01 de septiembre al 31 de diciembre de 2020 (círculos verdes) (figura 11).

Los conglomerados c1, c3, c4, c5, c7, c8, c9, c10, y c18 se integraron con una duración del 01 de septiembre de 2020 al 30 de abril de 2021 (círculos amarillos); tres conglomerados (c2, c14 y c17) localizados en el centro, este y oeste tuvieron una duración del 01 de enero al 30 de abril de 2021 (círculos naranjas); el último conglomerado (c16) se conformó al oeste, del 01 de enero al 31 de agosto de 2021, representado con un círculo rojo. De acuerdo con el riesgo relativo de cada conglomerado el más alto fue el c1 con 3.61 y el más bajo fue el 19 con 1.42 (figura 11).

Los conglomerados c11, c15 y c19 conformaron las primeras agrupaciones temporales (marzo-agosto de 2020), c11 y c15 se localizaron al sureste y el c19 al noreste, el c11 agrupó 10 municipios de Chiapas, 51 de Oaxaca, nueve de Tabasco y 57 de Veracruz (RPL = 1132.20, $p < 0.001$), sumó 5,574 defunciones y un riesgo relativo de 2.05 (figura 11 y anexo 5).

El c15 integró 11 municipios de Campeche, 10 de Quintana Roo, 105 de Yucatán, seis de Tabasco, Catazajá, La Libertad y Palenque en Chiapas (RPL = 584.20, $p < 0.001$), registró 4,976 defunciones y un riesgo relativo de 1.70, se debe mencionar, que los municipios de Seybaplaya en Campeche, Puerto Morelos en Quintana Roo y Tahdziú en Yucatán no registraron defunciones; el c19 agrupó 22 municipios de NL, siete de SLP, 39 de Tamaulipas y tres en Veracruz (RPL = 147.60, $p < 0.001$), registró 2,711 defunciones y el riesgo relativo más bajo 1.42 (figura 11 y anexo 5).

El c12 tuvo la duración más larga (marzo-diciembre de 2020), se localizó al noroeste e incluyó a Ensenada, Mexicali, Tecate, Tijuana (municipio más poblado, 1,922,523 habitantes) y Playas de Rosarito en BC, y 17 municipios de Sonora (RPL =

1103.44, $p < 0.001$), registró 7,911 defunciones y un riesgo relativo de 1.79 (figura 11 y anexo 5).

Los conglomerados c6 y c13 fueron adyacentes y tuvieron una duración menor (septiembre-diciembre de 2020); sin embargo, agruparon gran parte de la región norte, el c6 integró 27 municipios de Coahuila, los 67 municipios que integran Chihuahua, 13 de Durango, Choix en Sinaloa y 36 en Sonora (RPL = 2007.98, $p < 0.001$), registró 5,943 defunciones y un riesgo relativo de 2.60; el c13 agrupó a Torreón en Coahuila, 21 municipios de Durango, 10 de Jalisco, ocho de Nayarit y 32 en Zacatecas (incluidas las capitales de Durango y Zacatecas) (RPL = 746.53, $p < 0.001$), sumó 3,039 defunciones y un riesgo relativo de 2.22 79 (figura 11 y anexo 5).

Nueve conglomerados (c1, c3, c4, c5, c7, c8, c9, c10, y c18) tuvieron una duración de septiembre de 2020 a abril de 2021, se localizaron al centro, noroeste y sur, el principal (c1) agrupó a Azcapotzalco, Coyoacán, Gustavo A. Madero, Iztacalco, Benito Juárez, Cuauhtémoc, Miguel Hidalgo y Venustiano Carranza en el norte de la CDMX (RPL = 7240.81, $p < 0.001$), registró 9,400 más muertes de las esperadas, lo que resultó en 13,144 defunciones en total y el riesgo relativo más alto de 3.61; los clusters c3, c4 y c5 fueron adyacentes al c1, el c3 integró 13 municipios de MEX (RPL = 2547.48, $p < 0.001$), sumó 9,251 defunciones y un riesgo relativo de 2.35 79 (figura 11 y anexo 5).

El c4 agrupó cuatro alcaldías del suroeste de la CDMX (Cuajimalpa de Morelos, La Magdalena Contreras, Álvaro Obregón, Tlalpan) y 21 municipios de MEX, incluida Toluca (capital) (RPL = 2426.76, $p < 0.001$), tuvo 9,387 defunciones y un riesgo relativo de 2.28; el c5 incluyó a Iztapalapa y Tláhuac (en CDMX) y cinco municipios de MEX (RPL = 2046.08, $p < 0.001$), registró 8,814 muertes y un riesgo relativo de 2.17 79 (figura 11 y anexo 5).

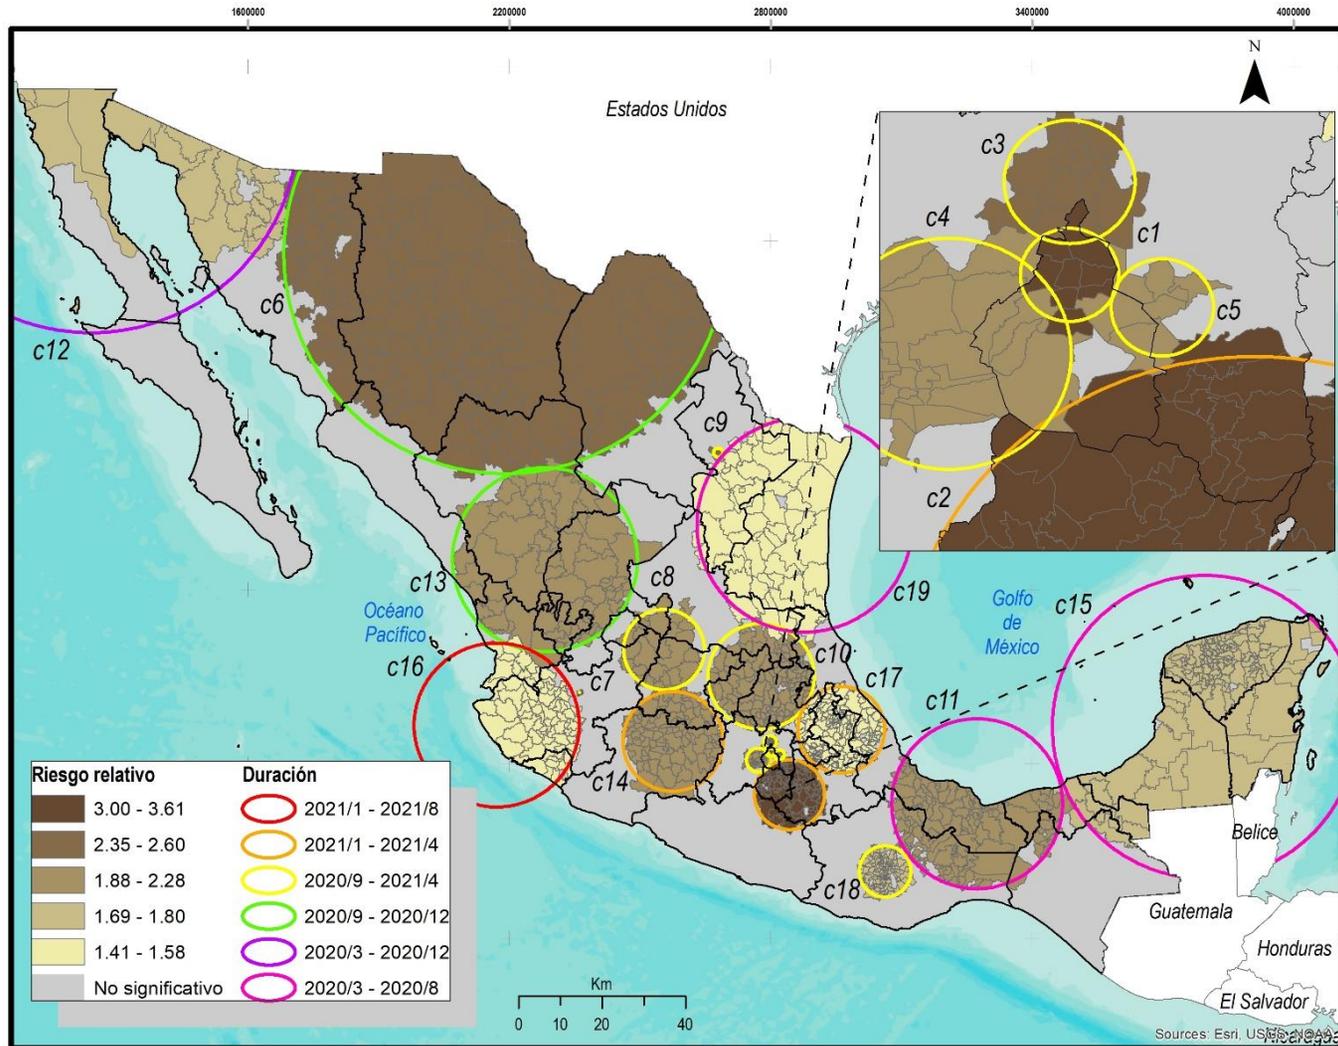
El c7 se situó en Guadalajara (RPL = 2046.08, $p < 0.001$), tuvo 2,528 más muertes de las esperadas, lo que resultó en 3,690 defunciones en total y un riesgo relativo de 3.20; el c8 agrupó a Aguascalientes, Asientos y El Llano en Aguascalientes, 10 municipios de Guanajuato (incluido León), seis de Jalisco, cuatro de SLP, incluida su capital (San Luis Potosí), así como Loreto, Pinos y Villa García en Zacatecas (RPL = 1735.83, $p < 0.001$), sumó 8,800 defunciones y un riesgo relativo de 2.03; el C9 agrupó a Guadalupe, Monterrey y San Nicolás de los Garza en NL (RPL = 1299.92, $p < 0.001$), registró 4,423 y un riesgo relativo de 2.42 79 (figura 11 y anexo 5).

El c10 integró siete municipios de Guanajuato, 63 de Hidalgo incluida Pachuca (capital), seis de MEX, 15 de Querétaro, 21 de SLP y 10 de Veracruz (RPL = 1187.97, $p < 0.001$), sumó 7,266 muertes y un riesgo relativo de 1.89; el c18 se localizó en el centro de Oaxaca y agrupó 118 municipios, incluido Oaxaca de Juárez (capital) (RPL = 183.20, $p < 0.001$), registró 567 más defunciones de las esperadas, lo que resultó en 1,273 defunciones en total y un riesgo relativo de 1.80 79 (figura 11 y anexo 5).

En enero de 2021 se conformaron tres conglomerados (c2, c14 y c17) y finalizaron en abril de ese año, el c2 agrupó a Milpa Alta en CDMX, seis municipios de Guerrero, 12 de MEX, 33 de Morelos incluida Cuernavaca (capital) y 60 de Puebla, incluida su capital (Puebla) (RPL = 2840.71, $p < 0.001$), registró 4,390 más defunciones de las esperadas, lo que resultó en 6,620 muertes en total y el riesgo relativo de 3.01; el c14 integró 24 municipios de Guanajuato, Ixtapan del Oro en MEX y 77 en Michoacán de Ocampo, incluida Morelia (capital) (RPL = 734.41, $p < 0.001$), sumó 4,488 defunciones y un riesgo relativo de 1.89; el c17 incluyó 13 municipios de Hidalgo, 84 de Puebla, 50 de Tlaxcala, incluida su capital (Tlaxcala) y 52 de Veracruz (incluida Xalapa) (RPL = 275.88, $p < 0.001$), registró 3065 defunciones y un riesgo relativo de 1.58 79 (figura 11 y anexo 5).

Por último, el conglomerado c16 tuvo una duración del 01 de enero al 31 de agosto de 2021, se localizó al oeste, agrupó nueve municipios de Colima, incluida su capital (Colima), 59 de Jalisco y 11 de Nayarit, incluido Tepic (capital) (RPL = 278.19, $p < 0.001$), registró 3,410 defunciones y un riesgo relativo de 1.54 79 (figura 11 y anexo 5).

Figura 11. México. Conglomerados espaciotemporales de defunciones de COVID-19 (marzo 2020 - diciembre 2022)



Fuente: Elaboración propia a partir de datos de la SS/DGE, 2020-2022.

3.5 Conclusiones de la dinámica espaciotemporal de COVID-19 en México

La distribución espacial de COVID-19 resultó heterogénea en gran parte del país, se observaron patrones de distribución de tasas altas de casos confirmados en las regiones norte y península de Yucatán, las 16 alcaldías de la CDMX registraron las tasas más elevadas. En cambio, los municipios con tasas bajas formaron patrones de distribución en el Pacífico sur donde la población vive en comunidades rurales y la movilidad de personas que pueden ser portadoras del SARS-CoV-2 es menor en comparación con los centros urbanos. En relación con las defunciones, los patrones de distribución de tasas altas se observaron en las regiones norte, centro, península de Yucatán y CDMX. En contraste, municipios de Oaxaca y Chiapas registraron las tasas de defunciones más bajas, este comportamiento se relaciona con las bajas tasas de casos, en otras palabras, al haber pocas personas enfermas, se evitan las muertes.

Las medidas preventivas implementadas por el Gobierno de México incluida la campaña de vacunación, las variantes de COVID-19 y las conductas sociales son algunos factores que influyen en la propagación o contención de SARS-CoV-2. En particular, se observó una relación entre las vacaciones decembrinas con los puntos máximos de defunciones (segunda ola) y de casos confirmados (cuarta ola) en enero de 2021 y 2022, respectivamente. Además, la variante Ómicron tuvo una rápida transmisión comunitaria que incidió en los aumentos de casos en la ola 4, también hubo más pruebas en comparación con las primeras olas, estos factores pudieron aumentar los registros de casos confirmados. En cambio, la campaña de vacunación contribuyó a la reducción de muertes a partir de la tercera oleada.

Los conglomerados espaciotemporales de COVID-19 evidenciaron los lugares con mayor riesgo relativo. Se identificaron 27 conglomerados estadísticamente significativos de casos confirmados, el más probable (c1) se concentró al norte de la CDMX y en Naucalpan de Juárez en MEX, además tuvo la duración más larga (enero-agosto 2022) que se relaciona con la cuarta (más severa) y quinta ola de casos confirmados. En relación con las defunciones, se identificaron 19 conglomerados estadísticamente significativos, el más probable se agrupó de manera similar que el c1 (de casos) y tuvo una duración de septiembre de 2020 a abril de 2021 que se relaciona con la segunda ola (más severa) de defunciones.

Capítulo 4. Contexto espacial y estadístico de factores de riesgo relacionados con COVID-19.

El capítulo 4, contextualiza la distribución espacial y estadística de factores de riesgo asociados con COVID-19, a partir de tres apartados: el primero presenta mapas de distribución de 25 indicadores en las dimensiones estatus socioeconómico, características de la población, condiciones de vivienda e higiene, factores epidemiológicos y factores del sistema de salud; el apartado siguiente analiza las estadísticas descriptivas y la distribución de los datos de los indicadores; el capítulo finaliza con los resultados del análisis de correlación.

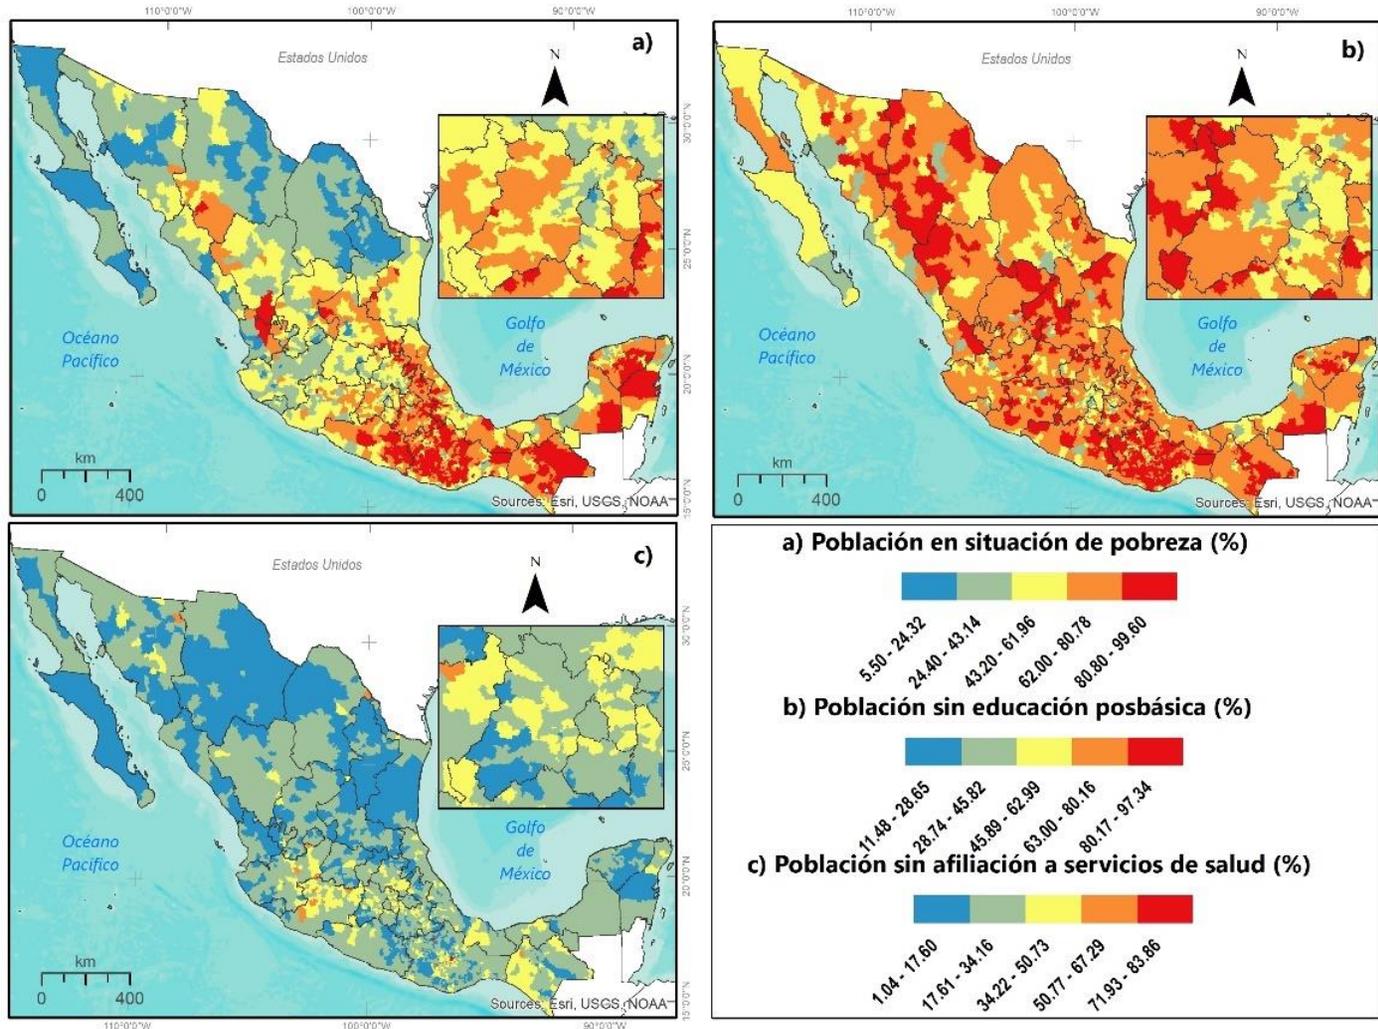
4.1 Distribución espacial de factores de riesgo relacionados con COVID-19

La figura 12a muestra que la población en situación de pobreza se distribuye de manera heterogénea, 49.57% de los municipios (1,224) se encuentran por encima de la media nacional que es de 61.95%. Los valores más altos (80.80%-99.60%) se observan en 601 municipios (24.34%), localizados en las regiones Pacífico sur y península de Yucatán. San Simón Zahuatlán en Oaxaca, Cochoapa el Grande en Guerrero y San Juan Cancuc en Chiapas son los lugares más pobres con 99.60%, 99.40% y 99.30%, respectivamente. Caso contrario, presentaron 5.10% de los municipios (126) que obtuvieron los valores más bajos (5.50%-24.32%), localizados al centro, norte y noroeste. San Pedro Garza García (5.50%) y Parás (7.30%) en NL, y Benito Juárez (7.90%) en CDMX destacan por tener mejores condiciones socioeconómicas en comparación con el resto de los municipios.

La población de 18 años y más sin educación posbásica se distribuye de manera desigual, 57.27% de los municipios (1,414) rebasan la media nacional (71.99%). Se observa que 690 (27.94%) registraron los valores más elevados (80.17%-97.34%), localizados en las regiones norte y suroeste. Chamula en Chiapas, Magdalena Teitipac y San Pedro Taviche en Oaxaca son los lugares con mayor deficiencia escolar universitaria con 97.34%, 96.75% y 96.41%, correspondientemente. En cambio, cinco municipios (0.20%) registraron los valores más bajos (11.48%-28.65%), las alcaldías Benito Juárez (11.48%), Miguel Hidalgo (23.57%) y Coyoacán (27.67%) en CDMX son los lugares con menor población sin estudios universitarios, es decir, tienen mayor preparación escolar universitaria en comparación con el resto de los municipios (figura 12b).

La distribución espacial de la población sin afiliación a servicios de salud resultó heterogénea, 45.48% de los municipios (1,123) se encuentran por encima de la media nacional (24.11%). Santa Ana Ateixtlahuaca, Santa María Ixcatlán y Villa Díaz Ordaz en Oaxaca registraron los valores más altos con 83.86%, 77.87% y 71.93%, respectivamente; es decir, son los lugares que más carecen de este servicio. De manera distinta, 29.76% de los municipios (735) registraron los valores más bajos (1.04%-17.60%), San Pedro Ocotepéc en Oaxaca (1.04%), La Magdalena Tlaltelulco en Tlaxcala (1.6%) y Chacsinkín en Yucatán (1.71%) son los lugares con menor población sin afiliación a servicios de salud, en otras palabras, más del 98% de la población de estos municipios está afiliada a servicios de salud (figura 12c).

Figura 12. México. Dimensión: Estatus socioeconómico, 2020



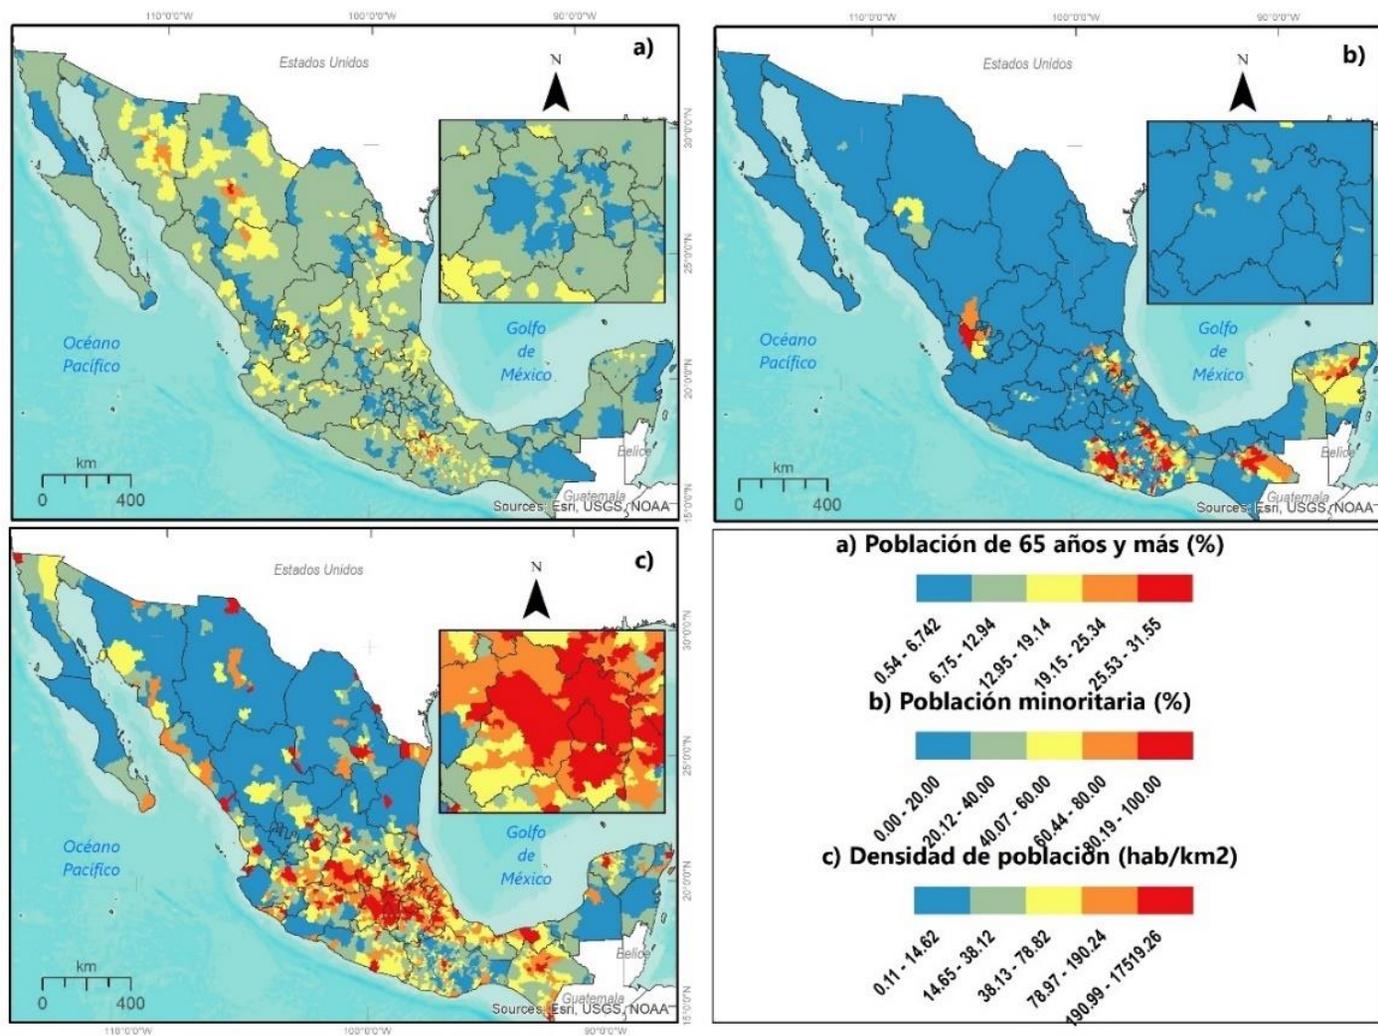
Fuente: Elaboración propia a partir de datos del CONEVAL (2020); INEGI (2020).

La dimensión características de la población está conformada por tres factores de riesgo, la figura 13a muestra que la población de 65 años y más se distribuye manera heterogénea, 40.86% de los municipios (1,009) rebasan la media nacional que es de 10.47%. Los valores más elevados (25.53%-31.55%) se registraron en 23 municipios (0.93%), San Andrés Yaá (31.55%), Cosoltepec (30.39%) y Santiago Huaucilla (30.29%) en Oaxaca son los lugares con más población en edad avanzada. Caso contrario, presentaron 15.47% de los municipios (382) que obtuvieron los valores más bajos (0.54%-6.74%), localizados a lo largo del territorio nacional. La Magdalena Tlaltelulco en Tlaxcala, El Carmen y Pesquería en NL son los lugares con menor población de 65 años y más con 0.54%, 1.48% y 1.74%, respectivamente.

La población minoritaria se agrupó en diferentes regiones, principalmente al noroeste, sureste y Pacífico sur. Los valores más altos (80.19%-100%) se observaron en 7.61% de los municipios (188). San Juan Quiotepec, San Cristóbal Amatlán y Santa María Temascaltepec en Oaxaca; Malinaltepec y Xochistlahuaca en Guerrero; y Mayapán en Yucatán son lugares que cuentan con el 100% de sus habitantes en este grupo poblacional. De manera distinta, 73.14% de los municipios (1,806) registraron los valores más bajos (0%-20%), además 186 municipios (7.53%) reportaron cero poblaciones minoritarias (figura 13b).

La densidad de población se distribuye de manera desigual, no obstante, se observaron agrupaciones de valores altos en el centro del país, principalmente, 19.96% de los municipios (493) registraron los valores más elevados (190.99-17,519.26 hab/km²). Iztacalco y Cuauhtémoc en CDMX y Nezahualcóyotl en MEX son los lugares con mayor concentración de población con 17,519.26, 16,786.1 y 17,025.57 habitantes por kilómetro cuadrado, correspondientemente. Caso contrario, presentaron 20% de los municipios (494) localizados al norte, debido a que registraron los valores más bajos (0.11-14.62 hab/km²). Coyame del Sotol (0.11) y Manuel Benavides (0.23) en Chihuahua, así como Ocampo (0.37) en Coahuila son los lugares que concentran menor población (figura 13c).

Figura 13. México. Dimensión: Características de la población, 2020



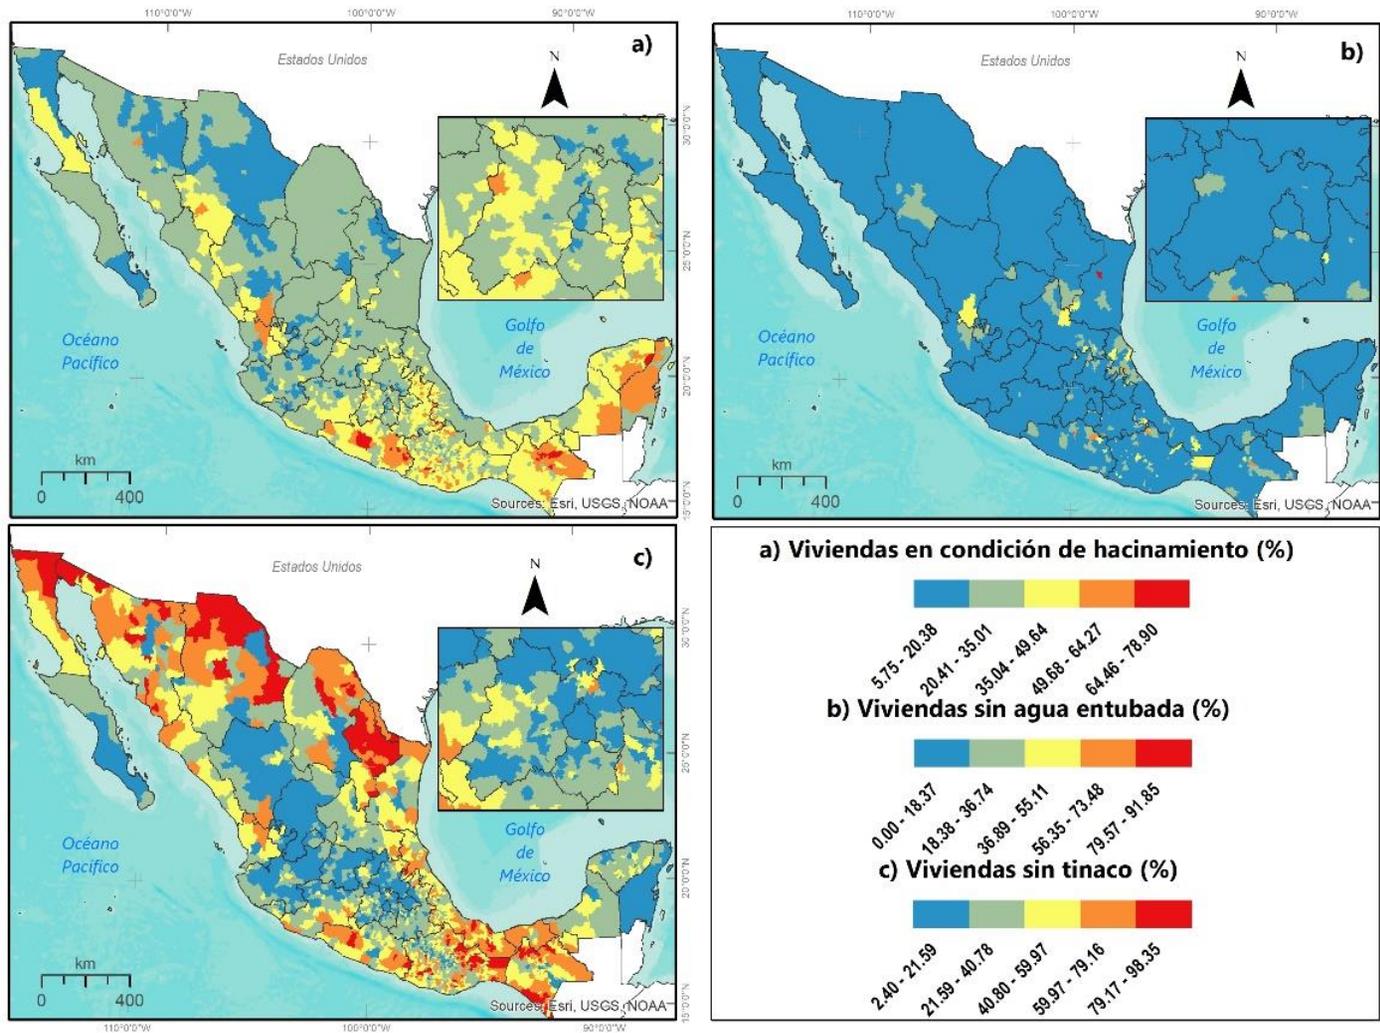
Fuente: Elaboración propia a partir de datos del INEGI, 2020.

La dimensión condiciones de vivienda e higiene incluye tres factores de riesgo, la figura 14a, muestra que las viviendas particulares habitadas en condición de hacinamiento se distribuyen de manera desigual, 45.80% de los municipios (1,131) se encuentran por encima de la media nacional que es de 33.74%. Los valores más elevados (64.46%-78.90%) se registraron en 22 municipios (0.89%) localizados en las regiones Pacífico sur y sureste, principalmente. Chemax en Yucatán (67.01%), Tehuipango (72.84%) y Filomeno Mata (78.90%) en Veracruz son los lugares con más viviendas hacinadas. De manera distinta, 9.43% de los municipios (233) obtuvieron los valores más bajos (5.75%-20.38%), localizados en las regiones norte y bajío. La alcaldía Benito Juárez (5.75%) en CDMX, Dr. Belisario Domínguez (7.78%) y Manuel Benavides (8.26%) en Chihuahua son los lugares con menos viviendas hacinadas en comparación con el resto de los municipios.

La distribución espacial de las viviendas particulares habitadas sin agua entubada presentó agrupaciones en gran parte del país, 29.32% de los municipios (724) rebasan la media nacional que es de 6.62%. La Magdalena Tlaltelulco en Tlaxcala y San Nicolas en Tamaulipas registraron los valores más altos con 91.85% y 79.57%, correspondientemente, en decir, estos lugares carecen del servicio de agua entubada. En cambio, 71% de los municipios (1,745) registraron valores bajos de viviendas sin agua entubada (0.00%-18.37), 27 municipios (1.09%) resultaron con valores de cero, en otras palabras, todas las viviendas cuentan con el servicio, localizadas en Oaxaca, Coatepec en Puebla y, Divisaderos, Granados y San Felipe de Jesús en Sonora (figura 14b).

Las viviendas particulares habitadas sin tinaco se distribuyen de manera heterogénea, 44.22% de los municipios (1,092) se encuentran por encima de la media nacional (39.44%). Los valores más altos (79.17%-98.35%) se registraron en 160 municipios (6.48%) localizados al norte y Pacífico sur, los que destacan por registrar más del 95% de viviendas sin tinaco son Mexicali en BC, Nuevo Casas Grandes y Juárez en Chihuahua, Los Aldamas en NL, Solosuchiapa en Chiapas y San Juan Bautista Tlacoatzintepec en Oaxaca con 98.35%, 96.26%, 95.11%, 95.38%, 95.19% y 95.05%, correspondientemente. De manera distinta, 26.16% de los municipios (646) registraron los valores más bajos (2.40%-21.59%). Momax y Zacatecas en Zacatecas, y Huejúcar en Jalisco, localizados al noroeste obtuvieron los valores más bajos con 2.40%, 3.54% y 2.70%, respectivamente; en otras palabras, en estos lugares más del 95% de las viviendas cuentan con tinaco (figura 14c).

Figura 14. México. Dimensión: Condiciones de vivienda e higiene, 2020



Fuente: Elaboración propia a partir de datos del INEGI, 2020.

La dimensión factores epidemiológicos (egresos hospitalarios) incluye seis comorbilidades, la figura 15a muestra que las tasas de egresos por enfermedades cardiovasculares se distribuyen de manera desigual, 26.24% de los municipios (648) rebasan la media nacional que es de 51.90. Nácori Chico y Tepache en Sonora, Santiago Tepetlapa y Santo Domingo Tomaltepec en Oaxaca son los lugares que presentan los valores más elevados con 1,894.19, 679.12, 769.23 y 679.27, respectivamente. En cambio, los valores más bajos (0.65-41.75) se registraron en 45.84% de los municipios (1,132), localizados a lo largo del territorio nacional. Santa Catarina (0.65), Pesquería (1.35) y García (1.51) en NL son los lugares con egresos cardiovasculares más bajos.

Las tasas de egresos por enfermedades respiratorias se distribuyen de manera heterogénea, 30.49% de los municipios (753) se encuentran por encima de la media nacional (68.67). Los valores más altos (495.54-914.44) se observaron en cinco municipios (0.20%), Nácori Chico y Divisaderos en Sonora, y Santiago Tepetlapa en Oaxaca registraron las tasas más elevadas, con 914.44, 664.01 y 769.23, correspondientemente. Caso contrario, presentaron 44.14% de los municipios (1,090) localizados a lo largo del país, debido a que registraron los valores más bajos (1.96-55.01). General Zuazua (1.96) y San Pedro Garza García (2.27) en NL, y Huautla de Jiménez (3.15) en Oaxaca son los lugares con egresos respiratorios más bajos (figura 15b).

Las tasas de egresos por cáncer se distribuyen de manera desigual, 18.06% de los municipios (446) rebasan la media nacional que es de 191.28. Los valores más altos (3,853.21-7,529.24) se registraron en 8 municipios (0.32%) localizados al noroeste y en Oaxaca. Soyopa en Sonora, San Juan Teita y San Pedro Mixtepec en Oaxaca son los lugares con las tasas más elevadas con 7,529.24, 6,985.29 y 5,041.15, respectivamente. De manera distinta, 63.91% de los municipios (1,578) obtuvieron los valores más bajos (0.33-217.79), localizados a lo largo del país. Santa Catarina, García y Juárez en NL son los lugares con egresos por cáncer más bajos con 0.33, 1.01 y 1.27, correspondientemente (figura 15c).

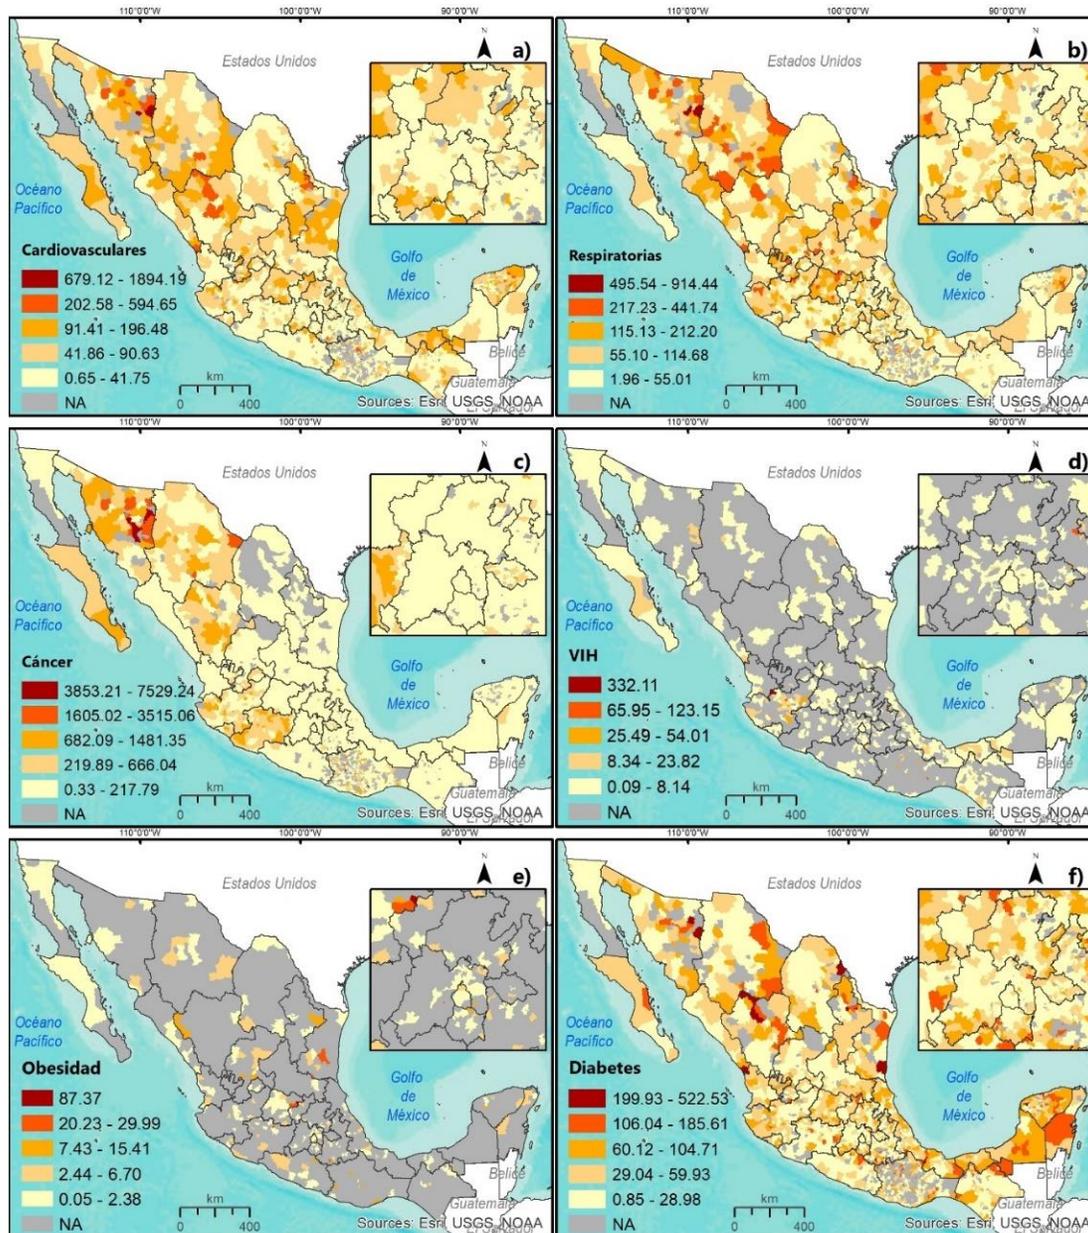
Las tasas de egresos por VIH se distribuyen de manera heterogénea, 4.65% de los municipios (115) se encuentran por encima de la media nacional (7.11). Hostotipaquillo en Jalisco registró la tasa más elevada con 332.11 egresos por cada 100,000 habitantes. En cambio, 16.07% de los municipios (397) obtuvieron los valores más bajos (0.09-8.14).

Monterrey en NL, Cuautitlán Izcalli y Tultitlán en MEX son los lugares con egresos por VIH más bajos con 0.09, 0.18 y 0.19, respectivamente (figura 15d).

Las tasas de egresos por obesidad se distribuyen de manera desigual, 2.38% de los municipios (59) se encuentran por encima de la media nacional que es de 3.67. Santa Catarina en Guanajuato es el lugar con la tasa más elevada con 87.37 egresos por cada 100,000 habitantes. De manera distinta, 5.87% de los municipios (145) obtuvieron los valores más bajos (0.05-2.38), Tijuana en BC, Monterrey en NL y Tlajomulco de Zúñiga en Jalisco obtuvieron los egresos por obesidad más bajos con 0.05, 0.09 y 0.14, correspondientemente (figura 15e).

Las tasas de egresos por diabetes se distribuyen de manera heterogénea, 26.36% de los municipios (651) rebasan la media nacional (41.81). Los valores más altos (199.93-522.53) se observaron en 19 municipios (0.76%), localizados al norte, sur y sureste. Nácori Chico y Villa Hidalgo en Sonora, y Yobaín en Yucatán registraron las tasas más elevadas con 522.53, 349.9 y 361.17, respectivamente. Caso contrario, presentaron 35.92% de los municipios (887) localizados a lo largo del país, debido a que registraron los valores más bajos (0.85-28.98). Juárez, El Carmen y Salinas Victoria en NL son los lugares con egresos por diabetes más bajos con 0.85, 0.96 y 1.15, correspondientemente (figura 15f).

Figura 15. México. Dimensión: Factores epidemiológicos (egresos hospitalarios), 2020



Fuente: Elaboración propia a partir de datos de la SS/DGIS, 2020.

La dimensión factores epidemiológicos (defunciones) incluye las mismas comorbilidades que los egresos hospitalarios, la figura 16a muestra que las tasas de defunciones por enfermedades cardiovasculares se distribuyen de manera desigual, 31.71% de los municipios (783) se encuentran por encima de la media nacional (254.80). Los valores más altos (877.19-1,628.66) se registraron en 22 municipios (0.89%), San Miguel Tulancingo (1,628.66), Santiago Tepetlapa (1,538.46) y Santa María Ixcatlán (1,518.44) en Oaxaca son los lugares con las tasas más elevadas. En cambio, los valores más bajos (9.13-188.62) se registraron en 34.02% de los municipios (840) localizados a lo largo del territorio nacional. Chalchihuitán en Chiapas, Cochoapa el Grande en Guerrero y San Cristóbal Amatlán en Oaxaca son los lugares con las defunciones cardiovasculares más bajas, con 9.13, 14.12 y 18.53, correspondientemente.

Las tasas de defunciones por enfermedades respiratorias se distribuyen de manera heterogénea, 34.26% de los municipios (846) rebasan la media nacional que es de 82.11. Los valores más altos (273.97-536.19) se observaron en 23 municipios (0.93%), localizados en las regiones norte y bajío, y en Oaxaca. San Pedro Topiltepec (536.19), San Nicolás Hidalgo (479.39) y Santa María Yolotepec (415.8) en Oaxaca obtuvieron las tasas más elevadas. Caso contrario, presentaron 30.05% de los municipios (742) localizados a lo largo del país, debido a que registraron los valores más bajos (4.39-56.46). Tlacoachistlahuaca y Cochoapa en Guerrero, además de Pantepec en Puebla son los lugares con las defunciones respiratorias más bajas con 4.39, 4.71 y 5.4, respectivamente (figura 16b).

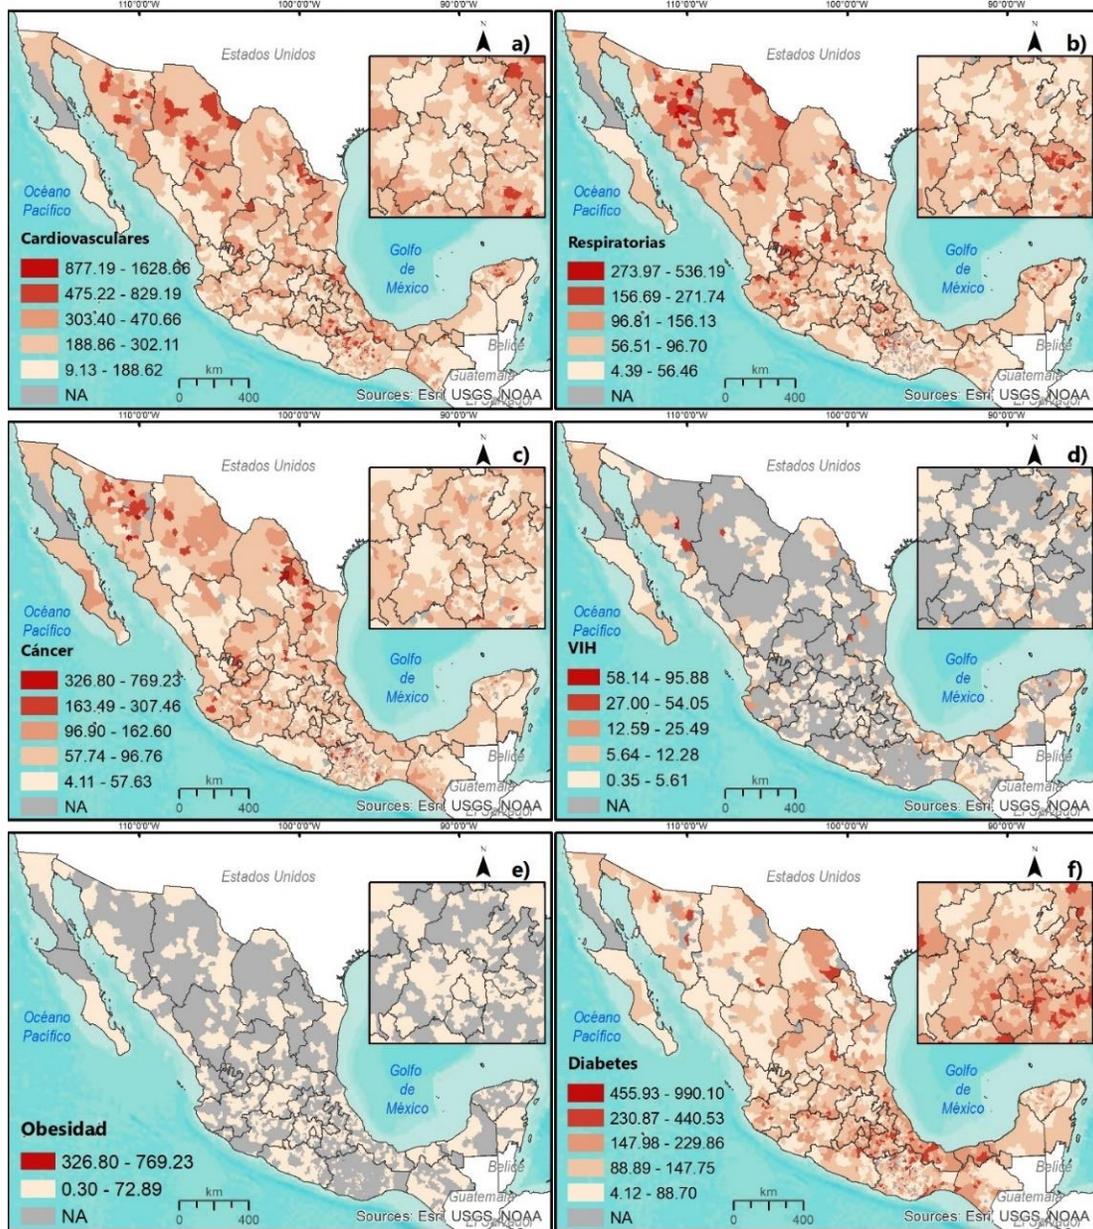
Las tasas de defunciones por cáncer se distribuyen de manera desigual, 35.43% de los municipios (875) se encuentran por encima de la media nacional (77.67). Los valores más altos (326.80-769.23) se registraron en 17 municipios (0.68%) localizados en las regiones norte y bajío, y en Oaxaca. San Tiago Tepetlapa (769.23), Santa Catarina Zapoquila (496.28) y San Vicente Nuñú (445.43) en Oaxaca, son los lugares con las tasas más elevadas. De manera distinta, 31.71% de los municipios (783) obtuvieron los valores más bajos (4.11-57.63), localizados a lo largo del país. Aquiles Serdán en Chihuahua, Alcozauca de Guerrero en Guerrero y Sitalá en Chiapas son los lugares con las defunciones por cáncer más bajas con 4.11, 4.71 y 6.44, respectivamente (figura 16c).

Las tasas de muertes por VIH se distribuyen de manera heterogénea, 9.84% de los municipios (243) rebasan la media nacional que es de 6.60. Villa Pesqueira (95.88) en Sonora, Asunción Cuyotepeji (90.33) y Calihualá (71.33) en Oaxaca registraron las tasas más elevadas. En cambio, 19.31% de los municipios (477) registraron los valores más bajos (0.35-5.61), distribuidos de manera desigual. Guasave en Sinaloa, Fresnillo en Zacatecas y Cuauhtémoc en Chihuahua presentaron las defunciones por VIH más bajas con 0.35, 0.42 y 0.55, correspondientemente (figura 16d).

Las tasas de defunciones por obesidad se distribuyen heterogéneamente, 7.57% de los municipios (187) se encuentran por encima de la media nacional (7.56). Santiago Tepetlapa (769.23) y La Trinidad Vista Hermosa (326.80) en Oaxaca registraron las tasas más elevadas. Por el contrario, Solidaridad en Quintana Roo, Santa Catarina en NL y Puerto Vallarta en Jalisco obtuvieron las de defunciones por obesidad más bajas con 0.30, 0.33 y 0.34, respectivamente (figura 16e).

Las tasas de muertes por diabetes se distribuyen de manera heterogénea, 38.88% de los municipios (960) rebasan la media nacional que es de 129.04. Los valores más altos (455.93-990.10) se observaron en 14 municipios (0.56%), localizados en las regiones centro y Pacífico sur, Magdalena Zahuatlán (990.10), Santo Domingo Tlatayápam (884.96) y San Baltazar Yatzachi el Bajo (741.84) en Oaxaca presentaron las tasas más elevadas. Caso contrario, presentaron 29.08% de los municipios (718) localizados a lo largo del país, debido a que registraron los valores más bajos (4.12-88.70). Mezquital en Durango, Churumuco en Michoacán y El Porvenir en Chiapas son los lugares con las defunciones por diabetes más bajas con 4.12, 8.10 y 8.15, correspondientemente (figura 16f).

Figura 16. México. Dimensión: Factores epidemiológicos (defunciones), 2020



Fuente: Elaboración propia a partir de datos de la SS/DGIS, 2020.

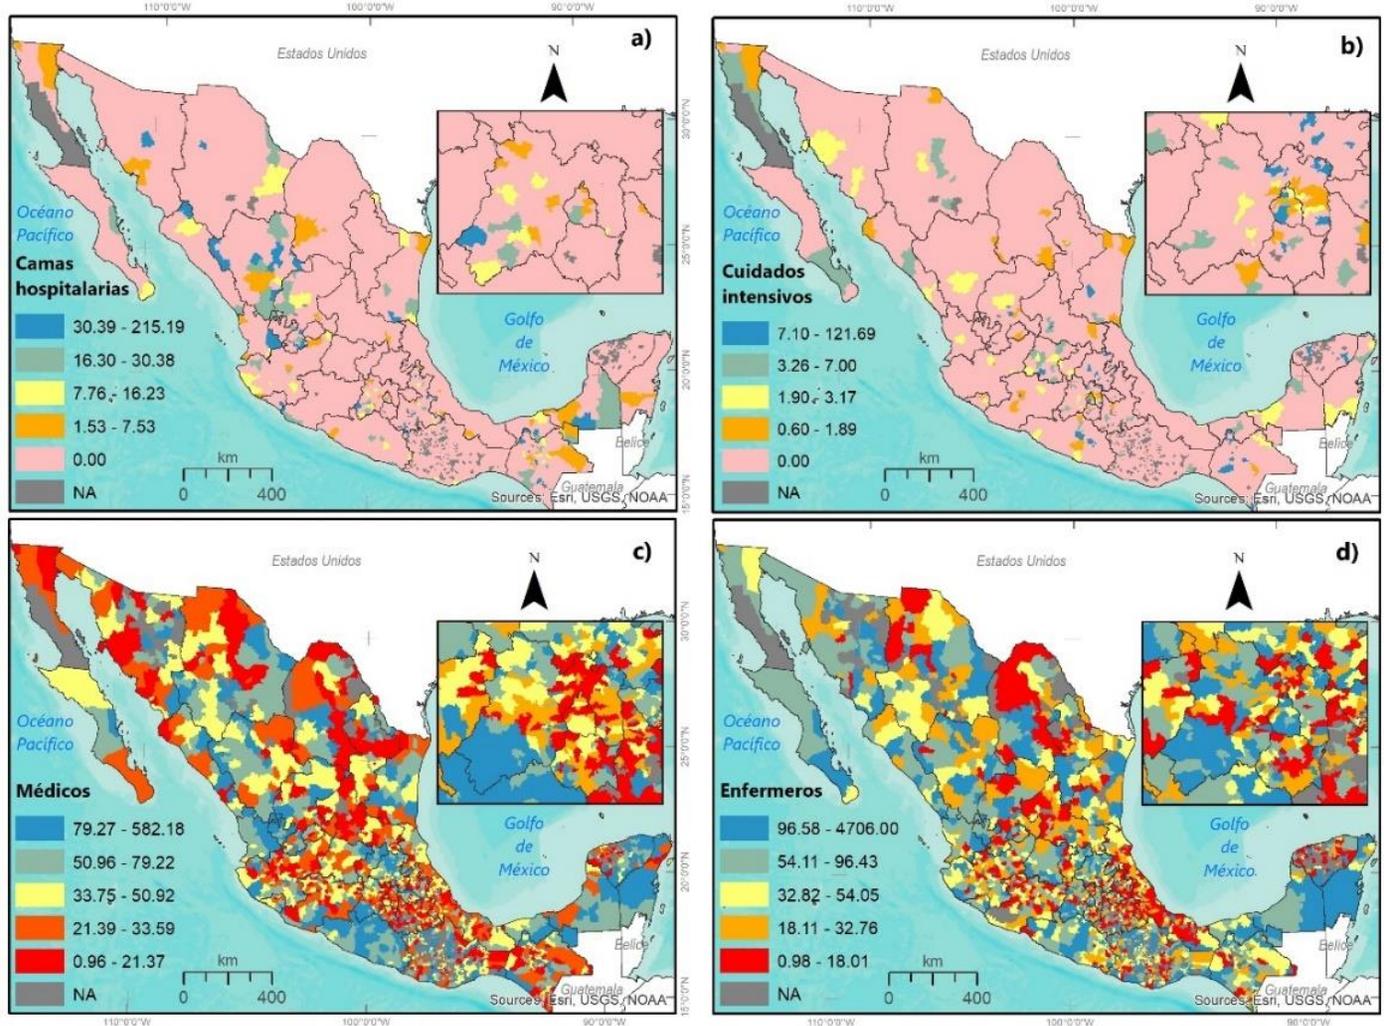
La dimensión factores del sistema de salud incluye cuatro factores de riesgo, la figura 17a muestra que la distribución espacial de las tasas de camas hospitalarias se concentra en un valor de cero, debido a que 2,071 municipios (84.28%) registraron este número de camas; por lo tanto, su tasa resulta con este número. Los valores más altos (30.39-215.19) se observaron en 1.49% de los municipios (37) localizados a lo largo del país, Zacapala en Puebla, Chalcatongo de Hidalgo en Oaxaca y Gómez Farías en Chihuahua son los lugares con las tasas de camas hospitalarias más elevadas, con 215.19, 199.3 y 170.87, respectivamente.

De manera similar, las tasas de camas en unidades de cuidados intensivos (UCI) se concentran en un valor de cero (2,084 municipios), 1.33% de los municipios (33) registraron los valores más altos (7.10-121.69), localizados a lo largo del país, Valladolid en Zacatecas, San Bartolo Coyotepec en Oaxaca y Apetatitlán de Antonio Carvajal en Tlaxcala son los lugares con las tasas de camas en UCI más elevadas, con 121.69, 105.86 y 74.99, correspondientemente (figura 17b).

La distribución espacial de las tasas de médicos resultó heterogénea, 33.45% de los municipios (826) rebasan la media nacional (50.51), 16.60% municipios (410) registraron los valores más altos (79.27-582.18) localizados a lo largo del país, San Jacinto Tlacotepec (582.18) y San Pedro Topiltepec (536.19) en Oaxaca, y Amacueca (504.96) en Jalisco son los lugares con las tasas más elevadas. Por el contrario, 23.61% de los municipios (583) registraron los valores más bajos (0.96-21.37), El Carmen y García en NL, y Miahuatlán de Porfirio Díaz en Oaxaca registraron las tasas de médicos más bajas con 0.96, 1.99 y 2.01 (figura 17c).

Las tasas de enfermeros se distribuyen de manera desigual, 28.75% de los municipios (710) se encuentran por encima de la media nacional que es de 59.42. Los valores más altos (96.58-4,706) se observaron en 389 municipios (15.75%) localizados a lo largo del país. San Bartolo Coyotepec en Oaxaca, Amacueca en Jalisco y Tzompantepec en Tlaxcala son los lugares con las tasas más elevadas con 4,706, 1288.53 y 1149.62, respectivamente. En cambio, 27.05% de los municipios (668) obtuvieron los valores más bajos (0.98-18.01), localizados al norte y sureste, principalmente. General Zuazua y García en NL, y Santa Lucía del Camino en Oaxaca registraron las tasas de enfermeros más bajas con 0.98, 1.76 y 1.99, respectivamente (figura 17d)

Figura 17. México. Dimensión: Factores del sistema de salud, 2020



Fuente: Elaboración propia a partir de datos de la SS/DGIS, 2020.

4.2 Estadísticas descriptivas de factores de riesgo relacionados con COVID-19

Como se observa en el cuadro 3, los indicadores de la dimensión estatus socioeconómico son medidos en porcentaje, la población sin afiliación a servicios de salud registró el valor mínimo más bajo (1.04%), mientras que la población en situación de pobreza resultó con el valor máximo más elevado (99.60%), este último indicador sumó 3 municipios con valores perdidos ($\leq 1,234$). Los datos de los tres indicadores siguieron una distribución asimétrica, debido a que la media y la mediana son distintas en cada caso.

Dos indicadores de la dimensión características de población son medidos en porcentaje, la población minoritaria registró el valor mínimo más bajo (0%) y el valor máximo más alto (100%), este último indicador sumó 172 municipios con valores NA ($\leq 1,234$). Por su parte, la densidad de población mostró una diferencia marcada entre sus valores extremos de 0.11 a 17,519.26 hab/km². Los datos de los tres indicadores mostraron una distribución asimétrica (cuadro 3).

Los indicadores de la dimensión características de vivienda e higiene son medidos en porcentaje, las viviendas sin agua entubada registraron el valor mínimo más bajo (0%), en cambio las viviendas sin tinaco resultaron con el valor máximo más elevado (98.35%). Esta dimensión no registró indicadores con valores NA y la distribución de los datos de los tres indicadores fue asimétrica (cuadro 3).

Los factores epidemiológicos (egresos hospitalarios) son medidos en tasas por 100,000 habitantes, los egresos por obesidad registraron el valor mínimo más bajo (0.05), mientras que los egresos por cáncer resultaron con el valor máximo más elevado (7,529.2). Los seis indicadores que integran esta dimensión registraron valores perdidos; sin embargo, los egresos por VIH y los egresos por obesidad contabilizan la mitad o más municipios ($\geq 1,234$) con valores NA con 1,972 y 2,230, respectivamente. Aunado a que la distribución de los datos resultó asimétrica (cuadro 3).

Los factores epidemiológicos (defunciones) son medidos en tasas por 100,000 habitantes, las defunciones causadas por obesidad registraron el valor mínimo más bajo (0.30), en cambio las defunciones cardiovasculares resultaron con el valor máximo más elevado (1,628.6). De manera similar que los egresos hospitalarios, los seis indicadores registraron valores perdidos, pero las defunciones por VIH y las defunciones por obesidad contabilizan la mitad o más municipios ($\geq 1,234$) con valores NA con 1,691 y 1,695,

correspondientemente. Además, la distribución de los datos también fue asimétrica (cuadro 3).

Los indicadores de la dimensión factores del sistema de salud son medidos en tasas por 100,000 habitantes, las camas hospitalarias y las camas en unidades de cuidados intensivos registraron el valor mínimo más bajo (0), mientras que los enfermeros generales resultaron con el valor máximo más elevado (4,706.0). Los cuatro indicadores que integran esta dimensión registraron 244 valores perdidos ($\leq 1,234$) y la distribución resultó asimétrica (cuadro 3).

Cuadro 3. Estadísticas descriptivas de factores de riesgo relacionados con COVID-19

Dimensión	Indicador (s)	Valor mínimo	Valor máximo	Media	Mediana	Valores perdidos
Estatus socioeconómico	Población en situación de pobreza (%)	5.50	99.60	61.95	62.7	3
	Población de 18+ sin educación posbásica (%)	11.48	97.34	71.99	73.98	0
	Población sin afiliación a servicios de salud (%)	1.04	83.86	24.11	22.63	0
Características de la población	Población de 65 años y más (%)	0.54	31.55	10.47	9.58	0
	Población minoritaria (%)	0.00	100	19.91	4.19	172
	Densidad de población	0.11	17,519.26	308.06	55.22	0
Condiciones de vivienda e higiene	Viviendas particulares habitadas en condición de hacinamiento (%)	5.75	78.90	33.74	32.57	0
	Viviendas particulares habitadas sin agua entubada (%)	0.00	91.85	6.62	3.09	0
	Viviendas particulares habitadas sin tinaco (%)	2.40	98.35	39.44	35.25	0
Factores epidemiológicos	Tasa de egresos cardiovasculares	0.65	1894.1	51.90	35.77	487
	Tasa de egresos respiratorios	1.96	914.44	68.67	52.17	405
	Tasa de egresos cáncer	0.33	7529.2	191.28	59.99	480
	Tasa de egresos VIH	0.09	332.11	7.11	3.24	1,972

Dimensión	Indicador (s)	Valor mínimo	Valor máximo	Media	Mediana	Valores perdidos
	Tasa de egresos de obesidad	0.05	87.37	3.67	1.69	2,230
	Tasa de egresos de diabetes	0.85	522.53	41.81	30.58	608
	Tasa de defunciones cardiovasculares	9.13	1628.6	254.80	225.08	36
	Tasa de defunciones respiratorias	4.39	536.19	82.11	70.70	226
	Tasa de defunciones de cáncer	4.11	769.23	77.67	68.72	200
	Tasa de defunciones VIH	0.35	95.88	6.60	4.59	1,691
	Tasa de defunciones de obesidad	0.30	769.23	7.56	3.68	1,695
	Tasa de defunciones de diabetes	4.12	990.10	129.04	116.16	168
Factores del sistema de salud	Tasa de camas hospitalarias	0.00	215.19	1.746	0	244
	Tasa de camas en unidades de cuidados intensivos	0.00	121.69	0.47	0	244
	Tasa de médicos generales	0.96	582.18	50.51	38.40	244
	Tasa de enfermeros generales	0.98	4706.0	59.42	35.21	244

Fuente: Elaboración propia a partir de datos del CONEVAL (2020); INEGI (2020); SS/DGIS (2020).

Con respecto a la prueba de normalidad Shapiro-Wilk, el p-value ($< 2.2e-16$) de los 25 indicadores resultó inferior al nivel de significancia ($\alpha = 0.05$), lo que indica que se rechaza H_0 y se determina que los datos no siguen una distribución normal al nivel de confianza de 95%, como se visualiza en el gráfico Q-Q (cuantil-cuantil), donde los datos (puntos azules) no se aproximan a la línea recta (anexo 6).

4.3 Correlación de factores de riesgo relacionados con COVID-19

En la dimensión estatus socioeconómico, el indicador población en situación de pobreza (%pbrz) registró una correlación moderada con la población de 18 años y más sin educación posbásica (%p18+se) de 0.65 y con la población minoritaria (%pmin) de 0.54, además tuvo una fuerte correlación con las viviendas particulares habitadas en condición de hacinamiento (%vphhcn) de 0.74. De manera distinta, la población sin afiliación a servicios de salud (%psass) no registró correlaciones significativas (figura 18).

El indicador población de 65 años y más (%p65+) de la dimensión características de la población, registró una correlación moderada negativa con la densidad de población (dnpbl) de -0.52 y positiva con las de defunciones cardiovasculares (tdcrd) de 0.63. A su vez, la población minoritaria (%pmin) se correlacionó con la población en situación de pobreza (%pbrz) con 0.54 (figura 18).

En la dimensión condiciones de vivienda e higiene, el indicador de viviendas particulares habitadas en condición de hacinamiento (%vphhcn) registró una fuerte correlación con la población en situación de pobreza (%pbrz) de 0.74. En cambio, los indicadores de viviendas particulares habitadas sin agua entubada (%vphsa) y viviendas particulares habitadas sin tinaco (%vphst) no registraron correlaciones significativas (figura 18).

En la dimensión factores epidemiológicos (egresos hospitalarios) el indicador de egresos cardiovasculares (tecrd) registró una correlación moderada con los egresos por enfermedades respiratorias (tersp) de 0.52 y con los egresos por diabetes (tedbts) de 0.60. De manera distinta, los egresos por cáncer (tecncr) no registraron correlaciones significativas. En cuanto a las defunciones, el indicador de defunciones cardiovasculares (tdcrd) registró una correlación moderada con la población de 65 años y más (%p65+) de 0.63, mientras que las defunciones por enfermedades respiratorias (tdrsp), cáncer (tdcncr) y diabetes (tddbts) no registraron correlaciones significativas (figura 18).

En la dimensión factores del sistema de salud, el indicador de enfermeros generales (tenfrmrs) registró una correlación moderada con las camas en unidades de cuidados intensivos (tcmsti) de 0.50 y con los médicos generales (tmdcs) de 0.57; por lo tanto, se descartó del Análisis de Componentes Principales, debido a que se correlaciona en más de una ocasión. En cambio, las camas hospitalarias (tcms) no registraron correlaciones significativas (figura 18).

Figura 18. Matriz de correlación de Spearman de factores de riesgo relacionados con COVID-19

	%p18+se	%psass	%p65+	%pmin	%vphsa	%vphst	%pbrz	%vphcn	tdcrd	tdrsp	tdcncr	tddbts	tecrd	tersp	tecncr	tedbts	tcms	tcmsti	tmdcs	tenfrmrs	dnpbl
%p18+se	1.00	-0.23	0.24	0.28	0.24	0.29	0.65	0.42	0.15	-0.06	-0.05	-0.12	0.06	-0.05	0.16	0.07	-0.07	-0.34	0.03	-0.11	-0.45
%psass	-0.23	1.00	-0.19	-0.12	0.02	-0.20	-0.11	-0.05	-0.13	-0.07	-0.03	0.19	-0.23	-0.15	0.07	-0.19	0.02	0.06	-0.10	-0.09	0.35
%p65+	0.24	-0.19	1.00	-0.05	-0.05	-0.03	-0.05	-0.42	0.63	0.32	0.49	0.19	0.38	0.21	0.27	0.33	-0.10	-0.13	0.13	0.04	-0.52
%pmin	0.28	-0.12	-0.05	1.00	0.26	0.33	0.54	0.48	-0.08	-0.23	-0.23	-0.11	-0.17	-0.24	-0.14	-0.02	-0.01	-0.03	0.03	0.03	0.03
%vphsa	0.24	0.02	-0.05	0.26	1.00	0.27	0.39	0.43	-0.11	-0.29	-0.19	-0.08	-0.12	-0.19	-0.21	0.00	0.03	-0.11	0.10	0.05	-0.02
%vphst	0.29	-0.20	-0.03	0.33	0.27	1.00	0.34	0.36	-0.01	-0.20	-0.08	-0.09	-0.05	-0.17	-0.17	0.03	-0.02	-0.13	-0.11	-0.07	-0.18
%pbrz	0.65	-0.11	-0.05	0.54	0.39	0.34	1.00	0.74	-0.02	-0.19	-0.26	0.01	-0.15	-0.16	-0.09	0.02	-0.03	-0.23	0.06	-0.05	-0.02
%vphcn	0.42	-0.05	-0.42	0.48	0.43	0.36	0.74	1.00	-0.29	-0.32	-0.42	-0.12	-0.22	-0.23	-0.20	-0.05	0.04	-0.19	0.05	-0.04	0.09
tdcrd	0.15	-0.13	0.63	-0.08	-0.11	-0.01	-0.02	-0.29	1.00	0.30	0.39	0.30	0.31	0.21	0.21	0.31	-0.04	-0.09	0.02	-0.05	-0.32
tdrsp	-0.06	-0.07	0.32	-0.23	-0.29	-0.20	-0.19	-0.32	0.30	1.00	0.32	0.20	0.22	0.31	0.18	0.11	-0.03	0.02	-0.03	-0.01	-0.15
tdcncr	-0.05	-0.03	0.49	-0.23	-0.19	-0.08	-0.26	-0.42	0.39	0.32	1.00	0.22	0.30	0.19	0.21	0.19	-0.06	0.03	0.02	0.05	-0.23
tddbts	-0.12	0.19	0.19	-0.11	-0.08	-0.09	0.01	-0.12	0.30	0.20	0.22	1.00	0.04	0.11	0.04	0.17	-0.03	-0.02	0.00	-0.04	0.14
tecrd	0.06	-0.23	0.38	-0.17	-0.12	-0.05	-0.15	-0.22	0.31	0.22	0.30	0.04	1.00	0.52	0.23	0.60	0.03	-0.01	0.25	0.22	-0.40
tersp	-0.05	-0.15	0.21	-0.24	-0.19	-0.17	-0.16	-0.23	0.21	0.31	0.19	0.11	0.52	1.00	0.21	0.43	0.05	0.07	0.21	0.21	-0.18
tecncr	0.16	0.07	0.27	-0.14	-0.21	-0.17	-0.09	-0.20	0.21	0.18	0.21	0.04	0.23	0.21	1.00	0.16	-0.02	-0.08	0.03	-0.04	-0.26
tedbts	0.07	-0.19	0.33	-0.02	0.00	0.03	0.02	-0.05	0.31	0.11	0.19	0.17	0.60	0.43	0.16	1.00	0.05	-0.06	0.31	0.22	-0.31
tcms	-0.07	0.02	-0.10	-0.01	0.03	-0.02	-0.03	0.04	-0.04	-0.03	-0.06	-0.03	0.03	0.05	-0.02	0.05	1.00	0.07	0.16	0.19	0.00
tcmsti	-0.34	0.06	-0.13	-0.03	-0.11	-0.13	-0.23	-0.19	-0.09	0.02	0.03	-0.02	-0.01	0.07	-0.08	-0.06	0.07	1.00	0.00	0.50	0.28
tmdcs	0.03	-0.10	0.13	0.03	0.10	-0.11	0.06	0.05	0.02	-0.03	0.02	0.00	0.25	0.21	0.03	0.31	0.16	0.00	1.00	0.57	-0.14
tenfrmrs	-0.11	-0.09	0.04	0.03	0.05	-0.07	-0.05	-0.04	-0.05	-0.01	0.05	-0.04	0.22	0.21	-0.04	0.22	0.19	0.50	0.57	1.00	-0.04
dnpbl	-0.45	0.35	-0.52	0.03	-0.02	-0.18	-0.02	0.09	-0.32	-0.15	-0.23	0.14	-0.40	-0.18	-0.26	-0.31	0.00	0.28	-0.14	-0.04	1.00

Fuente: Elaboración propia a partir de datos del CONEVAL (2020); INEGI (2020); SS/DGIS, 2020.

4.4 Conclusiones del contexto espacial y estadístico de factores de riesgo relacionados con COVID-19

La distribución espacial de factores de riesgo relacionados con COVID-19 resultó heterogénea en gran parte del país y reflejó las desigualdades estructurales y de salud de la población. En particular, las regiones Pacífico sur y península de Yucatán presentaron condiciones socioeconómicas desfavorables, viviendas hacinadas (porcentajes altos) y agrupación de grupos minoritarios en comparación con la parte centro, norte y oeste. Además, se observó que la población está concentrada en el centro del país y la distribución de adultos mayores es baja en todas las entidades, a excepción de algunos municipios de Oaxaca, Sonora y Chihuahua.

Los factores epidemiológicos (egresos y defunciones) representaron a la población de alto riesgo a resultados graves de COVID-19 por tener o morir a causa de enfermedades subyacentes. En este sentido, la distribución espacial de ambas condiciones de salud fue heterogénea, con algunas agrupaciones de tasas altas en las regiones norte, suroeste y península de Yucatán. Por otra parte, se observaron deficiencias en la infraestructura del sistema de salud, debido a que la distribución espacial de camas hospitalarias y en cuidados intensivos resultó con más del 80% de municipios con esta carencia (84.28% y 84.81%, respectivamente). Mientras que la distribución espacial del recurso humano (médicos y enfermeros) resultó heterogénea, sin embargo, las regiones norte y Pacífico sur, además de Veracruz y Yucatán registraron tasas bajas de ambos profesionales de la salud.

En otro orden de ideas, las técnicas estadísticas empleadas (descriptivas y correlación) permitieron identificar ocho indicadores que no aportaban suficiente información, debido a la falta excesiva de datos y redundancia de información. En particular, la tasa de egresos hospitalarios y defunciones relacionadas con VIH, así como la tasa de egresos y muertes por obesidad registraron $\geq 1,234$ valores perdidos; mientras que población en situación de pobreza, población de 65 años y más, egresos cardiovasculares y enfermeros generales presentaron coeficientes de correlación en los umbrales muy fuerte ($> 0,7$) y moderada ($0,7 \leq, < 0,5$), además de que se correlacionaron en dos o más ocasiones, por estas razones, fueron excluidos del Análisis de Componentes Principales.

Capítulo 5. Índice espacial dinámico de vulnerabilidad ante COVID-19 en México.

El siguiente capítulo revela los resultados del ÍEDVC19 mediante cuatro apartados: en primer lugar, se muestra un mapa de vulnerabilidad ante COVID-19 durante 2020-2022; posteriormente, se exponen cinco mapas de distribución del ÍEDVC19 definidos por la duración de cada ola epidémica; los siguientes apartados presentan los resultados del análisis de sensibilidad y se plantea la discusión de los hallazgos.

5.1 Índice espacial dinámico de vulnerabilidad ante COVID-19 (2020-2022)

Utilizando la base de datos que integró 18 indicadores (anexo 3), se ejecutó el ACP para obtener los coeficientes de los indicadores del primer componente principal que obtuvo la varianza más elevada (anexo 7) y aplicar la fórmula general del ÍEDVC19.

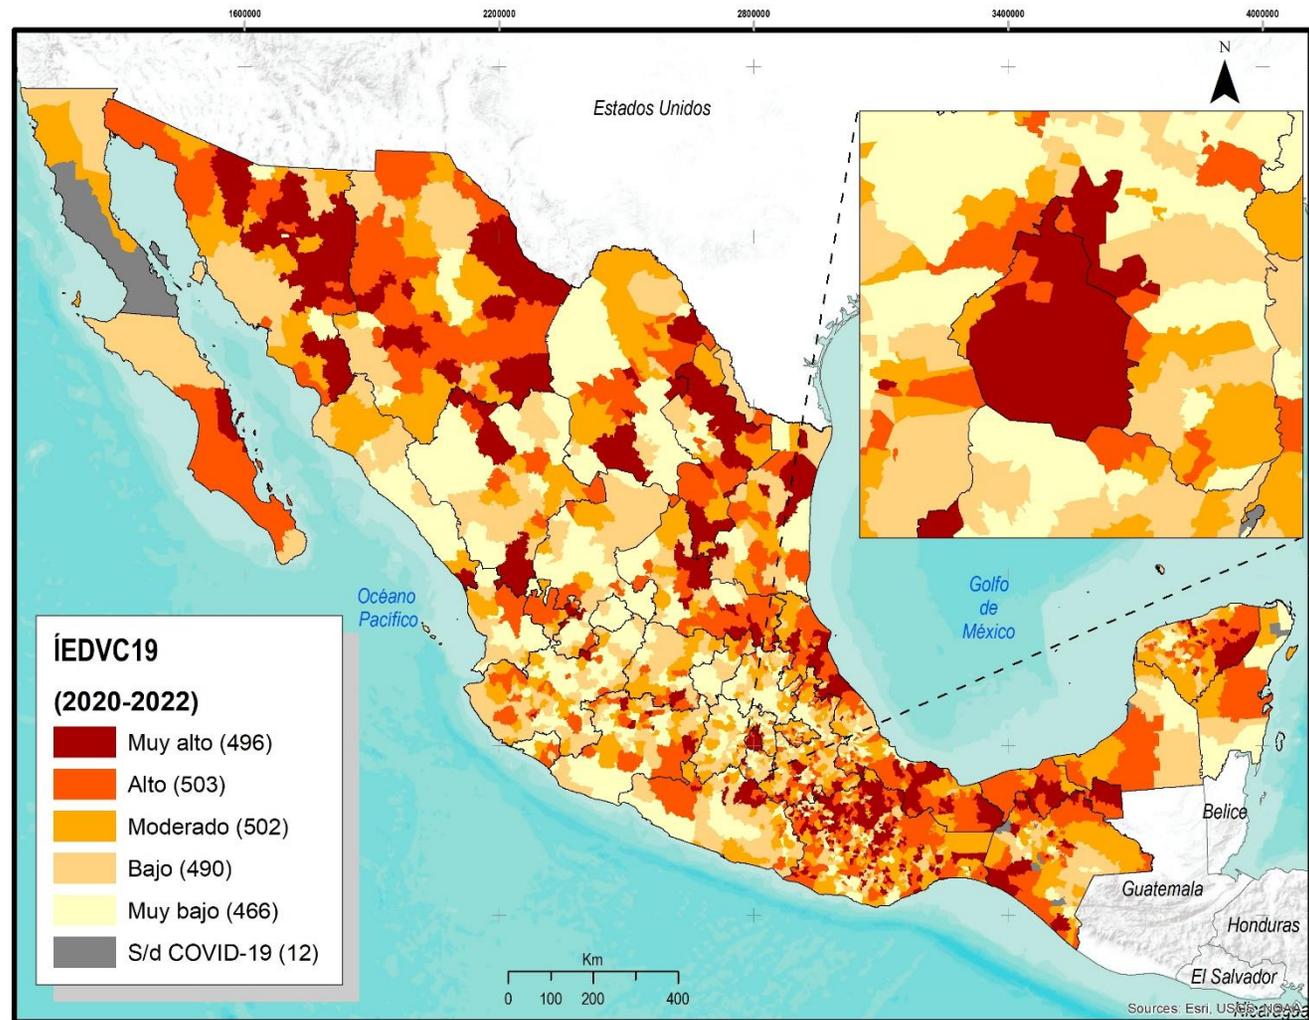
La figura 19 y el cuadro 4, muestran el mapa clasificado en cinco categorías de vulnerabilidad y las cifras del ÍEDVC19. Se observa que el 20.18% de los municipios (496) se encuentran en la categoría 'muy alta', localizados en las regiones norte y este, así como en Oaxaca, CDMX y Yucatán. Santiago Tepetlapa, Santa María Ixcatlán, San Juan Teita y San Pedro Mixtepec en Oaxaca, y Nácori Chico en Sonora son los lugares más vulnerables con valores de 1, 0.6730, 0.6391, 0.5740 y 0.6520, respectivamente.

El 20.47% de los municipios (503) se incluyeron en la categoría 'alta', ubicados de manera similar que los clasificados en 'muy alta' y en algunos casos son contiguos, es decir, comparten vecindad espacial. Los valores más altos los registraron Cusihuiriachi en Chihuahua (0.1759), Contla de Juan Cuamatzi en Tlaxcala (0.1757), San Pablo Cuatro Venados en Oaxaca (0.1757), Moroleón en Guanajuato (0.1756) y Chucándiro en Michoacán (0.1755) (figura 19 y cuadro 4).

La categoría 'moderada' incluyó 20.43% de los municipios (502), localizados en la mayoría de las entidades, pero con mayor concentración al centro y oeste. Ixhuatlán de Madero en Veracruz, Allende en NL, Santa Catarina Tayata en Oaxaca, Halachó en Yucatán y Bácum en Sonora son los lugares con el valor más alto con 0.1413, individualmente. En cuanto a la categoría 'baja', 18.96% de los municipios (490) la integraron, ubicados en las regiones centro (excepto CDMX) y oeste, así como en Guerrero. Villa Juárez en SLP, Tepalcingo y Jonacatepec de Leandro Valle en Morelos, San Antonio el Alto en Oaxaca y Tecalitlán en Jalisco resultaron con los valores más altos con 0.1184 (los dos primeros), 0.1183 y 0.1182 el resto (figura 19 y cuadro 4).

El 18.96% de los municipios (466) se incluyeron en la categoría 'muy baja', localizados de manera similar que los clasificados en 'baja' y en algunos casos son contiguos. Aquiles Serdán en Chihuahua, Ramos Arizpe en Coahuila, Jesús María en Aguascalientes, Corregidora en Querétaro y Guadalupe en Zacatecas son los lugares menos vulnerables durante tres años de la pandemia por registrar valores de 0, 0.0148, 0.0157, 0.0165 y 0.020, correspondientemente (figura 19 y cuadro 4).

Figura 19. México. Índice espacial dinámico de vulnerabilidad ante COVID-19 (2020-2022)



Fuente: Elaboración propia a partir de datos del INEGI (2020); SS/DGIS (2020); SS/DGE (2020-2022).

Cuadro 4. Cifras del ÍEDVC19

Vulnerabilidad	Tres años	Ola 1	Ola 2	Ola 3	Ola 4	Ola 5
Muy alto	496 (20.18%)	496 (20.18%)	439 (17.86%)	521 (21.20%)	494 (20.10%)	501 (20.39%)
Alto	503 (20.47%)	497 (20.22%)	450 (18.31%)	506 (20.59%)	495 (20.14%)	494 (20.10%)
Moderado	502 (20.43%)	490 (19.94%)	466 (18.96%)	500 (20.35%)	501 (20.39%)	488 (19.86%)
Bajo	490 (19.94%)	485 (19.73%)	527 (21.44%)	494 (20.10%)	486 (19.78%)	474 (19.29%)
Muy bajo	466 (18.96%)	489 (19.90%)	575 (23.40%)	436 (17.74%)	481 (19.57%)	500 (20.35%)
Total	2,457 (100%)	2,457 (100%)	2,457 (100%)	2,457 (100%)	2,457 (100%)	2,457 (100%)

Fuente: Elaboración propia a partir de datos del INEGI (2020); SS/DGIS (2020); SS/DGE (2020-2022).

5.2 Índice espacial dinámico de vulnerabilidad ante COVID-19 (por ola epidémica)

Los coeficientes obtenidos en el ACP se utilizaron para generar cinco mapas del ÍEDVC19 determinados por la duración de cada ola epidémica (apartado 2.3.5). La figura 20a y el cuadro 4 muestran el mapa y las cifras del ÍEDVC19 durante la primera ola (febrero-septiembre 2020), se observa que el 20.18% de los municipios (496) se encuentran en la categoría 'muy alta', localizados en las regiones norte y este, así como en Oaxaca y Yucatán. Santiago Tepetlapa, Santa María Ixcatlán, San Juan Teita y San Pedro Mixtepec en Oaxaca, y Nácóric Chico en Sonora registraron los valores más elevados con 1, 0.6692, 0.6384, 0.5723 y 0.6544, respectivamente.

La categoría 'alta' incluyó 20.22% de los municipios (497), ubicados de manera similar que los clasificados en 'muy alta' y en algunos casos son contiguos, por ejemplo, las alcaldías Álvaro Obregón, Benito Juárez y Miguel Hidalgo (al noroeste de la CDMX) comparten vecindad con Azcapotzalco, Coyoacán, Cuauhtémoc, Iztapalapa e Iztacalco. Los valores más altos los registraron Tacotalpa en Tabasco (0.1759), Ixtapangajoyá en Chiapas (0.1756), Zozocolco de Hidalgo en Veracruz (0.1754), Ayotzintepec en Oaxaca (0.1454) y Juárez en Coahuila con 0.1753 (figura 20a y cuadro 4).

El 19.94% de los municipios (490) se incluyeron en la categoría 'moderada', localizados a lo largo del país, las puntuaciones más altas se registraron en Citlaltépetl en Veracruz (0.1414), Santa Cruz Quilehtla en Tlaxcala (0.1414), San Martín Hidalgo en Jalisco (0.1413), Las Rosas en Chiapas (0.1412) y Acayucan en Veracruz (0.1412). En cuanto a la categoría 'baja', 19.73% de los municipios (485) la integraron, localizados en las regiones

centro (excepto CDMX), oeste y suroeste (Chiapas, Guerrero y Michoacán), principalmente. Tamazulápam del Espíritu Santo y Mazatlán Villa de Flores en Oaxaca, Matehuala en SLP, Totolac en Tlaxcala y Tzitzio en Michoacán resultaron con los valores más elevados con 0.1184 los dos primeros y 0.1183 el resto (figura 20a y cuadro 4).

En la categoría 'muy baja' se incluyeron 19.90% de los municipios (489), localizados de manera similar que los clasificados en 'baja'. Además, hubo similitud con los municipios menos vulnerables del ÍEDVC19 (2020-2022), Corregidora en Querétaro, Ramos Arizpe en Coahuila, Aquiles Serdán en Chihuahua, Jesús María en Aguascalientes y Guadalupe en Zacatecas resultaron con los valores más bajos en la primera ola con 0, 0.0033, 0.0076, 0.0154 y 0.0197, respectivamente (figura 20a y cuadro 4).

La figura 20b y el cuadro 4, muestran el mapa y las cifras del ÍEDVC19 durante la segunda ola (octubre 2020-mayo 2021), la categoría 'muy alta' presentó una reducción de municipios de 2.32% en comparación con la ola 1. No obstante, la disminución no fue homogénea, en particular, las alcaldías Álvaro Obregón, Benito Juárez, La Magdalena Contreras, Tláhuac, Tlalpan y Xochimilco en CDMX pasaron de la categoría 'alta' y 'moderada' en la primera ola a 'muy alta' vulnerabilidad en la segunda. Además, Santiago Tepetlapa, Santa María Ixcatlán, San Juan Teita en Oaxaca, y Nácori Chico en Sonora registraron los valores más elevados con 1, 0.6558, 0.6253 y 0.7205, correspondientemente.

De manera similar que los clasificados en 'muy alta', la categoría 'alta' presentó una disminución de municipios de 1.91% en comparación con la primera ola, localizados en las regiones noroeste, este y península de Yucatán. Los valores más altos los registraron Coxcatlán en SLP (0.1759), Juárez en Coahuila (0.1758), San Miguel Tlacamama y San Sebastián en Oaxaca (0.1758) y Huehuetán en Chiapas (0.1756) (figura 20b y cuadro 4).

La categoría 'moderada' registró una reducción de municipios menor al punto porcentual (0.98%) en comparación con la ola 1. Chapab en Yucatán, Reforma y Salto de Agua en Chiapas, Acultzingo en Veracruz y Otumba en MEX resultaron con los valores más altos con 0.1413 (los tres primeros) y 0.1412, 0.1411 el resto. De manera distinta, en la categoría 'baja' se registró el mayor porcentaje de municipios (21.44%) en comparación con los valores de las cinco oleadas con 1.71% (ola 1), 1.34% (ola3), 1.66% (ola 4) y 2.15% (ola 5) más que cada ola, respectivamente. Degollado en Jalisco, Santiago Laollaga y La

Compañía en Oaxaca, Tlacotepec de Benito Juárez en Puebla y Rioverde en SLP registraron los valores más altos con 0.1184 (los cuatro primeros) y 0.1182 el último (figura 20b y cuadro 4).

De manera similar que los clasificados en 'baja', en la categoría 'muy baja' se registró el mayor porcentaje de municipios (23.40%) en comparación con los valores de las cinco oleadas con 3.5% (ola 1), 5.66% (ola 3), 3.83% (ola 4) y 3.05% (ola 5) más que cada ola, correspondientemente. Los lugares se concentran al centro (excepto CDMX), oeste, suroeste (Guerrero y Michoacán) y península de Yucatán. De manera similar que la primera ola, Aquiles Serdán en Chihuahua, Ramos Arizpe en Coahuila y Jesús María en Aguascalientes resultaron con los valores más bajos con 0, 0.0067 y 0.0149, respectivamente (figura 20b y cuadro 4).

La figura 20c y el cuadro 4, muestran el mapa y las cifras del ÍEDVC19 durante la tercera ola (junio-noviembre 2021), la categoría 'muy alta' registró el mayor porcentaje de municipios (21.20%) en comparación con los valores de las cinco oleadas con 1.01% (ola 1), 3.34% (ola2), 1.1% (ola 4) y 0.81% (ola 5) más que cada ola, respectivamente. No obstante, el aumento no fue homogéneo, por ejemplo, las alcaldías Benito Juárez, Coyoacán, Tláhuac, Tlalpan y Xochimilco (en CDMX) pasaron de la categoría 'muy alta' en la segunda ola a 'alta' vulnerabilidad en la tercera.

De manera similar que los clasificados en 'muy alta', la categoría 'alta' registró el mayor porcentaje de municipios (20.59%) en comparación con los valores de las cinco oleadas con 0.37% (ola 1), 2.28% (ola 2), 0.45% (ola 4) y 0.49% (ola 5) más que cada ola, correspondientemente, se localizaron en las regiones norte, este y península de Yucatán, así como en la CDMX. Empalme en Sonora, Santiago Ixcuintepec, Sitio de Xitlapehua y San Miguel Santa Flor en Oaxaca, y Chenalhó en Chiapas registraron los valores más elevados con 0.1758 (los tres primeros) y 0.1757 el resto (figura 20c y el cuadro 4).

La categoría 'moderada' registró un aumento de municipios (1.39%) en comparación con la ola 2, localizados a lo largo del país, pero con mayor concentración al centro, oeste y suroeste (Chiapas, Guerrero y Michoacán). Los valores más altos los registraron Santa Catarina Tayata (0.1414) y Matías Romero Avendaño (0.1413) en Oaxaca, Atlautla (0.1414) en MEX, Tampico (0.1414) en Tamaulipas y Tierra Nueva (0.1413) en SLP. De manera distinta, la categoría 'baja' registró una reducción de municipios (1.34%) en

comparación con la segunda ola. Los valores más altos los registraron San Diego de Alejandría en Jalisco, Singuilucan en Hidalgo, Cerritos en SLP, Vega de Alatorre e Ixhuatlancillo en Veracruz con 0.1184, individualmente (figura 20c y el cuadro 4).

De manera similar que los clasificados en 'baja', la categoría 'muy baja' registró una disminución de municipios (5.66%) en comparación con la ola 2, se observaron concentraciones similares a los clasificados en 'baja' y en algunos casos son contiguos, localizados en las regiones centro (excepto CDMX), oeste y suroeste (Guerrero y Michoacán). De la misma manera, que las olas anteriores Aquiles Serdán en Chihuahua, Guadalupe en Zacatecas, Corregidora en Querétaro, Jesús María en Aguascalientes y Ramos Arizpe en Coahuila resultaron los lugares menos vulnerables con 0, 0.0086, 0.0095, 0.0153 y 0.0157, correspondientemente (figura 20c y el cuadro 4).

La figura 20d y el cuadro 4, muestran el mapa y las cifras del ÍEDVC19 durante la cuarta ola (diciembre 2021-abril 2022), la categoría 'muy alta' registró una reducción de 1.1% de municipios en comparación con la ola 3. Sin embargo, la disminución no fue homogénea, en particular, las alcaldías Coyoacán y Xochimilco (en CDMX) pasaron de la categoría 'alta' en la tercera ola a 'muy alta' vulnerabilidad en la cuarta. Santiago Tepetlapa, Santa María Ixcatlán, San Juan Teita y San Pedro Mixtepec en Oaxaca, y Nácori Chico en Sonora registraron los valores más elevados con 1, 0.6701, 0.6393, 0.5695 y 0.6489, respectivamente.

La categoría 'alta' registró una disminución de municipios menor al punto porcentual (0.45%) en comparación con la tercera ola, localizados en las regiones noroeste, este, península de Yucatán, así como en la CDMX. Los valores más altos los registraron Cusihuirachi en Chihuahua (0.1759), San Marcos Arteaga y Candelaria Loxicha en Oaxaca (0.1759 y 0.1756), Solosuchiapa en Chiapas (0.1757) y Santa Isabel Xiloxotla en Tlaxcala con 0.1757 (figura 20d y cuadro 4).

La categoría 'moderada' aumento 0.04% de los municipios en comparación con la ola 3, se localizan en gran parte del país con concentraciones al norte y centro. Los valores más elevados los registraron Anáhuac (0.1414) en NL, Yuriria (0.1413) en Guanajuato, Tzintzuntzan (0.1413) en Michoacán, San Pedro Huamelula (0.1413) en Oaxaca y Calpan (0.1412) en Puebla. De manera distinta, la categoría 'baja' registró una disminución de municipios menor al punto porcentual (0.32%). Susupuato en Michoacán, Coatlán del Río

en Morelos, San Antonino el Alto en Oaxaca, Atzalan en Veracruz y Tenancingo en MEX registraron los valores más altos con 0.1184, individualmente (figura 20d y cuadro 4).

La categoría 'muy baja' registró un aumento de 1.83% de los municipios en comparación a la ola 3, localizados en las regiones centro (excepto CDMX), oeste y suroeste (Guerrero y Michoacán). De igual manera, que las olas anteriores Aquiles Serdán en Chihuahua, Corregidora en Querétaro, Ramos Arizpe en Coahuila, Jesús María y San Francisco de los Romo en Aguascalientes resultaron los lugares menos vulnerables con 0, 0.0114, 0.0144, 0.0176 y 0.0212, correspondientemente (figura 20d y cuadro 4).

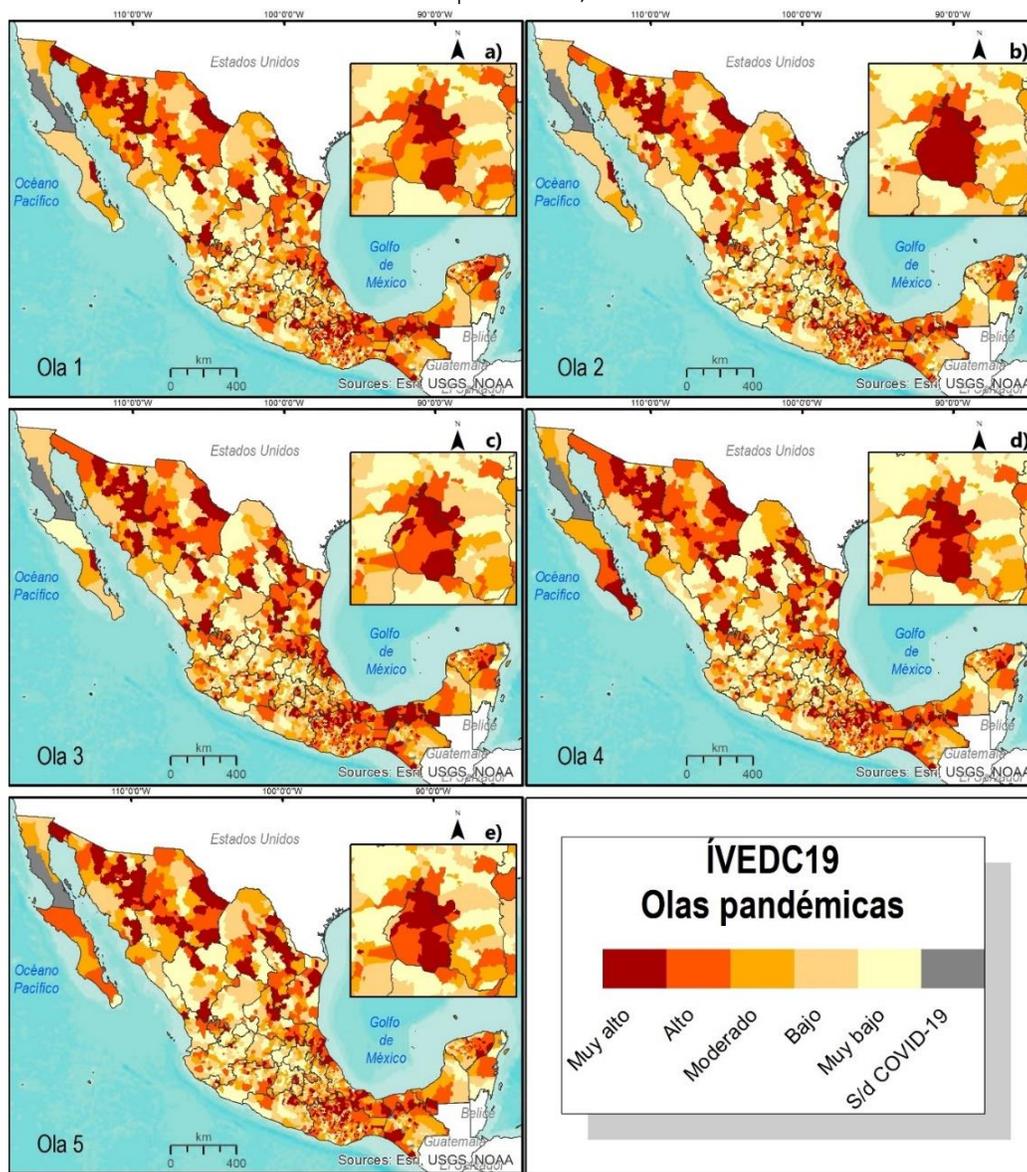
La figura 20e y el cuadro 4, muestran el mapa y las cifras del ÍEDVC19 durante la última ola (mayo-octubre 2022), se observa que la categoría 'muy alta' presentó un aumento de 0.29% de los municipios en comparación con la ola 4, localizados en las regiones norte y este, así como en Oaxaca y CDMX. Santiago Tepetlapa, Santa María Ixcatlán, San Juan Teita y San Pedro Mixtepec en Oaxaca, y Nácori Chico en Sonora registraron los valores más elevados con 1, 0.6702, 0.6395, 0.5760 y 0.6409, respectivamente.

En cambio, la categoría 'alta' registró una disminución de municipios menor al punto porcentual (0.04%) en comparación con la ola 4, se localizan de manera similar a los 'muy altos' y en algunos casos son contiguos, los valores más elevados los registraron Nativitas (0.1757) en Tlaxcala, San Francisco Jaltepetongo (0.1756) y Candelaria Loxicha (0.1756) en Oaxaca, así como Armadillo de los Infante (0.1756) en SLP y Chucándiro (0.1755) en Michoacán (figura 20e y cuadro 4).

Las categorías 'moderada' y 'baja' resultaron con disminuciones de municipios menores al punto porcentual (0.53% y 0.49%), ambas se concentran en las regiones centro (excepto CDMX), oeste y suroeste (Chiapas, Guerrero y Michoacán), además algunos son contiguos. Los valores más altos de la categoría 'moderada' los registraron Bolaños en Jalisco (0.1413), Tepatlaxco de Hidalgo (0.1413) y Jopala en Puebla (0.1411), Pacula en Hidalgo (0.1409) y Ocuituco en Morelos (0.1408). Mientras que en la categoría 'baja' los más elevados fueron Santiago Amoltepec en Oaxaca, Chapantongo en Hidalgo, Peto en Yucatán, Tianguismanalco en Puebla y Simojovel en Chiapas con 0.1184 (los cuatro primeros) y 0.1183, correspondientemente (figura 20e y cuadro 4).

La categoría 'muy baja' también registró una reducción menor al punto porcentual (0.78%) en comparación con la ola 4, se observaron concentraciones similares a los clasificados en 'baja' y en algunos casos son contiguos. De la misma manera, que las olas anteriores Aquiles Serdán en Chihuahua, Corregidora en Querétaro, Jesús María y San Francisco de los Romo en Aguascalientes y Ramos Arizpe en Coahuila resultaron los lugares menos vulnerables con 0, 0.0098, 0.0117, 0.0195 y 0.0195, correspondientemente (figura 20e y cuadro 4).

Figura 20. México. Índice espacial dinámico de vulnerabilidad ante COVID-19 (por ola epidémica)



Fuente: Elaboración propia a partir de datos del INEGI (2020); SS/DGIS (2020); SS/DGE (2020-2022).

5.3 Evaluación de la robustez del ÍEDVC19

Al comparar los valores del ÍEDVC19 y los 18 índices modificados a partir del % de incremento (apartado 2.3.6), se encontró que seis (33.33%) registraron variación significativa ($\geq 15\%$) en al menos uno de los municipios, mientras que 12 índices (66.67%) no representaron cambios. Excluyendo estos últimos, el índice modificado por el indicador población de 18 años y más sin educación posbásica registró el menor número de municipios (1) con variación significativa ($\geq 15\%$), en cambio el índice modificado por el indicador tasa de médicos generales registró el mayor número de municipios, con un total de 356 (14.49% del total). Las cifras del análisis de sensibilidad se muestran en el siguiente cuadro.

Cuadro 5. Cifras del análisis de sensibilidad del ÍEDVC19

Indicador con incremento del 1%	Municipios con variación	% de municipios con variación
Tasa de la mediana anual COVID-19	0	0.00
% población de 18+ sin educación posbásica	1	0.04
% población sin afiliación a servicios de salud	0	0.00
% población minoritaria	70	2.85
% viviendas sin agua entubada	0	0.00
% viviendas sin tinaco	0	0.00
% viviendas en condición de hacinamiento	0	0.00
Tasa de egresos respiratorios	0	0.00
Tasa de egresos cáncer	6	0.24
Tasa de egresos diabetes	0	0.00
Tasa de defunciones cardiovasculares	0	0.00
Tasa de defunciones respiratorias	0	0.00
Tasa de defunciones cáncer	0	0.00
Tasa de defunciones diabetes	0	0.00
Densidad de población	0	0.00
Tasa de camas hospitalarias	120	4.88
Tasa de camas en UCI	81	3.30
Tasa de médicos generales	356	14.49

Nota: el umbral de variación es $\geq 15\%$

Fuente: Elaboración propia a partir de datos del INEGI (2020); SS/DGIS (2020); SS/DGE (2020-2022).

5.4 Discusión de los hallazgos del ÍEDVC19

Dado que la pandemia de COVID-19 evolucionó continuamente en México, es necesario contar con una herramienta que muestre la vulnerabilidad a los resultados negativos de esta enfermedad de una manera precisa y en el tiempo. En este contexto, el ÍEDVC19 permitió localizar población vulnerable durante 2020-2022, además se sumó a los índices que muestran la vulnerabilidad variable en el tiempo (NIEHS, 2021; Gorris et al., 2021; Sierra-Alcocer et al., 2022) a partir de la duración de cada ola epidémica.

Los resultados del ÍEDVC19 durante 2020-2022, identificaron 40.65% de los municipios con vulnerabilidad alta y muy alta, localizados en las regiones norte, este, península de Yucatán, así como en Oaxaca y CDMX (figura 19), particularmente estos lugares a excepción de la parte este y Oaxaca registraron tasas altas de casos confirmados (figura 8a). No obstante, la capital nacional fue el epicentro de la pandemia, a pesar de ser una de las entidades que presenta mejores condiciones socioeconómicas, de vivienda e higiene y del sistema de salud, así como tasas bajas de egresos y defunciones de enfermedades subyacentes (apartado 4.1). Un factor que podría explicar las tasas altas y, en consecuencia, mayor vulnerabilidad en la CDMX es la densidad de población, debido a que es la entidad con más habitantes por kilómetro cuadrado del país (figura 13c). Este resultado está en línea con NIEHS (2021); Dutta et al. (2021); Sánchez et al. (2022), quienes señalan que la densidad de población aumenta la tasa de transmisión de enfermedades infecciosas, además de que existe menos distanciamiento social y la propagación de COVID-19 es mayor.

En cambio 38.9% de los municipios presentaron vulnerabilidad baja y muy baja, localizados en las regiones centro (excepto CDMX), oeste y suroeste (Guerrero y Michoacán) (figura 19), caso particular, presentan 58% y 49% de los municipios (47 y 55, respectivamente) de Guerrero y Michoacán, entidades caracterizadas por tener menores condiciones socioeconómicas, de vivienda e higiene, y sistemas de salud deficientes (apartado 4.1) en comparación con las entidades del centro y norte. Estos hallazgos difieren con índices estáticos previos (Suarez et al., 2020; Ávila-Ortega y Flores-Santana, 2020; Ressler et al., 2020) que localizaron población menos vulnerable al norte y en la capital nacional, esta disparidad podría ser resultado de no considerar una variable de COVID-19 (dinámica en el tiempo). Además, Sierra-Alcocer et al. (2022) mencionan que la

vulnerabilidad estática destaca las regiones que podrían experimentar un fuerte impacto y la vulnerabilidad dinámica matiza las regiones donde existe una fuerte relación entre las condiciones estructurales fijas y la epidemia en evolución.

La serie temporal de casos confirmados y defunciones de COVID-19 (figura 9) permitió identificar cinco olas epidémicas que determinaron los momentos clave para analizar la dinámica de la vulnerabilidad, este resultado coincide con Ascencio-Montiel et al. (2022) y Loza et al. (2023) quienes identificaron la misma cantidad de oleadas en México.

En este contexto, durante la primera ola, 40.4% de los municipios presentaron vulnerabilidad alta y muy alta, las regiones norte, este, península de Yucatán, así como Oaxaca y CDMX resultaron más vulnerables (figura 20a), este hallazgo es similar al de Lima et al. (2021), quienes identificaron a Tlaxcala, CDMX, Sonora y los estados turísticos de la península como los más afectados en la ola 1. Por el contrario, 39.63% de los municipios presentaron vulnerabilidad baja y muy baja, localizados en las regiones centro (excepto CDMX), oeste y suroeste (Chiapas, Guerrero y Michoacán) (figura 20a), particularmente la región suroeste se caracteriza por tener menores condiciones socioeconómicas, de vivienda e higiene, y sistemas de salud deficientes (apartado 4.1) en comparación con las entidades del centro y norte.

Es interesante notar que durante esta ola se registró el punto máximo de casos positivos (212,258) más bajo de las cinco oleadas (figura 9). Este comportamiento podría estar relacionado con diversos factores que influyen en la vulnerabilidad de la población, por un lado, las medidas de control social implementadas por el Gobierno de México como la "Jornada Nacional de Sana Distancia" (GM, 2020) que incluyó el confinamiento parcial o total de la población para evitar el contagio comunitario y por otro, las limitadas pruebas diagnósticas. Este resultado coincide con Pérez. (2020) y Loza et al. (2023), que identificaron a México con una de las tasas de prueba per cápita más bajas con alrededor de 17 por cada 1,000 personas, lo que reducía la detección de casos.

La segunda ola se caracterizó por ser la más severa en relación con las muertes de COVID-19, debido a que, en enero de 2021 se registró el punto máximo de defunciones (39,151) de las cinco oleadas, además, los casos confirmados aumentaron 50% en comparación con la ola 1 (figura 9). Loza et al. (2023) señalan que pudo deberse al

incremento de la movilidad de la población y a la introducción de pruebas rápidas. En relación con la vulnerabilidad, 36.17% de los municipios registraron alta y muy alta (4.23% menos que la primera), la regiones norte, este y península de Yucatán, así como Oaxaca y CDMX (figura 20b) resultaron más vulnerables. Es interesante notar que la capital nacional registró un incremento de seis alcaldías en la categoría 'muy alta' (14 en total) en comparación con la ola 1, en otras palabras, 87.5% del territorio capitalino resulto con niveles muy altos de vulnerabilidad.

Factores de conductas sociales podrían explicar el incremento de casos y defunciones y, en consecuencia, de vulnerabilidad en la ola 2, en particular, el comienzo de las vacaciones decembrinas y la llegada de turistas (nacionales e internacionales), sobre todo a la península por su atractivo turístico, además de la baja cobertura de vacunación (Ascencio-Montiel et al., 2022) y la disponibilidad de camas en unidades de cuidados intensivos (Olivas-Martínez et al., 2021), que resulto baja para todo el país con 62% de los municipios (2,084) con cero camas en UCI (figura 17b). En cambio, esta ola registró el mayor porcentaje de municipios con vulnerabilidad baja y muy baja (44.84%) de las cinco oleadas, localizados en las regiones centro (excepto CDMX), oeste y suroeste (Chiapas, Guerrero y Michoacán) (figura 20b), como se ha mencionado el suroeste se caracteriza por tener menores condiciones socioeconómicas, de vivienda e higiene, y sistemas de salud deficientes (apartado 4.1) en comparación con las regiones centro y norte.

En la tercera ola, las defunciones de COVID-19 disminuyeron 42.13%, en cambio los casos confirmados aumentaron 18.85% en comparación con la segunda (figura 9). Loza et al. (2023) indican que la dominancia de la variable Delta provocó un aumento de infecciones entre las edades más jóvenes que aún no estaban (0-17 años) o recién (18-29 años) incluidas en la campaña de vacunación. El incremento de casos contribuyó a que la población aumentara sus niveles de vulnerabilidad, debido a que, 41.79% de los municipios presentaron alta y muy alta (1.39% y 5.62% más que la primera y segunda ola, respectivamente), las regiones norte, este y península de Yucatán, así como Oaxaca y CDMX resultaron más vulnerables (figura 20c). No obstante, la CDMX disminuyó la cantidad de alcaldías (seis) en la categoría muy alta a alta y una a moderada, Cuajimalpa de Morelos destaca por presentar vulnerabilidad baja en esta ola y las subsecuentes.

Es interesante notar que esta ola registró el menor porcentaje de municipios con vulnerabilidad baja y muy baja (37.84%) de las cinco oleadas, localizados en las regiones centro (excepto CDMX), oeste y suroeste (Guerrero y Michoacán) (figura 20c). La estrategia de vacunación podría explicar el descenso de las muertes de COVID-19 y, en consecuencia, de vulnerabilidad, Ascencio-Montiel et al. (2022) mencionan que la vacunación inicialmente se centró en los grupos más vulnerables como los mayores de 65 años, lo que provocó una disminución en las tasas de mortalidad para los grupos de alto riesgo. Los adultos mayores se localizaron en las regiones norte y sureste, principalmente (figura 13a). Otro factor que ayudó a reducir el número de muertes fue la adquisición de conocimientos en el tratamiento de la enfermedad por parte de los profesionales de la salud (Loza et al., 2023).

La cuarta ola se caracterizó por ser la más severa en relación con la propagación de COVID-19, debido a que, en enero de 2022 se registró el punto máximo de casos confirmados (1,352,436) de las cinco oleadas (figura 9), pese a que, el personal de salud y la población de 40 años y más estaban vacunados parcial o totalmente y se llevaba a cabo la quinta y última etapa de vacunación dirigida al resto de la población (16-39 años). El aumento en los casos se reflejó en la vulnerabilidad de la población y 40.24% de los municipios presentaron alta y muy alta, las regiones norte, este, península de Yucatán, así como Oaxaca y CDMX resultaron más vulnerables (figura 20d).

El inicio de las vacaciones decembrinas, la llegada de turistas (nacionales e internacionales), sobre todo a la península y el surgimiento de la variante Ómicron (noviembre del 2021) podrían explicar el incremento de casos, este resultado es similar al de Loza et al. (2023) quienes explican que la mayor exposición de las personas a Ómicron debido a la reanudación de las actividades sociales puede haber causado el repunte observado de casos durante la ola 4. Además, la ONU (2022) señala que esta variante se propaga más fácilmente, pero la gravedad de la infección ha sido menor en comparación con Delta que prevaleció en la tercera ola. Este último factor, además de los avances en la vacunación y en el tratamiento de la enfermedad podrían explicar la disminución de muertes y, en consecuencia, de vulnerabilidad en 39.35% de los municipios que presentaron vulnerabilidad baja y muy baja, localizados en las regiones centro (excepto CDMX), oeste y suroeste (Guerrero y Michoacán) (figura 20d).

Como era de esperar, la finalización de la campaña de vacunación (marzo 2022) ayudó a la reducción de casos confirmados en la quinta ola en comparación con la ola 4, además se registró el punto máximo de defunciones (2,280) más bajo de las cinco oleadas (figura 9). El 40.49% de los municipios presentaron vulnerabilidad alta y muy alta, las regiones norte y este, así como Oaxaca y CDMX resultaron más vulnerables (figura 20e). Sin embargo, el comienzo de vacaciones de "semana santa" que conlleva movilidad de turistas nacionales (principalmente) podría explicar que la disminución de casos no fue tan representativa como se esperaba, con un descenso de 44% en comparación con la cuarta ola que resultó la más severa de las cinco oleadas. Además, la pérdida de efectividad de la vacuna en el grupo de edad de 50 a 59 años pudo haber sido otra razón para el aumento de casos (Loza et al., 2023). De manera similar, que las olas anteriores, la población menos vulnerable se localizó en las regiones centro (excepto la CDMX), oeste y suroeste (Guerrero y Michoacán) (figura 20e).

En síntesis, las regiones norte, este, península de Yucatán, así como Oaxaca y la capital nacional resultaron más vulnerables ante COVID-19 durante las cinco olas epidémicas. Por el contrario, las regiones centro (excepto CDMX), oeste y suroeste (Chiapas, Guerrero y Michoacán) presentaron vulnerabilidad dinámica baja. Este hallazgo está en línea con Sierra-Alcocer et al. (2022), quienes a nivel estatal identificaron mayor vulnerabilidad en las regiones norte y centro en comparación con la región suroeste que comprende los estados de Chiapas, Oaxaca, Guerrero y Michoacán.

El ÍEDVC19 tiene limitaciones, la falta de datos dinámicos de los factores de riesgo podrían influir en los resultados sobre todo en los estados socialmente vulnerables (Chiapas y Oaxaca) que presentaron municipios con vulnerabilidad alta a partir de la tercera oleada, debido a que los datos analizados son del año 2020 y ubicaron a estos lugares con las peores condiciones socioeconómicas, de vivienda e higiene, características de la población y del sistema de salud (apartado 4.1), lo cual pudo cambiar con el curso de la pandemia. En este sentido, al ser municipios marginados tienden a ser más vulnerables ante cualquier evento adverso, no solo ante COVID-19. Por lo anterior, contar con datos mensuales o anuales contribuiría a análisis más detallados y, en consecuencia, una mejor respuesta a eventos de esta magnitud.

Otra limitación está relacionada con la disponibilidad de datos de variables que influyen en la vulnerabilidad ante COVID-19 como la vacunación y las variantes de esta enfermedad, en particular, conocer cuanta población había concluido el esquema de vacunación y en qué tiempo, además de identificar la exposición y predominancia de las variantes podrían contribuir a refinar análisis espaciotemporales y localizar población vulnerable a lo largo de la pandemia, para ayudar a los planificadores de salud en la intervención y asignación de recursos de manera oportuna.

El ÍEDVC19 tiene fortalezas respecto a índices de vulnerabilidad estáticos desarrollados para México (Suarez et al., 2020; Ávila-Ortega y Flores-Santana, 2020; Ressler et al., 2020) y se suma al DySoVI (Sierra-Alcocer et al., 2022) que fue el primero en mostrar la visión dinámica en este país, mientras que los índices estáticos localizan la población que podría estar en riesgo, el ÍEDVC19 localiza las regiones susceptibles a los resultados negativos de la pandemia, derivado de la relación entre los factores estructurales y de salud de la población, y la evolución de COVID-19.

Otra fortaleza se relaciona con la metodología para el desarrollo del ÍEDVC19, debido a que puede ser replicable a cualquier país o escalas más pequeñas, en la medida de la disponibilidad de datos. Un punto para destacar es el análisis de sensibilidad, debido a que pocos estudios realizan validación de sus modelos. Además, el enfoque conceptual de los determinantes sociales de salud aplicado al análisis de vulnerabilidad, la visión espacial de la geografía y el uso de geotecnologías fundamentan la creación de este tipo de índices.

VI. Conclusiones

La pandemia de COVID-19 es un proceso complejo y dinámico que afecta a gran parte de la población mundial. Sin embargo, determinados grupos son más susceptibles a los resultados negativos derivado de factores de riesgo asociados al nivel socioeconómico, características de la población, vivienda e higiene, epidemiológicos, sistema de salud, entre otros. En este contexto, el índice desarrollado es capaz de localizar población vulnerable ante COVID-19 y aporta información útil de los momentos clave de la pandemia para que los funcionarios de salud pública diseñen estrategias equitativas acorde a la realidad territorial y temporal. De este modo, los siguientes apartados exponen las conclusiones de investigación que están en línea con la estructura capitular.

VI.1 Conclusiones de la relación entre el lugar y la enfermedad, y los índices de vulnerabilidad

Las topografías médicas (siglos XVIII y XIX) iniciaron con estudios que detallaban las condiciones de salud, factores físicos y sociales en comunidades europeas; durante el siglo XX surgieron ramas como la geografía médica y la geografía de la salud que siguen vigentes y bajo sus enfoques se desarrollan estudios relacionados con la distribución espacial de enfermedades y los sistemas de salud (infraestructura y recursos humanos), principalmente. Estos antecedentes y el avance tecnológico han marcado una pauta en la visión espacial de la relación entre el lugar y la enfermedad, y en la actualidad se realizan análisis más avanzados, a partir de herramientas geotecnológicas que han revalorizado la utilidad de la geografía en eventos de salud.

El uso de geotecnologías en análisis de enfermedades por parte de instituciones gubernamentales, educativas y usuarios han posicionado a la geografía como una ciencia que aporta conocimiento geoespacial valioso para la toma de decisiones enfocada en el territorio. A partir de 1990, estas instancias, incluyeron a los SIG y la teledetección en sus estudios dando como resultado sistemas de vigilancia de enfermedades y análisis de asociación espacial, entre otros. No obstante, con la cantidad de datos en salud generados por organizaciones mundiales, secretarías nacionales y empresas privadas es necesario disponer de software y métodos que almacenen, procesen y visualicen grandes cantidades de datos; por lo tanto, las tendencias geotecnológicas (geoanalítica, GeoAI y lenguajes de programación) son indispensables para perfeccionar el conocimiento que

se tiene acerca de la relación entre la ubicación geográfica (ambiente o lugar donde vivimos) y la propagación de enfermedades.

La pandemia de COVID-19 es un ejemplo de la producción de grandes volúmenes de datos, principalmente porque los gobiernos y la población comenzaron a compartir datos entorno a esta condición de salud que afecta a gran parte la humanidad “unos más que otros”. De este modo, instituciones sanitarias proponen que a través del marco de los determinantes sociales de salud se analice la vulnerabilidad de la población ante desastres o brotes de enfermedades, debido a que factores estructurales y de salud de la población representan una preocupación para la salud pública, en particular, este enfoque conceptual fue retomado para desarrollar un índice de vulnerabilidad ante COVID-19 basado en la visión espacial de la geografía y el uso de geotecnologías.

VI.2 Conclusiones de la metodología para el desarrollo de un ÍEDVC19

La metodología combinó técnicas de análisis espaciotemporal y estadístico que puede adaptarse a otros países o áreas geográficas específicas, en la medida de que se disponga de datos, o crear estrategias de obtención de información. En particular, la selección de variables se basó en índices de vulnerabilidad creados para otros países, lo que ocasionó disparidad entre algunos indicadores, por esta razón se ajustaron aquellos que no estaban en línea con los disponibles para México, por medio de indicadores proxy.

El análisis espaciotemporal se ejecutó en SaTScan™ por su utilidad en estudios de salud y acceso gratuito, el tipo de análisis seleccionado fue el retrospectivo de exploración de espacio-tiempo que permitió detectar conglomerados dentro de un lugar y periodo de tiempo definidos. Sin embargo, fue necesario realizar ajustes en la configuración predeterminada del software para que los resultados mostraran pequeños grupos de alto riesgo y no grandes grupos que no son útiles para priorizar los recursos en salud pública. Asimismo, no se debe olvidar que un estudio retrospectivo examina datos del pasado; por lo tanto, este análisis proporcionó evidencia de un hecho acontecido como la pandemia de COVID-19 y no predice su evolución, si ese fuera el objetivo se debe emplear un análisis prospectivo que también está disponible en SaTScan™.

El uso adecuado de las estadísticas y gráficos que proporciona R y RStudio se han convertido en una herramienta de gran potencial para analizar datos de salud. En este sentido, los análisis estadísticos se desarrollaron en este entorno de software libre,

específicamente, las técnicas estadísticas y de correlación contribuyeron a descartar indicadores que presentaron falta excesiva de datos y redundancia de información. A partir de la prueba de normalidad Shapiro-Wilk se identificó si la distribución de los datos era normal o no, en vista de que, no resultado normal se aplicó el método de correlación de Spearman que es indicado para este tipo de distribuciones.

Para ejecutar el Análisis de Componentes Principales se requiere una matriz de datos estándar y no debe haber valores faltantes. Dado que algunos indicadores registraron valores perdidos ($\leq 50\%$) fue necesario realizar preprocesamiento de datos, otra virtud de R es proporcionar técnicas de imputación de datos para el tratamiento de valores faltantes y mejorar la calidad de la información, de este modo, se generó una base de datos completa y se efectuó el ACP que permitió conocer los coeficientes del primer componente principal (valores con más información) que a su vez sirvieron como pesos para aplicar la fórmula y obtener los valores del ÍEDVC19. Además, el índice resultó robusto, debido a que más del 65% de los índices modificados no registraron variación significativa.

VI.3 Conclusiones de los resultados del ÍEDVC19

Las estadísticas de exploración de espacio-tiempo permitieron localizar conglomerados de tasas altas de casos confirmados y defunciones de COVID-19 en el periodo de febrero 2020 a diciembre 2022. Cada grupo presentó un patrón espacial y temporal heterogéneo y en determinados casos coincidieron con la duración de las olas epidémicas, este tipo de análisis proporciona información útil para los planificadores de salud de dónde se localizan las poblaciones en riesgo y durante cuánto tiempo permanecen expuestas, para implementar estrategias específicas como la adecuada asignación de recursos y afrontar la pandemia de manera oportuna.

Los factores de riesgo relacionados con COVID-19 presentaron distribuciones heterogéneas y algunos formaron patrones espaciales en lugares que requieren de atención por concentrar valores altos. Representar cartográficamente estos comportamientos permite identificar las desigualdades estructurales y de salud de la población, y explicar su incidencia en el territorio, para que los tomadores de decisiones locales orienten intervenciones específicas en los lugares que más carecen y, en consecuencia, son más susceptibles a experimentar pérdidas humanas y económicas en caso de que se presente un desastre sicionatural o brotes de enfermedades infecciosas.

El índice muestra la localización espacial y temporal de la población vulnerable a los resultados negativos de la pandemia de COVID-19, mediante la relación entre factores de riesgo y la evolución de esta enfermedad. Identificar quienes son los más vulnerables y que los hace estar en esta condición se convierte en un aspecto clave para los funcionarios de salud pública que les permite focalizar intervenciones en los lugares prioritarios de atención como es el caso de las regiones norte, este y península de Yucatán, así como en Oaxaca y la Ciudad de México, que registraron niveles altos de vulnerabilidad durante las cinco olas epidémicas.

Asimismo, el ÍEDVC19 complementa la visión estática de la vulnerabilidad y aporta nueva evidencia a los índices variables en el tiempo, la pandemia es un proceso complejo y dinámico que requiere herramientas que faciliten la ubicación geográfica de las poblaciones susceptibles ante eventos de esta magnitud para prevenir y controlar futuros escenarios adversos, además la validación del modelo hace más confiable los resultados para los funcionarios de salud pública en la toma de decisiones equitativas para el cuidado de los lugares particularmente afectados.

VII. Recomendaciones

Si bien, la revisión de literatura permitió conocer los aportes de la geografía y las geotecnologías en el estudio de la relación entre el lugar y la enfermedad, se sugiere revisar nuevos aportes teóricos y conceptuales que fundamenten análisis más avanzados en salud desde la perspectiva espacial, debido a que los problemas de salud actuales requieren de nuevos postulados y líneas de investigación definidas para analizar y comprender el proceso salud-enfermedad-atención. Además, es importante unificar el concepto de vulnerabilidad social en salud para evitar discrepancias en la definición con otras investigaciones.

Los estudios geográficos sobre la pandemia de COVID-19 revalorizaron la utilidad de esta ciencia en estudios de salud, sin embargo, se recomienda realizar análisis estadísticos antes de emplear técnicas de análisis espacial, debido a que en ocasiones la distribución o la falta de datos influyen en los resultados y, en consecuencia, pueden ser equivocados. Asimismo, al momento de elegir un método de correlación entre variables, es fundamental aplicar una prueba de normalidad de datos para seleccionar el apropiado de acuerdo con su distribución.

Debido a la cantidad de datos analizados, se sugiere el uso de un software que permita almacenar, procesar y visualizar bases de datos robustas, en particular, R y RStudio tiene estas ventajas, además de que integra funciones estadísticas y se pueden elaborar gráficos adecuados para la presentación de resultados de una investigación. No obstante, la elaboración de mapas se recomienda desarrollarla en un software SIG, debido a que el proceso en R y RStudio puede ser tardado y el diseño final muestra deficiencias estéticas “en mi perspectiva”.

Los resultados del ÍEDVC19 localizaron poblaciones vulnerables ante COVID-19 en el espacio y tiempo; por lo tanto, se sugiere a los funcionarios de salud pública y actores interesados apoyarse de este tipo de herramientas con sustento teórico y metodológico para focalizar intervenciones en los lugares prioritarios que registraron altos niveles de vulnerabilidad, además ante el surgimiento de enfermedades transmisibles, es recomendable formular políticas equitativas basadas en el territorio para prevenir futuros escenarios adversos.

A la población en general se recomienda que ante un brote de enfermedad infecciosa se mantenga informada de fuentes confiables como las organizaciones mundiales de salud, las secretarías sanitarias nacionales, los centros de salud locales, entre otros, el mal uso de las redes sociales puede generar desinformación y, en consecuencia, tomar malas decisiones. Además, las conductas sociales influyen en el aumento o disminución de enfermos; por lo tanto, es importante seguir las recomendaciones de las autoridades sanitarias para prevenir casos evitables y poner fin a eventos como la pandemia de COVID-19.

Referencias bibliográficas

- Acharya, R., y Porwal, A. (2020). A vulnerability index for the management of and response to the COVID-19 epidemic in India: an ecological study. *The Lancet. Global health*, 8(9), e1142-e1151. [https://doi.org/10.1016/S2214-109X\(20\)30300-4](https://doi.org/10.1016/S2214-109X(20)30300-4).
- Akoglu, H. (2018). User's guide to correlation coefficients. *Turkish journal of emergency medicine*, 18(3), 91-93. <https://doi.org/10.1016/j.tjem.2018.08.001>
- Alanís, C. (2020). Medicina, salud e higiene en el siglo XIX. ICSHu. *Boletín Científico de Ciencias Sociales y Humanidades*, 9(17), 35-42.
- Alcaide, R. (1990). La introducción y el desarrollo del higienismo en España durante el siglo XIX. Precursores, continuadores y marco legal de un proyecto científico y social. *Scripta nova*. (50), 32-54.
- Álvarez, Á., Díaz, C., García, M. et al. (2007). Sistema integrado de vigilancia para la prevención de dengue. *Revista Cubana de Medicina Tropical*, 59(3), 193-201.
- Althouse, LA., Ware, WB. y Ferron, JM. (1998). Detecting Departures from Normality: A Monte Carlo Simulation of A New Omnibus Test based on Moments. *Paper presented at the Annual Meeting of the American Educational Research Association*, San Diego, CA.
- Araujo, R. (2015). Vulnerabilidad y riesgo en salud: ¿dos conceptos concomitantes? *Revista Novedades en Población*, 11(21), 89-96.
- Arroz, M.E. (1977). Difusão Espacial da Hepatite Infecciosa, Lisboa, Centro Estudos Geográficos.
- Ascencio-Montiel, I.J., Ovalle-Luna, O.D., Rascón-Pacheco, R.A. et al. (2022) Comparative epidemiology of five waves of COVID-19 in Mexico. *BMC Infect Dis* 22, 813. <https://doi.org/10.1186/s12879-022-07800-w>
- Austin, C., y Kusumoto, F. (2016). The application of Big Data in medicine: current implications and future directions. *J Interv Card Electrophysiol* 47, 51-59. <https://doi.org/10.1007/s10840-016-0104-y>
- Ávila-Ortega, D., y Flores-Santana, C. (2020). An index of municipality-level vulnerability to COVID-19 in Mexico. *Terra Digitalis*, 4(2), 1-11. <https://doi.org/10.22201/igg.25940694e.2020.2.73>
- Azage, M., Kumie, A., Worku, A., y Bagtzoglou, AC. (2015) Childhood Diarrhea Exhibits Spatiotemporal Variation in Northwest Ethiopia: A SaTScan Spatial Statistical

- Analysis. *PLoS ONE* 10(12): e0144690.
<https://doi.org/10.1371/journal.pone.0144690>
- Barrera-Algarín, E., Estepa, F., Sarasola, J.L., y Vallejo, A. (2020). COVID-19, neoliberalismo y sistemas sanitarios en 30 países de Europa: repercusiones en el número de fallecidos. *Revista Española de Salud Pública*. ISSN-e 1135-5727.
- Barankanira, E., Molinari, N., Niyongabo, T. et al. (2015). Spatial analysis of HIV infection and associated individual characteristics in Burundi: indications for effective prevention. *BMC Public Health* 16, 118. <https://doi.org/10.1186/s12889-016-2760-3>
- Barcellos, C., Buzai, G., y Santana, P. (2018). Geografía de la salud: bases y actualidad. *Salud colectiva*. 14(1), 1-4. doi: 10.18294/sc.2018.1763
- Bascañán, J. (2015). El higienismo y la noción de contagio. el caso de la sífilis en los anales de la Universidad de Chile. *Intus - Legere Historia*, 9(1), 69-86. doi:<https://doi.org/10.15691/%x>
- Beam, AL., y Kohane, I.S. (2018). Big Data and Machine Learning in Health Care. *JAMA*, 319(13), 1317-1318. <https://doi.org/10.1001/jama.2017.18391>
- Beck, LR., Lobitz, BM., y Wood, BL. (2000). Remote sensing and human health: new sensors and new opportunities. *Emerging infectious diseases*, 6(3), 217-227. [https://doi.org/10.1016/s0065-308x\(00\)47014-4](https://doi.org/10.1016/s0065-308x(00)47014-4)
- Bellinger, C., Jabbar, MS., Zaiane, O. et al. (2017). A systematic review of data mining and machine learning for air pollution epidemiology. *BMC public health*, 17(1), 907. <https://doi.org/10.1186/s12889-017-4914-3>
- Benita, F., y Gasca-Sanchez, F. (2021). The main factors influencing COVID-19 spread and deaths in Mexico: A comparison between phases I and II. *Applied geography (Sevenoaks, England)*, 134, 102523. <https://doi.org/10.1016/j.apgeog.2021.102523>
- Blatt, AJ. (2015). The Importance of Geography in Disease Surveillance. En Blatt, A.J. (coord.) In: Health, Science, and Place. Geotechnologies and the Environment, vol 12. *Springer*, Cham. https://doi.org/10.1007/978-3-319-12003-4_2
- Bogorny, V., y Shekhar, S. (2010) "Spatial and Spatio-temporal Data Mining," *IEEE International Conference on Data Mining*, 1217-1217, doi: 10.1109/ICDM.2010.166.

- Boran, L., Xiao, G., y Qianyi, Zhou. (2022). "Construction of Development Momentum Index of Financial Technology by Principal Component Analysis in the Era of Digital Economy", *Computational Intelligence and Neuroscience*.
<https://doi.org/10.1155/2022/2244960>
- Borrel, C., y Malmusi, D. (2010). La investigación sobre los determinantes sociales y las desigualdades en salud: evidencias para la salud en todas las políticas. Informe SESPAS 2010. *Gaceta Sanitaria*. 24(Supl 1):101-8.
<https://doi.org/10.1016/j.gaceta.2010.05.005>.
- Borja-Aburto, V. (2000). Estudios ecológicos. *Salud Pública de México*. 42(6):533-538.
- Boulos, K., y Koh, K. (2021) Smart city lifestyle sensing, big data, geo-analytics and intelligence for smarter public health decision-making in overweight, obesity and type 2 diabetes prevention: the research we should be doing. *Int J Health Geogr* 20, 12. <https://doi.org/10.1186/s12942-021-00266-0>
- Boulos, K., Peng, M., y VoPham, G. (2019). An overview of GeoAI applications in health and healthcare. *Int J Health Geogr* 18, 7. <https://doi.org/10.1186/s12942-019-0171-2>
- Bragazzi, N., Haijiang, D., Damiani, H. et al. (2020) "How Big Data and Artificial Intelligence Can Help Better Manage the COVID-19 Pandemic" *International Journal of Environmental Research and Public Health*, 17(9), 3176.
<https://doi.org/10.3390/ijerph17093176>
- Brownstein, J.S., Holford, T.R., y Fish, D. (2005). Effect of Climate Change on Lyme Disease Risk in North America. *EcoHealth*, 2(1), 38-46. <https://doi.org/10.1007/s10393-004-0139-x>
- Buckeridge, D., Mason, R., Robertson, A. et al. (2002). Making health data maps: a case study of a community/university research collaboration. *Social science y medicine*, 55(7), 1189-1206. [https://doi.org/10.1016/s0277-9536\(01\)00246-5](https://doi.org/10.1016/s0277-9536(01)00246-5)
- Busso, G. (2001). Vulnerabilidad social: nociones e implicancias de políticas para Latinoamérica a inicios del siglo XXI. En Seminario Internacional "Las Diferentes expresiones de la Vulnerabilidad Social en América Latina y el Caribe", Santiago de Chile
- Buzai, G. (2021). Análisis espacial cuantitativo de los Condicionantes Socioespaciales de la Salud (CSS) de la megaciudad Buenos Aires. *Revista Geográfica Digital*, 18(35), 2-14. <http://dx.doi.org/10.30972/geo.18355130>

- Buzai, G. (2014). Paradigma Geotecnológico, Geografía Global y CiberGeografía, la gran explosión de un universo digital en expansión. *GeoFocus*, (1), 24-48.
- Byrnes, J., Mahoney, R., Quaintance, C. et al. (2015). Spatial and temporal patterns in preterm birth in the United States. *Pediatr Res*, 77, 836-844. <https://doi.org/10.1038/pr.2015.55>
- Cabieses, B., Bernales, M., Obach, A. et al. (2016). Capítulo 1. Introducción. En Cabieses, B., Bernales, M., Obach, A., y Pedrero, B. (ed) Vulnerabilidad social y su efecto en salud en Chile: Desde la comprensión del fenómeno hacia la implementación de soluciones (Primera edición, pp 13-19). Chile
- Camargo, A. (2022). PCAtest: testing the statistical significance of Principal Component Analysis in R. *PeerJ*, 10, e12967. <https://doi.org/10.7717/peerj.12967>
- Cárdenas, E., Juárez, C., Moscoso, R., y Vivas, J. (2017). Determinantes sociales en salud. Universidad ESAN, ISBN 978-612-4110-71-9 (Primera edición). Lima-Perú.
- Cardona, O. (1993). Evaluación de la amenaza, la vulnerabilidad y el riesgo. En Maskrey, A. (ed). Los desastres no son naturales (Primera edición, pp 45-64). Perú: Red de estudios sociales en prevención de desastres en América Latina
- Cardona, O. (2001). La necesidad de repensar de manera holística los conceptos de vulnerabilidad y riesgo. En *el International Work-Conference on Vulnerability in Disaster Theory and Practice*.
- Carter, E. (2016). El desarrollo de la geografía médica: una reseña de tendencias actuales. *Población y Sociedad*, 23(2), 207-220. <https://cerac.unlpam.edu.ar/index.php/pys/article/view/2982>
- Carroll, LN., Au, AP., Detwiler, LT. et al. (2014). Visualization and analytics tools for infectious disease epidemiology: a systematic review. *Journal of biomedical informatics*, 51, 287-298. <https://doi.org/10.1016/j.jbi.2014.04.006>
- Casco, J. (2001). Las topografías médicas: revisión y cronología. *Asclepio, Revista de Historia de la medicina y de la Ciencia*, 52(1), 213-244. <https://doi.org/10.3989/asclepio.2001.v53.i1.178>
- CDC. Centers for Disease Control and Prevention (2019). GIS and Public Health at CDC. <https://www.cdc.gov/gis/index.htm>
- CDC. Centers for Disease Control and Prevention (2018). Social Vulnerability Index (SVI) Interactive Map. <https://svi.cdc.gov/map.html>

- CDC/ATSDR. Centers for Disease Control and Prevention / Agency for Toxic Substances and Disease Registry (2021). At a glance: CDC/ATSDR Social Vulnerability Index. https://www.atsdr.cdc.gov/placeandhealth/svi/at-a-glance_svi.html
- Chang, AY., Parrales, ME., Jimenez, J. et al. (2009). Combining Google Earth and GIS mapping technologies in a dengue surveillance system for developing countries. *Int J Health Geogr* 8, 49. <https://doi.org/10.1186/1476-072X-8-49>
- Chimoyi, LA., y Musenge, E. (2014). Spatial analysis of factors associated with HIV infection among young people in Uganda, 2011. *BMC Public Health* 14, 555. <https://doi.org/10.1186/1471-2458-14-555>
- CONABIO. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (2020). Panel de información sobre COVID-19. <https://www.biodiversidad.gob.mx/atlas/covid19/>
- CONAPO. Consejo Nacional de Población (2015). Proyecciones de la Población de los municipios de México, 2015-2030. <https://datos.gob.mx/busca/organization/conapo>
- CONEVAL. Consejo Nacional de Evaluación de la Política de Desarrollo Social (2020). Pobreza a nivel de municipio 2010-2020. <https://www.coneval.org.mx/Medicion/Paginas/Pobreza-municipio-2010-2020.aspx>
- Correia, V., Carvalho, M., Sabrosa, P. et al. (2004) Remote sensing as a tool to survey endemic diseases in Brazil. *Cadernos de Saúde Pública*, 20(4), 891-904. <https://doi.org/10.1590/S0102-311X2004000400003>.
- COVID-19 National Emergency Response Center, Epidemiology and Case Management Team, Korea Centers for Disease Control and Prevention (2020). Coronavirus Disease-19: Summary of 2,370 Contact Investigations of the First 30 Cases in the Republic of Korea. *Osong public health and research perspectives*, 11(2), 81-84. <https://doi.org/10.24171/j.phrp.2020.11.2.04>
- Cromley, E., y McLafferty, S. (2012). GIS and Public Health. The Guilford Press: New York, New York. 2nd edition.
- Cromley, E. (2003). GIS and Disease, *Annu. Rev. Public Health*, 24, 7-24 doi: 10.1146/annurev.publhealth.24.012902.141019
- Cruz, H., y Monteiro J. (2021). Mortalidad por COVID-19 y las desigualdades por nivel socioeconómico y por territorio. *Población y desarrollo (CEPAL)*.

- <https://www.cepal.org/es/enfoques/mortalidad-covid-19-desigualdades-nivel-socioeconomico-territorio>
- Cruz, G., González, S., y Quiroz, L. (2017). Las tecnologías de la información y la comunicación en la enseñanza del pensamiento espacial en las ciencias sociales. *Especialidades*, 7(2), 92-106. <https://www.redalyc.org/journal/4195/419553524005/html/>
- CUAED-UNAM. Coordinación de la Universidad Abierta y Educación a Distancia de la Universidad Nacional Autónoma de México (2017). Lenguajes de programación. https://programas.cuaed.unam.mx/repositorio/moodle/pluginfile.php/1023/mod_resource/content/1/contenido/index.html
- Cuéllar, L., y Gutiérrez T. (2014). Desarrollo de la geografía médica o de la salud en Cuba. *Revista cubana de higiene y epidemiología*, 52(3), 388-401.
- Culebras, JM., Jáuregui-Lobera, I., y Franco-López, A. (2020) En la pandemia de COVID-19 no hay camas para todos, ¿a quién tratamos? *JONNPR*. 5(6):589-96. DOI: 10.19230/jonnpr.3664
- Curto, S. (2008). De la Geografía Médica a la Geografía de la Salud. *Revista geográfica del Instituto Panamericano de Geografía e Historia*. (143), 10-27. DOI:10.2307/40996761
- Curto, S. (1985). Geografía y Salud Humana. Asociación para la Promoción de Sistemas Educativos no Convencionales. SENOC.
- Curto, S. (1983). Geografía de los complejos patógenos. *Medicina y Humanismo*, 4(11), 295-300.
- Cutter, S., Boruff, B., y Shirley, W. (2003) Social vulnerability to environmental hazards. *Social Science Quarterly*, 84(2), 242-261. doi:10.1111/1540-6237.8402002
- Dangermond, J., y Goodchild, M. (2020). Building geospatial infrastructure, *Geo-spatial Information Science*, 23(1), 1-9. <https://doi.org/10.1080/10095020.2019.1698274>
- Daras, K., Alexiou, A., Rose, TC. et al. (2021) How does vulnerability to COVID-19 vary between communities in England Developing a Small Area Vulnerability Index (SAVI), *J Epidemiol Community Health* 75:729-734. <http://dx.doi.org/10.1136/jech-2020-215227>
- Davis, I. (1978). Shelter After Disaster, Oxford Polytechnic Press. Oxford

- Devin, I., Howard, T., Gianluca, B. et al. (2019) R You Still Using Excel? The Advantages of Modern Software Tools for Health Technology Assessment, *Value in Health*, 22(5), 575-579. <https://doi.org/10.1016/j.jval.2019.01.003>.
- Doupe, P., Faghmous, J., y Basu, S. (2019). Machine Learning for Health Services Researchers. *Value in health*, 22(7), 808-815. <https://doi.org/10.1016/j.jval.2019.02.012>
- Dutta, I., Basu, T., y Das, A. (2021). Spatial analysis of COVID-19 incidence and its determinants using spatial modeling: A study on India, *Environmental Challenges*, Volume 4, ISSN 2667-0100, <https://doi.org/10.1016/j.envc.2021.100096>.
- Dyer, O. (2020). Covid-19: Black people and other minorities are hardest hit in US, *BMJ*; 369:m1483 doi:10.1136/bmj.m1483
- Emilsson, L., Lindahl, B., Köster, M. et al. (2015). Review of 103 Swedish Healthcare Quality Registries. *Journal of internal medicine*, 277(1), 94-136. <https://doi.org/10.1111/joim.12303>
- Eslava, JC., Hernández, LH., Sarmiento, R. et al. (2016). Reflexiones acerca de la relación ambiente y salud: Pensando en ambientes saludables (Primera edición.). Bogotá: Universidad Nacional de Colombia. Facultad de Medicina. Departamento de Salud Pública.
- Esri. Environmental Systems Research Institute (2020). GIS for Health Care Today and Tomorrow. <https://www.esri.com/news/arcuser/0499/umbrella.html>
- Flanagan, BE., Gregory, EW., Hallisey, EJ. et al. (2011). A social vulnerability index for disaster management. *Journal of homeland security and emergency management*, 8(1).
- Foundation Surgo (2021). COVID-19 Community Vulnerability Index (CCVI). Precision for COVID. <https://precisionforcovid.org/ccvi>
- Gallegos, A. (2020). Necesidad de recursos humanos de enfermería por brote de COVID-19 Perú. *Rev. RECIEN*. 9(1).
- Gao, S., Mioc, D., Anton, F. et al. (2008). Online GIS services for mapping and sharing disease information. *International journal of health geographics*, 7, 8. <https://doi.org/10.1186/1476-072X-7-8>
- García, N., y Tello P. (2020). Análisis geográfico del Estado de Guerrero: una aproximación basada en los factores socioeconómicos de vulnerabilidad. En Santana et al.

- (coord). Ordenación territorial: Una revisión desde los objetivos de desarrollo sostenible. (Primera edición, pp 133-160). Toluca, México: Universidad Autónoma del Estado de México
- García, R. (2001). El alba de la modernidad. En Historia de las doctrinas sociales. La Habana: Ediciones Memoria.
- García, M. (2012). Medicina y arte. La evolución de la anatomía en el Renacimiento. *Rev Cient Soc Esp Enferm Neurol*, 35(1), 25-27. <https://www.elsevier.es/es-revista-revista-cientifica-sociedad-espanola-enfermeria-319-pdf-X201352461242765X>
- Geosalud México (2023). Atiende las medidas sanitarias contra la pandemia de COVID-19. <https://geosalud.github.io/Geosalud/index.html>
- Gesler, W. (1986). The uses of spatial analysis in medical geography: A review, *Social Science y Medicine*, 23(10), 963-973. [https://doi.org/10.1016/0277-9536\(86\)90253-4](https://doi.org/10.1016/0277-9536(86)90253-4).
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). Deep learning. MIT press.
- Gómez, E. (2009). Un recorrido histórico del concepto de salud y calidad de vida a través de los documentos de la OMS. *Revista TOG (A Coruña)*, 6(1), 1-10. <http://www.revistatog.com/num9/pdfs/original2.pdf>
- Gomes, C. (2020). Report of the WHO-China Joint Mission on Coronavirus Disease 2019 (COVID-19). *Brazilian Journal of Implantology and Health Sciences*, 2(3). Retrieved from <https://bjih.s.emnuvens.com.br/bjih/article/view/172>
- González, L., y Pérez, G. (2013). Minería de datos espaciales y su aplicación en estudios de salud y epidemiología. *Revista Cubana de Información en Ciencias de la Salud*, 24 (4), 482-489. http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2307-21132013000400010&lng=es&lng=en.
- Gorris, ME., Shelley, CD., Del Valle, SY., y Manore, CA. (2021). A time-varying vulnerability index for COVID-19 in New Mexico, USA using generalized propensity scores. *Health policy OPEN*, 2, 100052. <https://doi.org/10.1016/j.hpopen.2021.100052>
- Greenough, P., y Nelson, E. (2019). Beyond mapping: a case for geospatial analytics in humanitarian health. *Confl Health* 13, 50. <https://doi.org/10.1186/s13031-019-0234-9>

- GM. Gobierno de México (2020). Medidas de seguridad sanitaria. <https://coronavirus.gob.mx/medidas-de-seguridad-sanitaria/>
- GM. Gobierno de México. (2021). Ficha país. México. https://www.exteriores.gob.es/documents/fichaspais/mexico_ficha%20pais.pdf
- Grosjean, P., y Ibanez, F. (2018). *_pastecs: Package for Analysis of Space-Time Ecological Series_*. R package version 1.3.21, <<https://CRAN.R-project.org/package=pastecs>>.
- Gross, J., y Ligges, U. (2015). *_nortest: Tests for Normality_*. R package version 1.0-4, <<https://CRAN.R-project.org/package=nortest>>.
- Gutiérrez, M., y García-Ramos, JC. (2018). La geología de Asturias a través de las Topografías Médicas. *Trabajos De Geología*, 36(36), 203-236. <https://doi.org/10.17811/tdg.36.2016.203-236>
- Hanusz, Z., y Tarasińska, J. (2015). Normalization of the Kolmogorov-Smirnov and Shapiro-Wilk tests of normality. *Biometrical Letters*, 52(2) 85-93. <https://doi.org/10.1515/bile-2015-0008>
- Harrell, F. (2022). *_Hmisc: Harrell Miscellaneous_*. R package versión 4.7-1, <<https://CRAN.R-project.org/package=Hmisc>>.
- Health eHeart Study. (2021). University of California, San Francisco. <https://www.health-eheartstudy.org/>.
- Hernández, J., Núñez, I., Bacigalupo, A. et al. (2013). Modeling the spatial distribution of Chagas disease vectors using environmental variables and people's knowledge. *Int J Health Geogr* 12(29). <https://doi.org/10.1186/1476-072X-12-29>
- Hernández, R., y Fernández, C. (1998). Metodología de la investigación. México: McGraw-Hill
- Hilbert, M., y López, P. (2011). The world's technological capacity to store, communicate, and compute information. *Science*, 332(6025), 60-65. <https://doi.org/10.1126/science.1200970>
- Hipp, JA., y Chalise, N. (2015). Spatial Analysis and Correlates of County-Level Diabetes Prevalence, 2009-2010. *Prev Chronic Dis*, 12(140404). <https://doi.org/10.5888/pcd12.140404>

- HVRI. Hazards & Vulnerability Research Institute (2021). Social Vulnerability Index for the United States - 2010-2014. <http://artsandsciences.sc.edu/geog/hvri/sovi%C2%AE-0>
- Íñiguez, L. (1998). Geografía y salud: temas y perspectivas en América Latina. *Cad. Saúde Pública*, 14(4), 701-711. <https://doi.org/10.1590/S0102-311X1998000400012>
- IMCO. Centro de Investigación en Política Pública (2014). Los índices: hacer concreto lo abstracto. <https://imco.org.mx/los-indices-hacer-concreto-lo-abstracto/>
- INSP. Instituto Nacional de Salud Pública (2020). Fases de la epidemia por COVID-19 <https://www.insp.mx/avisos/5344-fases-de-la-epidemia-por-covid-19.html>
- INSP. Instituto Nacional de Salud Pública (2020). Línea de investigación en salud y grupos vulnerables. <https://www.insp.mx/lineas-de-investigacion/salud-y-grupos-vulnerables.html>
- INEGI. Instituto Nacional de Estadística y Geografía (2020). División territorial. En línea: <https://cuentame.inegi.org.mx/territorio/division/default.aspx?tema=T>
- INEGI. Instituto Nacional de Estadística y Geografía (2020). Demografía y sociedad. Población. <https://www.inegi.org.mx/temas/estructura/>
- Jalal, H., Pechlivanoglou, P., Krijkamp, E. et al. (2017). An Overview of R in Health Decision Sciences. *Medical decision making*, 37(7), 735-746. <https://doi.org/10.1177/0272989X16686559>
- Jordan, RE., Adab, P., y Cheng, KK. (2020). Covid-19: risk factors for severe disease and death. *BMJ (Clinical research ed.)*, 368, m1198. <https://doi.org/10.1136/bmj.m1198>
- Jori, G. (2013). El estudio de la salud y la enfermedad desde una perspectiva geográfica: temas, enfoques y métodos. *Revista bibliográfica de geografía y ciencias sociales*, 18(1029).
- Josse, J. y Husson, F. (2016). missMDA: A Package for Handling Missing Values in Multivariate Data Analysis. *Journal of Statistical Software*, 70(1), 1-31. [doi:10.18637/jss.v070.i01](https://doi.org/10.18637/jss.v070.i01)
- Josse, J. y Husson, F. (2013). Selecting the number of components in principal component analysis using cross-validation approximations, *Computational Statistics y Data Analysis*, 56(6), 1869-1879, <https://doi.org/10.1016/j.csda.2011.11.012>.

- Josse, J. y Husson, F. (2009). Pagès, Jérôme. Gestion des données manquantes en Analyse en Composantes Principales. *Journal de la société française de statistique*, 150(2), 28-51.
- JHU Johns Hopkins University (2023). CORONAVIRUS RESOURCE CENTER. <https://coronavirus.jhu.edu/map.html>
- Juárez, C., Márquez, M., Salgado, N. et al. (2014). La desigualdad en salud de grupos vulnerables de México: adultos mayores, indígenas y migrantes. *Rev Panam Salud Publica*. 35(4), 284-90.
- Kamis, C., Stolte, A., West, JS. et al. (2021). Overcrowding and COVID-19 mortality across U.S. counties: ¿Are disparities growing over time? *SSM - population health*, 15, 100845. <https://doi.org/10.1016/j.ssmph.2021.100845>
- Katrien, T., Groenhof, J., Laurien R. et al (2020). Data mining information from electronic health records produced high yield and accuracy for current smoking status, *Journal of Clinical Epidemiology*, 118, <https://doi.org/10.1016/j.jclinepi.2019.11.006>.
- Katzman, R. (2000). Notas sobre la medición de la vulnerabilidad social. En CEPAL (ed). La medición de la pobreza: métodos y aplicaciones (Primera edición, pp 275-303). Aguascalientes, México
- Kauhl, B., Schweikart, J., Krafft, T. et al. (2016). ¿Do the risk factors for type 2 diabetes mellitus vary by location? A spatial analysis of health insurance claims in Northeastern Germany using kernel density estimation and geographically weighted regression. *Int J Health Geogr* 15, 38. <https://doi.org/10.1186/s12942-016-0068-2>
- Kim, S., y Castro, MC. (2020). Spatiotemporal pattern of COVID-19 and government response in South Korea (as of May 31, 2020). *International journal of infectious diseases IJID*, 98, 328-333. <https://doi.org/10.1016/j.ijid.2020.07.004>
- Kitchin, R. (2013). "Big Data and Human Geography: Opportunities, Challenges and Risks." *Dialogues in Human Geography* 3 (3): 262-267. doi: 10.1177/2043820613513388
- Kuehn BM. (2014). Agencies use social media to track foodborne illness. *JAMA*, 312(2), 117-118. <https://doi.org/10.1001/jama.2014.7731>

- Krieger N. (2001). Theories for social epidemiology in the 21st century: an ecosocial perspective. *International journal of epidemiology*, 30(4), 668-677. <https://doi.org/10.1093/ije/30.4.668>
- Krieger, N. (2011). *Epidemiology and the people's health. Theory and context*. Oxford: Oxford University Press. ISBN-13: 9780195383874
- Krieger, N. (2009). Putting health inequities on the map: social epidemiology meets medical/health geography--an ecosocial perspective. *GeoJournal* 74, 87-97 <https://doi.org/10.1007/s10708-009-9265-x>
- Krieger, N., Waterman, PD., y Chen, JT. (2020). COVID-19 and Overall Mortality Inequities in the Surge in Death Rates by Zip Code Characteristics: Massachusetts, January 1 to May 19, 2020. *American journal of public health*, 110(12), 1850-1852. <https://doi.org/10.2105/AJPH.2020.305913>
- Kulldorff, M., Athas, WF., Feurer, EJ. et al. (1998). Evaluating cluster alarms: a space-time scan statistic and brain cancer in Los Alamos, New Mexico. *American journal of public health*, 88(9), 1377-1380.
- Kulldorff, M. (1997). A spatial scan statistic, *Communications in Statistics - Theory and Methods*, 26(6), 1481-1496, DOI: 10.1080/03610929708831995
- Laín, P. (1970) *La medicina hipocrática*. Ediciones de la revista de occidente, Madrid; España. <https://www.cervantesvirtual.com/obra/la-medicina-hipocratica-0/>
- Lalonde, M. (1981). *A new perspective on the health of Canadians. A working document*. Minister of Supply and Services Canada. <http://www.phac-aspc.gc.ca/ph-sp/pdf/perspect-eng.pdf>
- Laura-Ochoa (2019). Evaluation of Classification Algorithms using Cross Validation, *17 th LACCEI International Multi-Conference for Engineering, Education, and Technology: "Industry, Innovation, And Infrastructure for Sustainable Cities and Communities"*, 24-26 July 2019, Jamaica.
- Lehnert, E., Wilt, G., Flanagan, BE. et al. (2020) Spatial exploration of the CDC's Social Vulnerability Index and heat-related health outcomes in Georgia, *International Journal of Disaster Risk Reduction*, 46, 2212-4209, <https://doi.org/10.1016/j.ijdrr.2020.101517>
- Leonardo, L., Rivera, P., Crisostomo, B. et al. (2005). A study of the environmental determinants of malaria and schistosomiasis in the Philippines using Remote

- Sensing and Geographic Information Systems. *Parassitologia*, 47(1), 105-114.
<https://pubmed.ncbi.nlm.nih.gov/16044679>
- Liao, WB., Ju, K., Gao, YM. et al. (2020). The association between internal migration and pulmonary tuberculosis in China, 2005-2015: a spatial analysis. *Infect Dis Poverty* 9, 5. <https://doi.org/10.1186/s40249-020-0621-x>
- Lima EEC, Vilela EA, Peralta A, et al. (2021) Investigating regional excess mortality during 2020 COVID-19 pandemic in selected Latin American countries. *Genus*. 77(1):30. doi:10.1186/s41118-021-00139-1
- López, JA. (1986). Hipócrates y los escritos hipocráticos: origen de la medicina científica. Epos: *Revista De filología*, (2), 157. <https://doi.org/10.5944/epos.2.1986.9454>
- Loza, A., Wong-Chew, RM., Jiménez-Corona, ME. et al. (2023). Two-year follow-up of the COVID-19 pandemic in Mexico. *Frontiers in Public Health*, 10, 1050673.
- Lucas, A. (2022). *_amap: Another Multidimensional Analysis Package_*. R package version 0.8-19, <<https://CRAN.R-project.org/package=amap>>.
- Macharia, PM., Joseph, NK., y Okiro, EA. (2020). A vulnerability index for COVID-19: spatial analysis at the subnational level in Kenya. *BMJ Global Health* 5:e003014. <http://dx.doi.org/10.1136/bmjgh-2020-003014>
- Maharana, A., y Nsoesie, EO. (2018). Use of Deep Learning to Examine the Association of the Built Environment With Prevalence of Neighborhood Adult Obesity. *JAMA Netw Open*. 1(4):e181535. doi:10.1001/jamanetworkopen.2018.1535
- Martínez, R., Tuya, L., Martínez, M. et al. (2009). El coeficiente de correlación de los rangos de Spearman caracterización. *Revista Habanera de Ciencias Médicas*, 8(2) http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1729-519X2009000200017&lng=esytlng=es.
- Martínez, R., y Sánchez, L. (2016). Aplicaciones de los sistemas de información geográfica en la vigilancia y el control del dengue. En Guzmán M. (coord). *Dengue* (Primera edición, pp 395-410) México.
- Maskrey, A. (1998). Capítulo 1: El riesgo. En Maskrey, A. (coord). *Navegando entre brumas. La aplicación de los sistemas de información geográfica al análisis de riesgo en América Latina* (Primera edición, pp 10-29). Perú: Red de estudios sociales en prevención de desastres en América Latina

- Moreno, A. (2015). Singularidades gnoseológicas de la praxis geotecnológica en la ciencia geográfica. En Fuenzalida et al. (coord). Geografía, geotecnología y análisis espacial: tendencias, métodos y aplicaciones. (Primera edición, pp 17-30). Chile: Editorial Triangulo.
- Morales, C., Breilh, J., Passos N. et al. (2017). Tras las huellas de la determinación social de la salud. Universidad Nacional de Colombia, Sede Bogotá. https://www.researchgate.net/publication/321588829_Tras_las_huellas_de_la_determinacion_social_de_la_salud
- Munnangi, S., y Boktor, SW. (2022). Epidemiology Of Study Design. In *StatPearls*. StatPearls Publishing.
- Mcglashan, ND. (1972). Medical Geography, In N.D. Mcglashan (Ed.), *Medical Geography Techniques and Field Studies*, Londres, Methuen y Co Ltd, (pp.50-85).
- Nardo, M., y Saisana, M. (2009). OECD/JRC Handbook on constructing composite indicators. Putting theory into practice. https://knowledge4policy.ec.europa.eu/sites/default/files/jrc47008_handbook_final.pdf
- NIEHS. National Institute of Environmental Health Sciences. (2021). COVID-19 Pandemic Vulnerability Index (PVI) <https://covid19pvi.niehs.nih.gov/>
- Newton, R., Deonarine, A., y Wernisch, L. (2012). Displaying R spatial statistics on Google dynamic maps with web applications created by Rwui. *Int J Health Geogr* 11, 41. <https://doi.org/10.1186/1476-072X-11-41>
- Nutor, JJ., Duah, HO., Agbadi, P. et al. (2020). Spatial analysis of factors associated with HIV infection in Malawi: indicators for effective prevention. *BMC Public Health* 20, 1167. <https://doi.org/10.1186/s12889-020-09278-0>
- Olivas-Martínez, A., Cárdenas-Fragoso, J. L., Jiménez, J. V., et al. (2021). In-hospital mortality from severe COVID-19 in a tertiary care center in Mexico City; causes of death, risk factors and the impact of hospital saturation. *PloS one*, 16(2), e0245772. <https://doi.org/10.1371/journal.pone.0245772>
- ONU Organización de las Naciones Unidas (2022). Mitos y verdades sobre la variante Ómicron del COVID-19. <https://news.un.org/es/story/2022/01/1503042>

- ONU Organización de las Naciones Unidas (2020). Las ciudades concentran el 90% de los casos de COVID-19. <https://coronavirus.onu.org.mx/las-ciudades-concentran-el-90-de-los-casos-de-covid-19>
- OPS/OMS. Organización Panamericana de la Salud/Organización Mundial de la Salud (2021). Determinantes sociales de la salud. <https://www.paho.org/es/temas/determinantes-sociales-salud>
- OPS. Organización Panamericana de la Salud. (2021). Vivienda y Salud. <https://www.habitatmexico.org/vivienda-y-salud>
- Oracle (2021). ¿Qué es la inteligencia artificial-AI? <https://www.oracle.com/mx/artificial-intelligence/what-is-ai/>
- Ortiz-Hernández, L., y Pérez-Sastré, MA. (2020). Inequidades sociales en la progresión de la COVID-19 en población mexicana. *Pan American journal of public health*, 44, e106. <https://doi.org/10.26633/RPSP.2020.106>
- Ortiz, L., Pérez, D., y Tamez, S. (2015). Desigualdad socioeconómica y salud en México. *Rev Med Inst Mex Seguro*, 01(55), 336-347. <https://www.medigraphic.com/cgi-bin/new/resumen.cgi?IDARTICULO=58492>
- Otero, Á., y Zunzunegui, M. (2011). Determinantes sociales de la salud y su influencia en la atención sanitaria. En Martín, A., y Jodar, G. (ed) *Conceptos y materiales para docentes y estudiantes* (Primera edición, pp 87-99).
- Oviedo, M., Brito, R., Nicolino, R. et al. (2014). Spatial and statistical methodologies to determine the distribution of dengue in Brazilian municipalities and relate incidence with the Health Vulnerability Index. *Spatial and Spatio-temporal Epidemiology*, 11, 1877-5845, <https://doi.org/10.1016/j.sste.2014.04.001>
- Ozdenerol, E. (2015). GIS and Remote Sensing Use in the Exploration of Lyme Disease Epidemiology. *International journal of environmental research and public health*, 12(12), 15182-15203. <https://doi.org/10.3390/ijerph121214971>
- Palomero, J., y Alvariño, P. (2016). La importancia del higienismo y la potabilización del agua en la ciudad de valencia (1860 -1910). *Investigaciones Geográficas*, (65), 45-55. <http://dx.doi.org/10.14198/INGEO2016.65.03>
- Pandey, A., y Jain, A. (2017). Comparative analysis of KNN algorithm using various normalization techniques. *International Journal of Computer Network and Information Security*, 11(11), 36.

- Panch, T., Szolovits, P., y Atun, R. (2018). Artificial intelligence, machine learning and health systems. *Journal of global health*, 8(2), 020303. <https://doi.org/10.7189/jogh.08.020303>
- Pan-Montojo, N. (2020). De Hipócrates a la epidemiología moderna: grandes hitos de la lucha contra las enfermedades. *El ágora*. <https://www.elagoradiario.com/coronavirus/epidemias-historicas/hipocrates-epidemiologia-grandes-hitos-lucha-enfermedades/>
- Parkes, E. (2014). Mode of Communication of Cholera. By John Snow, MD. *International Journal of Epidemiology*, 42(6), 1543-1552. <https://doi.org/10.1093/ije/dyt193>
- Pérez, R. (2020) Mexico's coronavirus czar faces criticism as COVID-19 surges. Science. <https://www.science.org/content/article/mexico-s-coronavirus-czar-faces-criticism-covid-19-surges>
- Peset, J. (2018). Medicina y enfermedad en el renacimiento. Cuadernos del Marqués de San Adrián: *revista de humanidades*, (10). <https://dialnet.unirioja.es/servlet/articulo?codigo=7219313>
- Peña, J., Perdomo, M., y Cuartas E. (2013). Geografía y salud, una visión de pasado y presente. *Entorno Geográfico*, (9), 146-158. <https://doi.org/10.25100/eg.v0i9.7613>
- Pickenhayn, J. (2008). El fenómeno urbano y la reespacialización de los complejos patógenos. *Raega - O Espaço Geográfico em Análise*, (15), 19-25. DOI: 10.5380/raega.v15i0.14219
- Pizarro, R. (2001). La vulnerabilidad social y sus desafíos: una mirada desde América Latina. *Revista CEPAL*, ISSN: 1680-8770, Santiago de Chile
- Pyle, GF. (1969). The diffusion of cholera in the United States in the nineteenth century. *Geographical analysis*, 1, 59-75. <https://doi.org/10.1111/j.1538-4632.1969.tb00605.x>
- Python (2021). Acerca de Python. <https://www.python.org/doc/>
- Plasencia-Urizarri, TM, Aguilera-Rodríguez, R., y Almaguer-Mederos, LE (2020). Comorbilidades y gravedad clínica de la COVID-19: revisión sistemática y metaanálisis. *Revista Habanera de Ciencias Médicas*, 19 (1), 1-18.
- Quentin, E. (2022). Estadística aplicada a eventos de salud [apuntes de estancia doctoral virtual]. Universidad UTE, Ecuador.

- R Core Team (2023). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- R Core Team (2022). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Raví, D., Wong, C., Deligianni, F. et al. (2017). "Deep Learning for Health Informatics," in IEEE. *Journal of Biomedical and Health Informatics*, 21(1), 4-21, doi: 10.1109/JBHI.2016.2636665.
- RAE. Real Academia Española (2021). Índice. <https://dle.rae.es/%C3%ADndice>
- Readhead, A., Chang, AH., Ghosh, JK. et al. (2020). Spatial distribution of tuberculosis incidence in Los Angeles County. *BMC Public Health*, 20, 1434. <https://doi.org/10.1186/s12889-020-09523-6>
- Ressl, R., Luz Martínez, C., Piña Camacho, M., et al. (2020). Mapping Mexican COVID-19 vulnerability at municipal scale. *Terra Digitalis*, 4(2), 1-8. <https://doi.org/10.22201/igg.25940694e.2020.2.79>
- Richardson, DB., Volkow, ND., Kwan, MP., et al. (2013). Medicine. Spatial turn in health research. *Science*, 339(6126), 1390-1392. <https://doi.org/10.1126/science.1232257>
- Rodríguez, R. (2015) Precursores: Escuela Hipocrática de medicina. *Boletín CONAMED-OPS*. <https://www.gob.mx/conamed>
- Rotela, C., Aylén, D., Moral, M. et al. (2014). Introducción al uso de herramientas geoespaciales aplicadas a la Salud Pública. Ciudad Autónoma de Buenos Aires: Argentina. 1ra edición. <https://www.tandfonline.com/doi/full/10.1080/17538947.2020.1738568>
- Rosa, R. (2011). Geotecnologías en Geografía Aplicada. *Revista del Departamento de Geografía*, 16, 81-90. <https://doi.org/10.7154/RDG.2005.016.009>
- Rogers, K. (2021). Thomas Sydenham. *Britannica Encyclopaedia*. <https://www.britannica.com/biography/Thomas-Sydenham>
- Rois, R., Ray, M., Rahman, A. et al. (2021). Prevalence and predicting factors of perceived stress among Bangladeshi university students using machine learning algorithms. *J Health Popul Nutr*, 40, 50. <https://doi.org/10.1186/s41043-021-00276-5>

- Rosenthal, P.J., Breman, J.G., Djimde, A.A. et al. (2020). COVID-19: Shining the Light on Africa. *The American journal of tropical medicine and hygiene*, 102(6), 1145-1148. <https://doi.org/10.4269/ajtmh.20-0380>
- Rovetta, A. (2020) Raiders of the Lost Correlation: A Guide on Using Pearson and Spearman Coefficients to Detect Hidden Correlations in Medical Sciences. *Cureus* 12(11): e11794. doi:10.7759/cureus.11794
- Ruiz, N. (2012). La definición y medición de la vulnerabilidad social. Un enfoque normativo. *Investigaciones geográficas*, (77), 63-74.
- Rushton, G. (1998). Improving the geographic basis of health surveillance using GIS. *In GIS and Health* (pp. 81-98). CRC Press.
- Rüping, S. (2015). Big Data in Medizin und Gesundheitswesen. *Bundesgesundheitsbl.* 58, 794-798. <https://doi.org/10.1007/s00103-015-2181-y>
- SS. Secretaría de Salud (2020). 266. Arranca vacunación contra COVID-19 en México. <https://www.gob.mx/salud/prensa/266-arranca-vacunacion-contra-covid-19-en-mexico>
- SS/DGE. Secretaría de Salud/Dirección General de Epidemiología (2022). Coronavirus COVID19 Informe Técnico Semanal. <https://www.gob.mx/salud/documentos/coronavirus-covid19-informe-tecnico-semanal>
- SS/DGIS. Secretaría de Salud/Dirección General de Información en Salud (2020). Datos abiertos. http://www.dgis.salud.gob.mx/contenidos/basesdedatos/Datos_Abiertos_gobmx.html
- Saghapour, T., Corti, B., Jafari, A., et al. (2021). Supporting pandemic disease preparedness: Development of a composite index of area vulnerability, *Health y Place*, 70. <https://doi.org/10.1016/j.healthplace.2021.102629>
- Sánchez, C., Santana, G., y Santana M. (2022). Variabilidad espacial de la tasa de mortalidad de Covid-19 en México mediante la aplicación de la gwr. En Santana, M., Buzai, G., y Santana, G. (coord). Geografía de la salud en pandemia. Métodos de análisis espacial en el estudio de la COVID-19 (Primera edición, pp 33-52). Toluca, México: Universidad Autónoma del Estado de México

- Santana, P. (2014). *Introducción a la Geografía de la salud: territorio, salud y bienestar*. Traducción de la primera edición en portugués (2014) por Marcela Virginia Santana Juárez. ISBN: 978-607-00-7909-2
- Santana, M. (2009). *Condiciones geográficas y de salud de la población del Estado de México*. Tesis: Doctorado en Geografía, Universidad Nacional Autónoma de México
- Schroeder, L., Veronez, M., Souza, E. et al. (2020). "Respiratory Diseases, Malaria and Leishmaniasis: Temporal and Spatial Association with Fire Occurrences from Knowledge Discovery and Data Mining" *International Journal of Environmental Research and Public Health*, 17(10), 3718. <https://doi.org/10.3390/ijerph17103718>
- Schober, P., Boer, C., y Schwarte, LA. (2018). Correlation Coefficients: Appropriate Use and Interpretation. *Anesthesia and analgesia*, 126(5), 1763-1768. <https://doi.org/10.1213/ANE.0000000000002864>
- SEP. Secretaría de Educación Pública (2021). *Guía para el regreso responsable y ordenado a las escuelas ciclo escolar 2021-2022*. <https://coronavirus.gob.mx/wp-content/uploads/2021/08/GuiaAperturaEscolar-SEP-20agosto202119hrs.pdf>
- Seffino, M., y Etcheverría, S. (2020). *Números índice. Universidad Nacional del Centro de la Provincia de Buenos Aires. Technical Report*. <https://www.researchgate.net/publication/342420374>
- Sierra-Alcocer, R., López-Ramírez, P., y González-Farías, G. (2022). A Dynamic Social Vulnerability Index to COVID-19 in Mexico. In: Tapia-McClung, R., Sánchez-Siordia, O., González-Zuccolotto, K., Carlos-Martínez, H. (eds) *Advances in Geospatial Data Science. iGISc 2021. Lecture Notes in Geoinformation and Cartography. Springer, Cham*. https://doi.org/10.1007/978-3-030-98096-2_13
- SG. Secretaría de Gobernación (2020). *Lineamientos técnicos específicos para la reapertura de las actividades económicas*. https://www.dof.gob.mx/nota_detalle.php?codigo=5594138yfecha=29/05/2020#gsc.tab=0
- Shaw, N., y McGuire, S. (2017). Understanding the use of geographical information systems (GIS) in health informatics research: A review. *Journal of innovation in health informatics*, 24(2), 940. <https://doi.org/10.14236/jhi.v24i2.940>

- Shabbir, W., Pilz, J. y Naeem, A. (2020). A spatial-temporal study for the spread of dengue depending on climate factors in Pakistan (2006-2017). *BMC Public Health* 20, 995. <https://doi.org/10.1186/s12889-020-08846-8>
- Siordia, C., Saenz, J., y Tom, SE. (2012). An Introduction to Macro- Level Spatial Nonstationarity: a Geographically Weighted Regression Analysis of Diabetes and Poverty. *Human geographies*, 6(2), 5-13. <https://doi.org/10.5719/hgeo.2012.62.5>
- Spatial Sciences Institute (2021). Promoting human well-being. University of Southern California. <https://spatial.usc.edu/promoting-human-well-being/>
- Spielman, SE., Tuccillo, J., Folch, DC. et al. (2020). Evaluating social vulnerability indicators: criteria and their application to the Social Vulnerability Index. *Nat Hazards*, 100, 417-436. <https://doi.org/10.1007/s11069-019-03820-z>
- Suárez, M., Valdés, C., Galindo, M. et al. (2020). Índice de vulnerabilidad ante el COVID-19 en México. *Investigaciones Geográficas*, (104). <https://doi.org/10.14350/rig.60140>
- Suhr, DD. (2005). Principal component analysis vs. exploratory factor analysis. *SUGI 30 proceedings*, 203, 230.
- Sun, K., Chen, J., y Viboud, C. (2020). Early epidemiological analysis of the coronavirus disease 2019 outbreak based on crowdsourced data: a population-level observational study, *The Lancet Digital Health*, 2(4). [https://doi.org/10.1016/S2589-7500\(20\)30026-1](https://doi.org/10.1016/S2589-7500(20)30026-1).
- Szelezsán, J. (2006). La Salud, inalcanzable sin la epidemiología. *Revista Médicas UIS*, 19(3), 156. <https://dialnet.unirioja.es/servlet/articulo?codigo=6545593>
- Tavera, J. (2005). ¿En qué momento occidente se separó del islam? ¿Se repite la historia? *Escritura y Pensamiento*. 8(17), 211-222. <https://doi.org/10.15381/escrypensam.v8i17.7861>
- Tisnés, A. (2014). Espacio y salud: teoría, técnicas y conceptos. una aproximación a la evolución temporal de la geografía de la salud. *Geografia Em Questão*, 7(2), 74-99.
- Tiwari, A., Dadhania, AV., Ragunathrao, VA., y Oliveira, ER. (2021). Using machine learning to develop a novel COVID-19 Vulnerability Index (C19VI). *The Science of the total environment*, 773, 145650. <https://doi.org/10.1016/j.scitotenv.2021.145650>
- Topol, EJ. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*, 25, 44-56. <https://doi.org/10.1038/s41591-018-0300-7>

- Thatcher, E.J., Camacho, F., Anderson, R.T. et al. (2021). Spatial analysis of colorectal cancer outcomes and socioeconomic factors in Virginia. *BMC Public Health*, 21, 1908. <https://doi.org/10.1186/s12889-021-11875-6>
- UNDRO. Office of the United Nations Disaster Relief Coordinator (1979) Natural Disasters and Vulnerability Analysis. Report of Expert Group Meeting
- UNICEF. Fondo de las Naciones Unidas para la Infancia. (2021). Miles de millones de personas se quedarán sin acceso a servicios de agua potable, saneamiento e higiene antes de 2030. Comunicado de prensa. <https://www.unicef.org/es/comunicados-prensa/miles-de-millones-de-personas-se-que-dar%C3%A1n-sin-acceso-servicios-de-agua-potable>
- Urteaga, L. (1980). Miseria, miasmas y microbios. las topografías médicas y el estudio del medio ambiente en el siglo XIX. *Revista Geográfica*, cuadernos críticos de Geografía humana, (29)
- Valdés, E., y Lecaros, J. (2016) Sobre el concepto de vulnerabilidad social: Marco filosófico, ético y jurídico. En Cabieses et al. (coord). *Vulnerabilidad social y su efecto en salud en Chile*. (Primera edición, pp 43-55). Chile: Universidad del Desarrollo
- Vinnakota, S., y Lam, N.S. (2006). Socioeconomic inequality of cancer mortality in the United States: a spatial data mining approach. *Int J Health Geogr* 5, 9. <https://doi.org/10.1186/1476-072X-5-9>
- Wall, P., y Devine, O. (2000). Interactive analysis of the spatial distribution of disease using a geographic information systems. *J Geograph Syst* 2, 243-256 <https://doi.org/10.1007/PL00011457>
- Walz, Y., Wegmann, M., Dech, S. et al. (2015). Risk profiling of schistosomiasis using remote sensing: approaches, challenges and outlook. *Parasites y vectors*, 8, 163. <https://doi.org/10.1186/s13071-015-0732-6>
- Wang, R., Liu, Y., Lu, Y. et al. (2019). The linkage between the perception of neighbourhood and physical activity in Guangzhou, China: using street view imagery with deep learning techniques. *Int J Health Geogr* 18, 18, <https://doi.org/10.1186/s12942-019-0182-z>

- Wang, D., Hu, B., Hu, C. et al. (2020). Clinical Characteristics of 138 Hospitalized Patients With 2019 Novel Coronavirus-Infected Pneumonia in Wuhan, China. *JAMA*. 323(11):1061-1069. doi:10.1001/jama.2020.1585
- Weintraub, WS. (1998). Development of the American College of Cardiology National Cardiovascular Data Registry. *The Journal of invasive cardiology*, 10(8), 489-491.
- Xia, C., Bergquist, R., Lynn, H. et al. (2017). Village-based spatio-temporal cluster analysis of the schistosomiasis risk in the Poyang Lake Region, China. *Parasites Vectors* **10**, 136. <https://doi.org/10.1186/s13071-017-2059-y>
- Xing, DF., Xu, CD., Liao, XY. et al. (2019). Spatial association between outdoor air pollution and lung cancer incidence in China. *BMC Public Health* 19, 1377. <https://doi.org/10.1186/s12889-019-7740-y>
- Yang, J., Li, Y., Liu, Q. et al. (2020). Brief introduction of medical database and data mining technology in big data era. *Journal of evidence-based medicine*, 13(1), 57-69. <https://doi.org/10.1111/jebm.12373>
- Yang, C., Raskin, R., Goodchild, M., y Gahegan, M. (2010) Geospatial Cyberinfrastructure: Past, present and future, *Computers, Environment and Urban Systems*, 34(4), 264-277, <https://doi.org/10.1016/j.compenvurbsys.2010.04.001>.
- Ye, J., Yao, L., Shen, J. et al. (2020). Predicting mortality in critically ill patients with diabetes using machine learning and clinical notes. *BMC Med Inform Decis Mak*, 20, 295. <https://doi.org/10.1186/s12911-020-01318-4>
- Yedinak, J., Yu Li, Krieger, M., et al. (2021). Machine learning takes a village: Assessing neighbourhood-level vulnerability for an overdose and infectious disease outbreak, *International Journal of Drug Policy*, ISSN 0955-3959, <https://doi.org/10.1016/j.drugpo.2021.103395>.
- Zhang, Y., Liu, M., Wu, SS. et al. (2019). Spatial distribution of tuberculosis and its association with meteorological factors in mainland China. *BMC Infect Dis* 19, 379. <https://doi.org/10.1186/s12879-019-4008-1>
- Zhou, F., Yu, T., Du, R. et al. (2020). Clinical course and risk factors for mortality of adult inpatients with COVID-19 in Wuhan, China: a retrospective cohort study. *Lancet*, 395(10229), 1054-1062. [https://doi.org/10.1016/S0140-6736\(20\)30566-3](https://doi.org/10.1016/S0140-6736(20)30566-3)

Anexos

Anexo 1. México. División territorial a nivel estatal



Fuente: Elaboración propia con base en INEGI, 2020.

Anexo 2. Cálculos para obtener los indicadores del ÍEDVC19

Dimensión	Indicador (s)	Fórmula (s)
COVID-19	Tasa casos confirmados COVID-19	$100,000 * \frac{\text{Total de casos confirmados COVID – 19(mensuales)}}{\text{Población total}}$
	Tasa defunciones COVID-19	$100,000 * \frac{\text{Total de defunciones COVID – 19 (mensuales)}}{\text{Población total}}$
Estatus socioeconómico	% población en situación de pobreza	Extraído del CONEVAL, 2020.
	% población de 18+ sin educación posbásica	$100 * \frac{\text{población de 18 años y más sin educación posbásica}}{\text{población de 18 años y más}}$
	% población sin afiliación a servicios de salud	$100 * \frac{\text{población no derechohabiente a servicios de salud}}{\text{población total}}$
Características de la población	% población de 65 años y más	$100 * \frac{\text{población de 65 años y más}}{\text{población total}}$
	% población minoritaria	$\text{población minoritaria} = \text{población de 3 años y más que habla alguna lengua indígena} + \text{población afrodescendiente}$
		$100 * \frac{\text{población minoritaria}}{\text{población total}}$
	Densidad de población	$\frac{\text{población total}}{\text{superficie (kilómetros cuadrados)}}$
Condiciones de vivienda e higiene	% viviendas particulares habitadas en condición de hacinamiento	$100 * \frac{\text{VPH con más de 2.5 ocupantes por dormitorio}}{\text{Total de viviendas particulares habitadas}}$
	% viviendas particulares habitadas sin agua entubada	$100 * \frac{\text{VPH que no disponen de agua entubada}}{\text{Total de viviendas particulares habitadas}}$

Dimensión	Indicador (s)	Fórmula (s)
	% viviendas particulares habitadas sin tinaco	$100 * \frac{VPH \text{ que no disponen de tinaco}}{\text{Total de viviendas particulares habitadas}}$
Factores epidemiológicos	Tasa de egresos cardiovasculares	$100,000 * \frac{\text{Total de egresos cardiovasculares}}{\text{Población total}}$
	Tasa de egresos respiratorios	$100,000 * \frac{\text{Total de egresos respiratorios}}{\text{Población total}}$
	Tasa de egresos cáncer	$100,000 * \frac{\text{Total de egresos cáncer}}{\text{Población total}}$
	Tasa de egresos VIH	$100,000 * \frac{\text{Total de egresos VIH}}{\text{Población total}}$
	Tasa de egresos obesidad	$100,000 * \frac{\text{Total de egresos obesidad}}{\text{Población total}}$
	Tasa de egresos diabetes	$100,000 * \frac{\text{Total de egresos diabetes}}{\text{Población total}}$
	Tasa de defunciones cardiovasculares	$100,000 * \frac{\text{Total de defunciones cardiovasculares}}{\text{Población total}}$
	Tasa de defunciones respiratorias	$100,000 * \frac{\text{Total de defunciones respiratorias}}{\text{Población total}}$
	Tasa de defunciones cáncer	$100,000 * \frac{\text{Total de defunciones cáncer}}{\text{Población total}}$
	Tasa de defunciones VIH	$100,000 * \frac{\text{Total de defunciones VIH}}{\text{Población total}}$
	Tasa de defunciones obesidad	$100,000 * \frac{\text{Total de defunciones obesidad}}{\text{Población total}}$
	Tasa de defunciones diabetes	$100,000 * \frac{\text{Total de defunciones diabetes}}{\text{Población total}}$

Dimensión	Indicador (s)	Fórmula (s)
Factores del sistema de salud	Tasa de camas hospitalarias	$100,000 * \frac{\text{Total de camas hospitalarias generales}}{\text{Población total}}$
	Tasa de camas en unidades de cuidados intensivos	$100,000 * \frac{\text{Total de camas en unidades de cuidados intensivos}}{\text{Población total}}$
	Tasa de médicos generales	$100,000 * \frac{\text{Total de médicos generales}}{\text{Población total}}$
	Tasa de enfermeros generales	$100,000 * \frac{\text{Total de enfermeros generales}}{\text{Población total}}$

Fuente: Elaboración propia a partir de datos del CONEVAL (2020); INEGI (2020); SS/DGIS (2020), SS/DGE (2020-2022).

Anexo 3. Indicadores y pesos para la aplicación de la fórmula general del ÍEDVC19

Dimensión	Indicador (s)	Loading (peso/importancia)
COVID-19	Mediana de la tasa de casos confirmados COVID-19 (2020, 2021, 2022)	0.16614519
Estatus socioeconómico	% población de 18+ sin educación posbásica	0.27000922
	% población sin afiliación a servicios de salud	0.24611635
	% población minoritaria	0.23664171
	Densidad de población	0.06694032
Condiciones de vivienda e higiene	% viviendas particulares habitadas en condición de hacinamiento	0.25257844
	% viviendas particulares habitadas sin agua entubada	0.16279681
	% viviendas particulares habitadas sin tinaco	0.23804957
Factores epidemiológicos	Tasa de egresos respiratorios	0.23743126
	Tasa de egresos cáncer	0.23350038
	Tasa de egresos diabetes	0.22850978
	Tasa de defunciones cardiovasculares	0.25082017

Dimensión	Indicador (s)	Loading (peso/importancia)
Factores del sistema de salud	Tasa de defunciones respiratorias	0.24312712
	Tasa de defunciones cáncer	0.25222680
	Tasa de defunciones diabetes	0.24675522
	Tasa de camas hospitalarias	0.27252610
	Tasa de camas en unidades de cuidados intensivos	0.27263445
	Tasa de médicos generales	0.27061070

Fuente: Elaboración propia a partir de los resultados del ACP.

Anexo 4. Conglomerados espaciotemporales de casos confirmados de COVID-19 entre febrero de 2020 y diciembre 2022

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
1	Miguel Hidalgo	CDMX (8): Miguel Hidalgo, Cuauhtémoc, Venustiano Carranza, Azcapotzalco, Gustavo A. Madero, Álvaro Obregón, Benito Juárez, Iztacalco; Estado de México (1): Naucalpan de Juárez	2022/1 - 2022/8	414483	79456.38	5.47	357594.99	<0.001
2	Milpa Alta	CDMX (7): Milpa Alta, Coyoacán, Iztapalapa, La Magdalena Contreras, Tláhuac, Tlalpan, Xochimilco; Estado de México (9): Ayapango, Cocotitlán, Chalco, Juchitepec, La Paz, Tepetlixpa, Valle de Chalco Solidaridad, Temamatla, Tenango del Aire; Morelos (5): Tepoztlán, Tlalnepantla, Tlayacapan, Totolapan	2022/1 - 2022/8	339695	82817.14	4.25	227241.58	<0.001
3	San Diego de la Unión	Guanajuato (17): San Miguel de Allende, Comonfort, Doctor Mora, Dolores Hidalgo Cuna de la Independencia Nacional, Guanajuato, León, Ocampo, San Diego de la Unión, San Felipe, San José Iturbide, San Luis de la Paz, Santa Catarina, Santa Cruz de Juventino Rosas, Silao de la Victoria, Tierra Blanca, Victoria, Xichú; Querétaro (1): Querétaro; San Luis Potosí (10): San Luis Potosí, San Nicolás Tolentino, Santa María del Río, Soledad de Graciano Sánchez, Tierra Nueva, Cerro de San Pedro, Ciudad Fernández, Villa de Arriaga, Villa de Reyes, Zaragoza	2022/1 - 2022/8	230977	80617.78	2.93	94358.18	<0.001
4	Comondú	Baja California Sur (5): Comondú, Mulegé, La Paz, Los Cabos, Loreto; Chihuahua (9): Batopilas de Manuel Gómez Morín, Chínipas, Guazapares, Maguarichi, Morelos, Moris, Ocampo, Urique, Uruachi; Sinaloa (11): Ahome, Angostura, Badiraguato, Culiacán, Choix, El Fuerte, Guasave, Mocorito, Salvador Alvarado, Sinaloa, Navolato; Sonora (25): Álamos, Arivechi, Bacanora, Bácum, Cajeme, Empalme, Etchojoa, Quiriego, La Colorada, Guaymas, Hermosillo, Huatabampo, Mazatán, Navojoa, Ónavas, Rosario, San Javier, Soyopa, Suaqui Grande, San Miguel de Horcasitas, Ures, Villa Pesqueira, Yécora, Benito Juárez, San Ignacio Río Muerto	2022/1 - 2022/8	193138	74314.42	2.64	66633.92	<0.001
5	Galeana	Coahuila (2): Arteaga, Saltillo; Nuevo León (22): Allende, Apodaca, General Escobedo, General Terán, General Zaragoza, Guadalupe, Aramberri, Cadereyta Jiménez, Doctor Arroyo, Galeana, San Pedro Garza García, Hualahuises, Iturbide, Juárez, Linares, Montemorelos, Monterrey, Pesquería, Rayones, San Nicolás de los Garza, Santa Catarina,	2022/1 - 2022/8	187611	84574.99	2.25	47185.68	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		Santiago; San Luis Potosí (2): Cedral, Vanegas; Tamaulipas (2): Mainero, Villagrán; Zacatecas (2): Concepción del Oro, El Salvador						
6	Centro	Tabasco (6): Centro, Nacajuca	2022/1 - 2022/8	47262	12175.46	3.90	29099.53	<0.001
7	Valparaíso	Aguascalientes (9): Aguascalientes, Calvillo, Cosío, Jesús María, Pabellón de Arteaga, Rincón de Romos, San José de Gracia, Tepezalá, San Francisco de los Romo; Durango (7): Durango, Mezquital, Nombre de Dios, Poanas, Pueblo Nuevo, Súchil, Vicente Guerrero; Jalisco (11): Bolaños, Colotlán, Chimaltitán, Huejúcar, Huejuquilla el Alto, Mezquitic, San Martín de Bolaños, Santa María de los Ángeles, Totatiche, Villa Guerrero, Villa Hidalgo; Nayarit: Acaponeta, Huajicori, Del Nayar, Rosamorada, Ruíz, Santa María del Oro, Tepic, La Yesca; Zacatecas: Apozol, Apulco, Atolinga, Benito Juárez, Calera, Cañitas de Felipe Pescador, Cuauhtémoc, Chalchihuites, Fresnillo, Trinidad García de la Cadena, Genaro Codina, El Plateado de Joaquín Amaro, General Pánfilo Natera, Guadalupe, Huanusco, Jalpa, Jerez, Jiménez del Teul, Juan Aldama, Juchipila, Luis Moya, Mezquital del Oro, Miguel Auza, Momax, Monte Escobedo, Morelos, Nochistlán de Mejía, Ojocaliente, Pánuco, Río Grande, Sain Alto, Trancoso, General Enrique Estrada, General Francisco R. Murguía, Sombrerete, Susticacán, Tabasco, Tepechitlán, Tepetongo, Teúl de González, Ortega, Tlaltenango de Sánchez Román, Valparaíso, Vetagrande, Villanueva, Zacatecas, Santa María de la Paz	2022/1 - 2022/4	75342	28316.17	2.68	26857.98	<0.001
8	Río Lagartos	Quintana Roo (6): Cozumel, Isla Mujeres, Benito Juárez, Lázaro Cárdenas, Solidaridad, Tulum; Yucatán (75): Acanceh, Baca, Bokobá, Buctzotz, Chankom, Chemax, Cacalchén, Calotmul, Cansahcab, Cantamayec, Cenotillo, Conkal, Cuncunul, Cuzamá, Chicxulub Pueblo, Chichimilá, Chikindzonot, Chumayel, Mayapán, Mérida, Dzemul, Dzidzantún, Dzilam de Bravo, Dzilam González, Dzitás, Dzoncauich, Espita, Hocabá, Hochtún, Homún, Huhí, Ixil, Izamal, Kanasín, Kantunil, Panabá, Kua, Progreso, Mocochoá, Motul, Muxupip, Quintana Roo, Río Lagartos, Sanahcat, San Felipe, Seyé, Valladolid, Xocchel, Yaxcabá, Sinanché, Sotuta, Sucilá, Sudzal, Suma, Tahdziú,	2022/1 - 2022/8	95266	45324.71	2.12	20998.12	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		Tahmek, Tekal de Venegas, Tekantó, Tekit, Tekom, Telchac Pueblo, Telchac Puerto, Temax, Temozón, Tepakán, Teya, Tinum, Tixcacalcupul, Tixkokob, Tixpéhual, Tizimín, Tunkás, Uayma, Yaxkukul, Yobaín						
9	San Pablo Etlá	Oaxaca (7): Guadalupe Etlá, Oaxaca de Juárez, San Agustín Etlá, San Andrés Huayápam, San Jacinto Amilpas, San Pablo Etlá, Villa de Etlá	2022/1 - 2022/8	23130	4773.67	4.86	18166.47	<0.001
10	Manuel Benavides	Coahuila de Zaragoza (28): Abasolo, Acuña, Allende, Castaños, Morelos, Múzquiz, Cuatro Ciénegas, Escobedo, Francisco I. Madero, Nadadores, Frontera, Guerrero, Sacramento, San Buenaventura, San Juan de Sabinas, San Pedro, Jiménez, Juárez, Lamadrid, Monclova, Nava, Ocampo, Piedras Negras, Progreso, Sabinas, Sierra Mojada, Villa Unión, Zaragoza; Chihuahua (42): Ahumada, Aldama, Allende, Aquiles Serdán, Bachíniva, Buenaventura, Camargo, Carichí, Coronado, Coyame del Sotol, La Cruz, Cuauhtémoc, Cusihuirachi, Chihuahua, Delicias, Dr. Belisario Domínguez, Santa Isabel, Gran Morelos, Guadalupe, Hidalgo del Parral, Huejotitán, Jiménez, Julimes, López, Manuel Benavides, Matamoros, Meoqui, Namiquipa, Nonoava, Ojinaga, Praxedis G. Guerrero, Riva Palacio, Rosales, Rosario, San Francisco de Borja, San Francisco de Conchos, San Francisco del Oro, Santa Bárbara, Satevó, Saucillo, El Tule, Valle de Zaragoza; Durango (4): Hidalgo, Mapimí, Ocampo, Tlahualilo	2022/1 - 2022/8	86970	42605.97	2.05	17832.16	<0.001
11	Colima	Colima (4): Colima, Cuauhtémoc, Ixtlahuacán, Villa de Álvarez; Jalisco (1): Pihuamo	2022/1 - 2022/8	22902	5086.42	4.51	16665.87	<0.001
12	Guadalajara	Jalisco: Guadalajara	2022/1 - 2022/4	29803	9990.55	2.99	12788.50	<0.001
13	Zempoala	Hidalgo (9): Epazoyucan, Pachuca de Soto, Mineral de la Reforma, Singuilucan, Tepeapulco, Zempoala, Villa de Tezontepec, Tlanalapa, Zapotlán de Juárez; Estado de México (2): Axapusco, Nopaltepec	2022/1 - 2022/8	30206	10677.37	2.84	11909.43	<0.001
14	Papalotla de Xicohtécatl	Puebla (6): Coronango, Cuautlancingo, Puebla, Juan C. Bonilla, San Miguel Xoxtla, Tlaltenango; Tlaxcala (23): Chiautempan, Mazatecochco de José María Morelos, Xicohtzinco, Zacatelco, Acuamanala de Miguel Hidalgo, Nativitas, San Pablo del Monte, Tenancingo, Teolocholco, Tepeyanco, Tetlatlahuca, Tlaxcala, Papalotla de Xicohtécatl,	2022/1 - 2022/8	66891	35081.91	1.92	11431.32	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		La Magdalena Tlaltelulco, San Lorenzo Axocomanitla, San Damián Texóloc, San Francisco Tetlanohcan, San Jerónimo Zacualpan, San Juan Huactzinco, Santa Apolonia Teacalco, Santa Catarina Ayometla, Santa Cruz Quilehtla, Santa Isabel Xiloxotla						
15	Xalapa	Veracruz de Ignacio de la Llave (1): Xalapa	2022/1 - 2022/8	20050	7132.80	2.82	7816.54	<0.001
16	Ebano	San Luis Potosí (6): San Vicente Tancuayalab, Tamuín, Tanlajás, Tanquián de Escobedo, Ciudad Valles, Ebano; Tamaulipas (5): Altamira, Ciudad Madero, González, Tampico, El Mante; Veracruz de Ignacio de la Llave (3): Pánuco, Pueblo Viejo, El Higo	2022/1 - 2022/8	39085	20180.45	1.94	6956.38	<0.001
17	Tultitlán	Estado de México (9): Coacalco de Berriozábal, Cuautitlán, Ecatepec de Morelos, Melchor Ocampo, Tlalnepantla de Baz, Tultepec, Tultitlán, Cuautitlán Izcalli, Tonanitla	2022/1 - 2022/8	87943	59731.73	1.48	5862.86	<0.001
18	Juan Escudero	R. Guerrero: Acapulco de Juárez, Tecoaanapa, Chilpancingo de los Bravo, Juan R. Escudero, Mochitlán, Quechultenango	2021/5 - 2021/8	19870	8747.40	2.28	5188.39	<0.001
19	Cuautla	Colima (2): Manzanillo, Minatitlán; Jalisco (55): Acatlán de Juárez, Ahualulco de Mercado, Amacueca, Amatitán, Ameca, San Juanito de Escobedo, El Arenal, Atemajac de Brizuela, Atengo, Atenguillo, Atoyac, Autlán de Navarro, Ayutla, Cabo Corrientes, Casimiro Castillo, Cihuatlán, Zapotlán el Grande, Cocula, Cuautitlán de García Barragán, Cuautla, Chiquilistlán, Ejutla, Etzatlán, El Grullo, Guachinango, Hostotipaquillo, La Huerta, Jocotepec, Juchitlán, El Limón, Magdalena, Mascota, Mixtlán, Puerto Vallarta, Villa Purificación, San Marcos, San Martín Hidalgo, San Sebastián del Oeste, Sayula, Tala, Talpa de Allende, Tapalpa, Tecolotlán, Techaluta de Montenegro, Tenamaxtlán, Teuchitlán, Tolimán, Tomatlán, Tonaya, Tuxcacuesco, Unión de Tula, San Gabriel, Villa Corona, Zacoalco de Torres, Zapotitlán de Vadillo; Nayarit (6): Ahuacatlán, Amatlán de Cañas, Ixtlán del Río, Jala, San Pedro Lagunillas, Bahía de Banderas	2021/5 - 2021/8	24943	12613.39	1.98	4687.92	<0.001
20	Ixtaczoquitlán	Veracruz de Ignacio de la Llave (13): Atzacan, Córdoba, Ixtaczoquitlán, Fortín, Orizaba, Huiloapan de Cuauhtémoc, Magdalena, Naranjal, Rafael Delgado, Tequila, Río Blanco, San Andrés Tenejapan, Tlilapan	2022/1 - 2022/8	17011	8489.54	2.01	3306.64	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
21	La Unión de Isidro Montes de Oca	Guerrero: Coahuayutla de José María Izazaga, La Unión de Isidoro Montes de Oca, Zihuatanejo de Azueta; Michoacán de Ocampo: Lázaro Cárdenas	2021/5 - 2021/8	7265	2598.69	2.80	2804.06	<0.001
22	Huandacareo	Guanajuato (19): Abasolo, Acámbaro, Celaya, Cortazar, Huanímaro, Irapuato, Jaral del Progreso, Moroleón, Pénjamo, Pueblo Nuevo, Salamanca, Salvatierra, Santiago Maravatío, Tarandacuao, Tarimoro, Uriangato, Valle de Santiago, Villagrán, Yuriria; Michoacán de Ocampo (36): Acuitzio, Álvaro Obregón, Angamacutiro, Coeneo, Copándaro, Cuitzeo, Charo, Erongarícuaro, Hidalgo, Huandacareo, Huaniqueo, Huiramba, Indaparapeo, Jiménez, Lagunillas, Madero, Morelia, Nahuatzen, Numarán, Panindícuaro, Pátzcuaro, Penjamillo, Purépero, Puruándiro, Queréndaro, Quiroga, Santa Ana Maya, Chucándiro, Morelos, Tarímbaro, Tzintzuntzan, Tzitzio, Zacapu, Zináparo, Zinapécuaro, José Sixto Verduzco	2022/1 - 2022/8	72699	57863.66	1.26	1772.68	<0.001
23	Nopala de Villagrán	Hidalgo (7): Alfajayucan, Chapantongo, Huichapan, Nopala de Villagrán, Tecozautla, Tepetitlán, Tula de Allende; Estado de México (6): Acambay de Ruíz Castañeda, Aculco, Jilotepec, Polotitlán, Timilpan, Soyaniquilpan de Juárez; Querétaro (1): San Juan del Río	2022/1 - 2022/4	8410	5176.90	1.63	848.28	<0.001
24	Poza Rica de Hidalgo	Veracruz de Ignacio de la Llave: Poza Rica de Hidalgo	2022/1 - 2022/8	5180	2766.17	1.87	836.20	<0.001
25	San Francisco Ixhuatán	Chiapas (1): Arriaga; Oaxaca (24): Asunción Ixtaltepec, El Barrio de la Soledad, Ciudad Ixtepec, Chahuites, El Espinal, Juchitán de Zaragoza, Santo Domingo Chihuitán, Santiago Niltepec, Reforma de Pineda, Salina Cruz, San Blas Atempa, San Dionisio del Mar, San Francisco Ixhuatán, San Francisco del Mar, San Mateo del Mar, San Miguel Chimalapa, San Pedro Comitancillo, San Pedro Huilotepec, San Pedro Tapanatepec, Santa María Chimalapa, Santa María Xadani, Santo Domingo Ingenio, Santo Domingo Zanatepec, Unión Hidalgo	2022/1 - 2022/8	8439	5919.17	1.43	473.65	<0.001
26	General Canuto A. Neri	Guerrero (26): Ajuchitlán del Progreso, Apaxtla, Arcelia, Buenavista de Cuéllar, Cocula, Coyuca de Catalán, San Miguel Totolapan, Taxco de Alarcón, Teloloapan, Tepecoacuilco de Trujano, Tetipac, Tlalchapa, Tlapehuala, Eduardo Neri, Cuetzala del Progreso, Cutzamala de Pinzón, General Canuto A. Neri, General Heliodoro Castillo, Huitzuc de los Figueroa,	2022/1 - 2022/4	35718	31371.75	1.14	289.36	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		Iguala de la Independencia, Ixcateopan de Cuauhtémoc, Leonardo Bravo, Mártir de Cuilapan, Pedro Ascencio Alquisiras, Pilcaya, Pungarabato; Estado de México (42): Almoloya de Alquisiras, Almoloya del Río, Amanalco, Amatepec, Atizapán, Calimaya, Capulhuac, Coatepec Harinas, Chapultepec, Donato Guerra, Ixtapan de la Sal, Ixtapan del Oro, Joquicingo, Malinalco, Rayón, San Antonio la Isla, Metepec, Texcaltitlán, Mexicaltzingo, Ocuilan, Oztoloapan, Tlatlaya, Toluca, Tonatico, Valle de Bravo, Villa de Allende, Villa Guerrero, Zacazonapan, Zacualpan, Zinacantepec, Zumpahuacán, San Mateo Atenco, San Simón de Guerrero, Santo Tomás, Sultepec, Tejupilco, Luvianos, Temascaltepec, Tenancingo, Tenango del Valle, Texcalyacac, Tianguistenco; Michoacán de Ocampo (6): Huetamo, Juárez, San Lucas, Susupuato, Tiquicheo de Nicolás Romero, Tuzantla; Morelos (15): Amacuzac, Coatlán del Río, Cuernavaca, Emiliano Zapata, Jiutepec, Jojutla, Mazatepec, Miacatlán, Puente de Ixtla, Temixco, Tetecala, Tlaltizapán de Zapata, Tlaquiltenango, Xochitepec, Zacatepec						
27	San Mateo Nejápam	Guerrero (4): Alpoyeca, Tlapa de Comonfort, Huamuxtitlán, Tlalixtaquilla de Maldonado; Oaxaca (9): Calihualá, San Andrés Tepetlapa, San Juan Ihualtepec, San Juan Bautista, Tlachichilco, San Mateo Nejápam, San Miguel Ahuehuetitlán, Santiago Tamazola, Santiago Yucuyachi, Zapotitlán Lagunas	2022/1 - 2022/4	1044	682.45	1.53	82.29	<0.001

Notas: Obs: Número de casos observados en el conglomerado; Esp: Número de casos esperados en el conglomerado; RR: Riesgo relativo; RPL: Relación de probabilidad logarítmica
Fuente: Elaboración propia a partir de los resultados de análisis espaciotemporal.

Anexo 5. Conglomerados espaciotemporales de defunciones de COVID-19 entre marzo de 2020 y diciembre 2022

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
1	Cuauhtémoc	CDMX (8): Azcapotzalco, Coyoacán, Gustavo A. Madero, Iztacalco, Benito Juárez, Cuauhtémoc, Miguel Hidalgo, Venustiano Carranza	2020/9 - 2021/4	13144	3744.72	3.61	7240.81	<0.001
2	Axochiapan	CDMX (1): Milpa Alta; Guerrero (6): Atenango del Río, Buenavista de Cuéllar, Copalillo, Xochihuehuetlán, Huitzuco de los Figueroa, Olinalá; Estado de México (12): Amecameca, Atlautla, Ayapango, Cocotitlán, Chalco, Ecatingo, Juchitepec, Tepetlixpa, Ozumba, Tlalmanalco, Temamatla, Tenango del Aire; Morelos (33): Amacuzac, Atlatláhuacan, Axochiapan, Ayala, Coatlán del Río, Cuautla, Cuernavaca, Emiliano Zapata, Huitzilac, Jantetelco, Jiutepec, Jojutla, Jonacatepec de Leandro Valle, Mazatepec, Miacatlán, Ocuilco, Puente de Ixtla, Temixco, Tepalcingo, Tepoztlán, Tetecala, Tetela del Volcán, Tlalnepantla, Tlaltizapán de Zapata, Tlaquiltenango, Tlayacapan, Totolapan, Xochitepec, Yautepec, Yecapixtla, Zacatepec, Zacualpan de Amilpas, Temoac; Puebla (60): Acatlán, Acteopan, Ahuatlán, Ahuehuetitla, Albino Zertuche, Atlixco, Atzala, Atzitzihuacán, Calpan, Chila de la Sal, Chinantla, Coatzingo, Cohetzala, Cohuecan, Domingo Arenas, Epatlán, Cuayuca de Andrade, Chiautla, Chiautzingo, Chietla, Huaquechula, Huatlatlauca, Huehuetlán el Chico, Huejotzingo, Nealtican, Ocoyucan, Piaxtla, Puebla, Ixcamilpa de Guerrero, Izúcar de Matamoros, Jolalpan, San Pedro Cholula, Juan C. Bonilla, Xicotlán, La Magdalena Tlatlauquitepec, Xochiltepec, Zacapala, San Andrés Cholula, San Diego la Mesa Tochimiltzingo, San Gregorio Atzompa, San Jerónimo Tecuanipan, San Martín Totoltepec, San Nicolás de los Ranchos, San Pablo Anicano, Santa Catarina Tlaltempan, Santa Inés Ahuatempan, Santa Isabel Cholula, Huehuetlán el Grande, Tecamatlán, Tehuitzingo, Teopantlán, Teotlalco, Tepemaxalco, Tepeojuma, Tepexco, Tianguismanalco, Tilapa, Tlapanalá, Tochimilco, Tulcingo	2021/1 - 2021/4	6620	2230.96	3.01	2840.71	<0.001
3	Tultitlán	Estado de México (13): Atizapán de Zaragoza, Coacalco de Berriozábal, Cuautitlán, Ecatepec de Morelos, Jaltenco, Melchor Ocampo, Teoloyucan, Nextlalpan, Tlalnepantla de Baz, Tultepec, Tultitlán, Cuautitlán Izcalli, Tonanitla	2020/9 - 2021/4	9251	4000.21	2.35	2547.48	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
4	Ocoyoacac	CDMX (4): Cuajimalpa de Morelos, La Magdalena Contreras, Álvaro Obregón, Tlalpan; Estado de México (21): Almoloya del Río, Atizapán, Calimaya, Capulhuac, Chapultepec, Huixquilucan, Xalatlaco, Joquicingo, Lerma, Rayón, San Antonio la Isla, Metepec, Mexicaltzingo, Naucalpan de Juárez, Ocoyoacac, Otzolotepec, Toluca, Xonacatlán, San Mateo Atenco, Texcalyacac, Tianguistenco	2020/9 - 2021/4	9387	4181.70	2.28	2426.76	<0.001
5	La Paz	CDMX (2): Iztapalapa, Tláhuac; Estado de México (5): Chicoloapan, Chimalhuacán, La Paz, Nezahualcóyotl, Valle de Chalco Solidaridad	2020/9 - 2021/4	8814	4117.15	2.17	2046.08	<0.001
6	Coyame del Sotol	Coahuila de Zaragoza (27): Abasolo, Acuña, Allende, Morelos, Múzquiz, Cuatro Ciénegas, Escobedo, Francisco I. Madero, Nadadores, Frontera, Guerrero, Sacramento, San Buenaventura, San Juan de Sabinas, San Pedro, Jiménez, Juárez, Lamadrid, Monclova, Nava, Ocampo, Piedras Negras, Progreso, Sabinas, Sierra Mojada, Villa Unión, Zaragoza; Chihuahua (67): Ahumada, Aldama, Allende, Aquiles Serdán, Ascensión, Bachíniva, Balleza, Batopilas de Manuel Gómez Morín, Bocoyna, Buenaventura, Camargo, Carichí, Casas Grandes, Coronado, Coyame del Sotol, La Cruz, Cuauhtémoc, Cusihuiriaci, Chihuahua, Chínipas, Delicias, Dr. Belisario Domínguez, Galeana, Santa Isabel, Gómez Farías, Gran Morelos, Guachochi, Guadalupe, Guadalupe y Calvo, Guazapares, Guerrero, Hidalgo del Parral, Huejotitán, Ignacio Zaragoza, Janos, Jiménez, Juárez, Julimes, López, Madera, Maguarichi, Manuel Benavides, Matachí, Matamoros, Meoqui, Morelos, Moris, Namiquipa, Nonoava, Nuevo Casas Grandes, Ocampo, Ojinaga, Praxedis G. Guerrero, Riva Palacio, Rosales, Rosario, San Francisco de Borja, San Francisco de Conchos, San Francisco del Oro, Santa Bárbara, Satevó, Saucillo, Temósachic, El Tule, Urique, Uruachi, Valle de Zaragoza; Durango (13): Gómez Palacio, Guanaceví, Hidalgo, Indé, Lerdo, Mapimí, Ocampo, El Oro, San Bernardo, Tepehuanes, San Luis del Cordero, San Pedro del Gallo, Tlahualilo; Sinaloa (1): Choix; Sonora (36): Aconchi, Agua Prieta, Álamos, Arivechi, Arizpe, Bacanora, Bacerac, Bacoachi, Banámichi, Baviácora, Bavispe, Cananea, Cumpas, Divisaderos, Quiriego, Fronteras, Granados, Huachinera, Huásabas, Huépac, Mazatán, Moctezuma, Naco, Nacori Chico, Nacozari de García, Rosario, Sahuaripa, San Felipe	2020/9 - 2020/12	5943	2306.91	2.60	2007.98	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		de Jesús, Soyopa, Suaqui Grande, Tepache, San Pedro de la Cueva, Ures, Villa Hidalgo, Villa Pesqueira, Yécora						
7	Guadalajara	Jalisco (1): Guadalajara	2020/9 - 2021/4	3690	1162.65	3.20	1744.03	<0.001
8	Ocampo	Aguascalientes (3): Aguascalientes, Asientos, El Llano; Guanajuato (10): Dolores Hidalgo Cuna de la Independencia Nacional, Guanajuato, León, Ocampo, Purísima del Rincón, Romita, San Diego de la Unión, San Felipe, San Francisco del Rincón, Silao de la Victoria; Jalisco(6):Encarnación de Díaz, Lagos de Moreno, Ojuelos de Jalisco, San Diego de Alejandría, San Juan de los Lagos, Unión de San Antonio; San Luis Potosí (4):San Luis Potosí, Mexquitic de Carmona, Villa de Arriaga, Villa de Reyes; Zacatecas (3): Loreto, Pinos, Villa García	2020/9 - 2021/4	8800	4393.72	2.03	1735.83	<0.001
9	Guadalupe	Nuevo León (3): Guadalupe, Monterrey, San Nicolás de los Garza	2020/9 - 2021/4	4423	1844.57	2.42	1299.92	<0.001
10	Pacula	Guanajuato (7): Atarjea, Doctor Mora, San José Iturbide, Santa Catarina, Tierra Blanca, Victoria, Xichú; Hidalgo (63): Actopan, Agua Blanca de Iturbide, Ajacuba, Alfajayucan, El Arenal, Atitalaquia, Atlapexco, Atotonilco el Grande, Atotonilco de Tula, Calnali, Cardonal, Chapantongo, Chapulhuacán, Chilcuautla, Francisco I. Madero, Huasca de Ocampo, Huautla, Huazalingo, Huejutla de Reyes, Huichapan, Ixmiquilpan, Jacala de Ledezma, Jaltocán, Juárez Hidalgo, Lolotla, San Agustín Metzquitlán, Metzquitlán, Mineral del Chico, Mineral del Monte, La Misión, Mixquiahuala de Juárez, Molango de Escamilla, Nicolás Flores, Nopala de Villagrán, Omitlán de Juárez, San Felipe Orizatlán, Pacula, Pachuca de Soto, Pisaflores, Progreso de Obregón, Mineral de la Reforma, San Agustín Tlaxiaca, San Salvador, Santiago de Anaya, Tasquillo, Tecozautla, Tepehuacán de Guerrero, Tepeji del Río de Ocampo, Tepetitlán, Zimapán, Tetepango, Tezontepec de Aldama, Tianguistengo, Tlahuelilpan, Tlahuiltepa, Tlanchinol, Tlaxcoapan, Tula de Allende, Xochiatipan, Xochicoatlán, Yahualica, Zacualtipán de Ángeles, Zapotlán de Juárez; Estado de México (6): Aculco, Apaxco, Hueypoxtla, Jilotepec, Polotitlán, Soyaniquilpan de Juárez; Querétaro (15): Pinal de Amoles, Arroyo Seco, Cadereyta de Montes, Colón, Ezequiel Montes, Jalpan de Serra, Landa de Matamoros, El Marqués, Pedro Escobedo, Peñamiller,	2020/9 - 2021/4	7266	3882.37	1.89	1187.97	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		Querétaro, San Joaquín, San Juan del Río, Tequisquiapan, Tolimán; San Luis Potosí (21): Aquismón, Cárdenas, San Antonio, San Cirilo de Acosta, San Martín Chalchicuautla, Santa Catarina, San Vicente Tancuayalab, Tamasopo, Tamazunchale, Tampacán, Tampamolón Corona, Tanlajás, Tanquián de Escobedo, Tancanhuitz, Coxcatlán, Huehuetlán, Lagunillas, Rayón, Matlapa, Axtla de Terrazas, Xilitla; Veracruz de Ignacio de la Llave (10): Benito Juárez, Chalma, Chiconamel, Huayacocotla, Iamatlán, Platón Sánchez, Tempoal, Texcatepec, Zacualpan, Zontecomatlán de López y Fuentes						
11	Pajapan	Chiapas (10): Pichucalco, Cintalapa, Copainalá, Chapultenango, Francisco León, Ixtacomitán, Juárez, Ostuacán, Reforma, Tecpatán; Oaxaca (51): Asunción Ixtaltepec, Ayotzintepec, El Barrio de la Soledad, Ciudad Ixtepec, San Andrés Solaga, El Espinal, Tamazulápam del Espíritu Santo, Guevea de Humboldt, Villa Hidalgo, Ixtlán de Juárez, Loma Bonita, Santo Domingo Chihuitán, Matías Romero Avendaño, Mixistlán de la Reforma, Santiago Niltepec, San Baltazar Yatzachi el Bajo, San Bartolomé Zoogocho, San Juan Lalana, San Ildefonso Villa Alta, San José Chiltepec, San Juan Guichicovi, San Juan Bautista Tuxtepec, San Juan Cotzocón, San Juan Juquila Mixes, San Juan Mazatlán, San Juan Yaeé, Santiago Yaveo, San Lucas Ojitlán, San Miguel Chimalapa, San Miguel Soyaltepec, Villa Talea de Castro, Santa María Alotepec, Santa María Temaxcalapa, Santa María Tlahuitoltepec, Santa María Chimalapa, Santa María Guienagati, Santa María Jacatepec, Santa María Petapa, Santiago Camotlán, Santiago Lalopa, Santiago Atitlán, Santiago Choápam, Santiago Ixcuintepec, Santiago Jocotepec, Santiago Lachiguiri, Santiago Laollaga, Santo Domingo Ingenio, Santo Domingo Petapa, Totontepec Villa de Morelos, San Juan Bautista Valle Nacional, Unión Hidalgo; Tabasco (9): Cárdenas, Centro, Comalcalco, Cunduacán, Huimanguillo, Jalpa de Méndez, Nacajuca, Paraíso, Teapa; Veracruz de Ignacio de la Llave (57): Acayucan, Acula, Alvarado, Amatitlán, Angel R. Cabada, Boca del Río, Catemaco, Coatzacoalcos, Cosamaloapan de Carpio, Cosoleacaque, Cotaxtla, Chacaltianguis, Chinameca, Las Choapas, Isla, Ixhuatlán del Sureste, Ixmatlahuacan, Hidalgotitlán, Hueyapan de Ocampo, Jáltipan, Jamapa, Jesús Carranza, Juan Rodríguez	2020/3 - 2020/8	5574	2744.29	2.05	1132.20	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		Clara, Lerdo de Tejada, Ignacio de la Llave, Mecayapan, Medellín de Bravo, Moloacán, Otatitlán, Oteapan, Pajapan, Playa Vicente, Minatitlán, Oluta, Saltabarranca, José Azueta, Texistepec, Tierra Blanca, Tlacojalpan, San Andrés Tuxtla, San Juan Evangelista, Santiago Tuxtla, Sayula de Alemán, Soconusco, Soteapan, Tlacotalpan, Tlalixcoyan, Zaragoza, Agua Dulce, Tuxtilla, Veracruz, Nanchital de Lázaro Cárdenas del Río, Tres Valles, Carlos A. Carrillo, Tatahuicapan de Juárez, Uxpanapa, Santiago Sochiapan						
12	Mexicali	Baja California (5): Ensenada, Mexicali, Tecate, Tijuana, Playas de Rosarito; Sonora (17): Altar, Benjamín Hill, Caborca, Carbó, Puerto Peñasco, Cucurpe, Imuris, Magdalena, Nogales, Opodepe, Oquitoa, Pitiquito, San Luis Río Colorado, Trincheras, Santa Ana, Sáric, General Plutarco Elías Calles	2020/3 - 2020/12	7911	4457.06	1.79	1103.44	<0.001
13	Súchil	Coahuila de Zaragoza (1): Torreón; Durango (21): Canatlán, Coneto de Comonfort, Cuencamé, Durango, General Simón Bolívar, Guadalupe, Victoria, Mezquital, Nazas, Nombre de Dios, Pánuco de Coronado, Peñón Blanco, Poanas, Pueblo Nuevo, Rodeo, San Dimas, San Juan de Guadalupe, San Juan del Río, Súchil, Santa Clara, Vicente Guerrero, Nuevo Ideal; Jalisco (10): Bolaños, Colotlán, Chimaltitán, Huejúcar, Huejuquilla el Alto, Mezquitic, San Martín de Bolaños, Santa María de los Ángeles, Totatiche, Villa Guerrero; Nayarit (8): Acaponeta, Huajicori, Del Nayar, Rosamorada, Ruíz, Tecuala, Tuxpan, La Yesca; Sinaloa (3): Concordia, Escuinapa, Rosario; Zacatecas (32): Atolinga, Calera, Cañitas de Felipe Pescador, Cuauhtémoc, Chalchihuites, Fresnillo, Genaro Codina, El Plateado de Joaquín Amaro, Guadalupe, Jerez, Jiménez del Teul, Juan Aldama, Miguel Auza, Momax, Monte Escobedo, Morelos, Pánuco, Río Grande, Sain Alto, Trancoso, General Enrique Estrada, General Francisco R. Murguía, Sombrerete, Susticacán, Tabasco, Tepetongo, Tlaltenango de Sánchez Román, Valparaíso, Vetagrande, Villa de Cos, Villanueva, Zacatecas	2020/9 - 2020/12	3039	1378.16	2.22	746.53	<0.001
14	Morelia	Guanajuato (24): Abasolo, Acámbaro, Apaseo el Alto, Celaya, Coroneo, Cortazar, Cuerámbaro, Huanímaro, Irapuato, Jaral del Progreso, Jerécuaro, Moroleón, Pénjamo, Pueblo Nuevo, Salamanca, Salvatierra, Santa Cruz de Juventino Rosas, Santiago Maravatío, Tarandacuao, Tarimoro, Uriangato, Valle de	2021/1 - 2021/4	4488	2392.55	1.89	734.41	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		Santiago, Villagrán, Yuriria; Estado de México (1): Ixtapan del Oro; Michoacán de Ocampo (77): Acuitzio, Álvaro, Obregón, Angamacutiro, Angangueo, Aporo, Ario, Carácuaro, Coeneo, Copándaro, Cuitzeo, Charapan, Charo, Erongarícuaro, Gabriel Zamora, Hidalgo, La Huacana, Huandacareo, Huaniqueo, Huetamo, Huiramba, Indaparapeo, Irimbo, Jacona, Jiménez, Juárez, Jungapeo, Lagunillas, Madero, Maravatío, Morelia, Nahuatzen, Nocupétaro, Nuevo Parangaricutiro, Nuevo Urecho, Numarán, Ocampo, Panindícuaro, Paracho, Pátzcuaro, Penjamillo, La Piedad, Purépero, Puruándiro, Queréndaro, Quiroga, Santa Ana Maya, Salvador Escalante, Senguio, Susupuato, Tacámbaro, Tangancícuaro, Cherán, Chilchota, Chucándiro, Churintzio, Churumuco, Ecuandureo, Morelos, Taretan, Tarímbaro, Tingambato, Tiquicheo de Nicolás Romero, Tlalpujahuá, Tlazazalca, Turicato, Tuxpan, Tuzantla, Tzintzuntzan, Tzitzio, Uruapan, Zacapu, Zamora, Zináparo, Zinapécuaro, Ziracuaretiro, Zitácuaro, José Sixto Verduzco						
15	Hopelchén	Campeche (11): Calkiní, Campeche, Carmen, Champotón, Hecelchakán, Hopelchén, Palizada, Tenabo, Escárcega, Calakmul, Candelaria; Chiapas (3): Catazajá, La Libertad, Palenque; Quintana Roo (10): Cozumel, Felipe Carrillo Puerto, Isla Mujeres, Othón P. Blanco, Benito Juárez, José María Morelos, Lázaro Cárdenas, Solidaridad, Tulum, Bacalar; Tabasco (6): Balancán, Centla, Emiliano Zapata, Jonuta, Macuspana, Tenosique; Yucatán (105): Abalá, Acanceh, Akil, Baca, Bokobá, Buctzotz, Chacsinkín, Chankom, Chapab, Chemax, Cacalchén, Calotmul, Cansahcab, Cantamayec, Celestún, Cenotillo, Conkal, Cuncunul, Cuzamá, Chicxulub Pueblo, Chichimilá, Chikindzonot, Chocholá, Chumayel, Mayapán, Mérida, Dzán, Dzemul, Dzidzantún, Dzilam de Bravo, Dzilam González, Dzitás, Dzoncauich, Espita, Halachó, Hocabá, Hoctún, Homún, Huhí, Hunucmá, Ixil, Izamal, Kanasín, Kantunil, Opichén, Oxkutzcab, Panabá, Peto, Kaua, Progreso, Kinchil, Kopomá, Mama, Maní, Maxcanú, Mocochoá, Motul, Muna, Muxupip, Quintana Roo, Río Lagartos, Sacalum, Sanahcat, San Felipe, Samahil, Santa Elena, Seyé, Ucu, Umán, Valladolid, Xocchel, Yaxcabá, Sinanché, Sotuta, Sucilá, Sudzal, Suma, Tahmek, Teabo, Tecoh, Tekal de Venegas, Tekantó, Tekax, Tekit, Tekom, Telchac Pueblo, Telchac	2020/3 - 2020/8	4976	2946.58	1.70	584.20	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		Puerto, Temax, Temozón, Tepakán, Tetiz, Teya, Ticul, Timucuy, Tinum, Tixcacalcupul, Tixkokob, Tixmehuac, Tixpéhual, Tizimín, Tunkás, Tzucacab, Uayma, Yaxkukul, Yobaín						
16	Tomatlán	Colima (9): Armería, Colima, Comala, Coquimatlán, Cuauhtémoc, Manzanillo, Minatitlán, Tecomán, Villa de Álvarez; Jalisco (59): Acatlán de Juárez, Ahualulco de Mercado, Amacueca, Amatitán, Ameca, San Juanito de Escobedo, El Arenal, Atemajac de Brizuela, Atengo, Atenguillo, Atoyac, Autlán de Navarro, Ayutla, Cabo Corrientes, Casimiro Castillo, Cihuatlán, Zapotlán el Grande, Cocula, Cuautitlán de García Barragán, Cuautla, Chiquilistlán, Ejutla, Etzatlán, El Grullo, Guachinango, Hostotipaquillo, La Huerta, Jocotepec, Juchitlán, El Limón, Magdalena, Mascota, Mixtlán, Puerto Vallarta, Villa Purificación, San Marcos, San Martín Hidalgo, Gómez Farías, San Sebastián del Oeste, Sayula, Tala, Talpa de Allende, Tapalpa, Tecolotlán, Techaluta de Montenegro, Tenamaxtlán, Teocuitatlán de Corona, Teuchitlán, Tolimán, Tomatlán, Tonaya, Tonila, Tuxcacuesco, Tuxpan, Unión de Tula, San Gabriel, Villa Corona, Zacoalco de Torres, Zapotitlán de Vadillo; Nayarit (11): Ahuacatlán, Amatlán de Cañas, Compostela, Ixtlán del Río, Jala, Xalisco, San Blas, San Pedro Lagunillas, Santa María del Oro, Tepic, Bahía de Banderas	2021/1 - 2021/8	3410	2215.48	1.54	278.19	<0.001
17	Zacapoaxtla	Hidalgo (13): Acatlán, Acaxochitlán, Almoloya, Apan, Cuauhtémoc de Hinojosa, Huehuetla, Metepec, San Bartolo Tutotepec, Santiago Tulantepec de Lugo Guerrero, Singuilucan, Tenango de Doria, Tepeapulco, Tulancingo de Bravo; Puebla (84): Acajete, Acateno, Acatzingo, Ahuacatlán, Ahuazotepec, Aljojuca, Amixtlán, Aquixtla, Atempan, Ayotoxco de Guerrero, Chignahuapan, Caxhuacan, Chignautla, Honey, Chilchotla, Coatepec, Cuautempan, Cuetzalan del Progreso, Cuyoaco, Chalchicomula de Sesma, Chiconcuautla, Chichiquila, Francisco Z. Mena, General Felipe Ángeles, Guadalupe Victoria, Hermenegildo Galeana, Huauchinango, Huehuetla, Hueyapan, Hueytamalco, Hueytlalpan, Huitzilán de Serdán, Naupan, Nauzontla, Nopalucan, Ocotepec, Olintla, Oriental, Pahuatlán, Pantepec, Quimixtlán, Ixtacamaxitlán, Ixtepec, Jalpan, Jonotla, Jopala, San Salvador el Seco, Juan Galindo, Lafragua, Libres, Xiutetelco, Mazapiltepec de Juárez, Xochiapulco, Xochitlán de	2021/1 - 2021/4	3065	1944.91	1.58	275.88	<0.001

No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value	
		Vicente Suárez, Yaonáhuac, Zacapoaxtla, Zacatlán, Rafael Lara Grajales, Zapotitlán de Méndez, Zaragoza, Zautla, Zihuateutla, San Felipe Tepatlán, San José Chiapa, San Juan Atenco, San Nicolás Buenos Aires, Soltepec, Tenampulco, Tepango de Rodríguez, Tepatlaxco de Hidalgo, Tepeaca, Tepeyahualco, Tetela de Ocampo, Teteles de Ávila Castillo, Teziutlán, Tlacuilotepec, Tlachichuca, Tlaola, Tlapacoya, Tlatlauquitepec, Tlaxco, Tuzamapan de Galeana, Venustiano Carranza, Xicoteppec; Tlaxcala (50): Amaxac de Guerrero, Apetatitlán de Antonio Carvajal, Atlangatepec, Atltzayanca, Apizaco, El Carmen Tequexquitla, Cuapiaxtla, Cuaxomulco, Chiautempan, Muñoz de Domingo Arenas, Huamantla, Hueyotlipan, Ixtacuixtla de Mariano Matamoros, Ixtenco, Mazatecochco de José María Morelos, Contla de Juan Cuamatzi, Yauhquemehcan, Sanctórum de Lázaro Cárdenas, Acuamanala de Miguel Hidalgo, Panotla, San Pablo del Monte, Santa Cruz Tlaxcala, Teolocholco, Tepeyanco, Terrenate, Tetla de la Solidaridad, Tlaxcala, Tlaxco, Tocatlán, Totolac, Ziltlaltépec de Trinidad Sánchez Santos, Tzompantepec, Xaloztoc, Xaltocan, Papalotla de Xicohténcatl, Benito Juárez, Emiliano Zapata, Lázaro Cárdenas, La Magdalena Tlaltelulco, San Lorenzo Axocomanitla, San Lucas Tecopilco, San Damián Texóloc, San Francisco Tetlanohcan, San Jerónimo Zacualpan, San José Teacalco, San Juan Huactzinco, Santa Ana Nopalucan, Santa Catarina Ayometla, Santa Cruz Quilehltla, Santa Isabel Xiloxotla; Veracruz de Igancio de la Llave (52): Acajete, Acatlán, Altotonga, Atzalan, Ayahualulco, Banderilla, Calcahualco, Coacoatzintla, Coahuatlán, Coatepec, Coatzintla, Colipa, Cosautlán de Carvajal, Coxquihui, Coyutla, Chiconquiaco, Ixhuacán de los Reyes, Jalacingo, Xalapa, Espinal, Filomeno Mata, Gutiérrez Zamora, Xico, Jilotepec, Juchique de Ferrer, Landero y Coss, Martínez de la Torre, Mecatlán, Miahuatlán, Misantla, Naolinco, Nautla, Papantla, Perote, Poza Rica de Hidalgo, Las Vigas de Ramírez, Rafael Lucio, Tenochtitlán, Teocelo, Tepetlán, Tihuatlán, Castillo de Teayo, Tecolutla, Tlacolulan, Tlalnelhuayocan, Tlapacoyan, Yecuatla, Zozocolco de Hidalgo, Tonayán, Totutla, Villa Aldama, San Rafael							

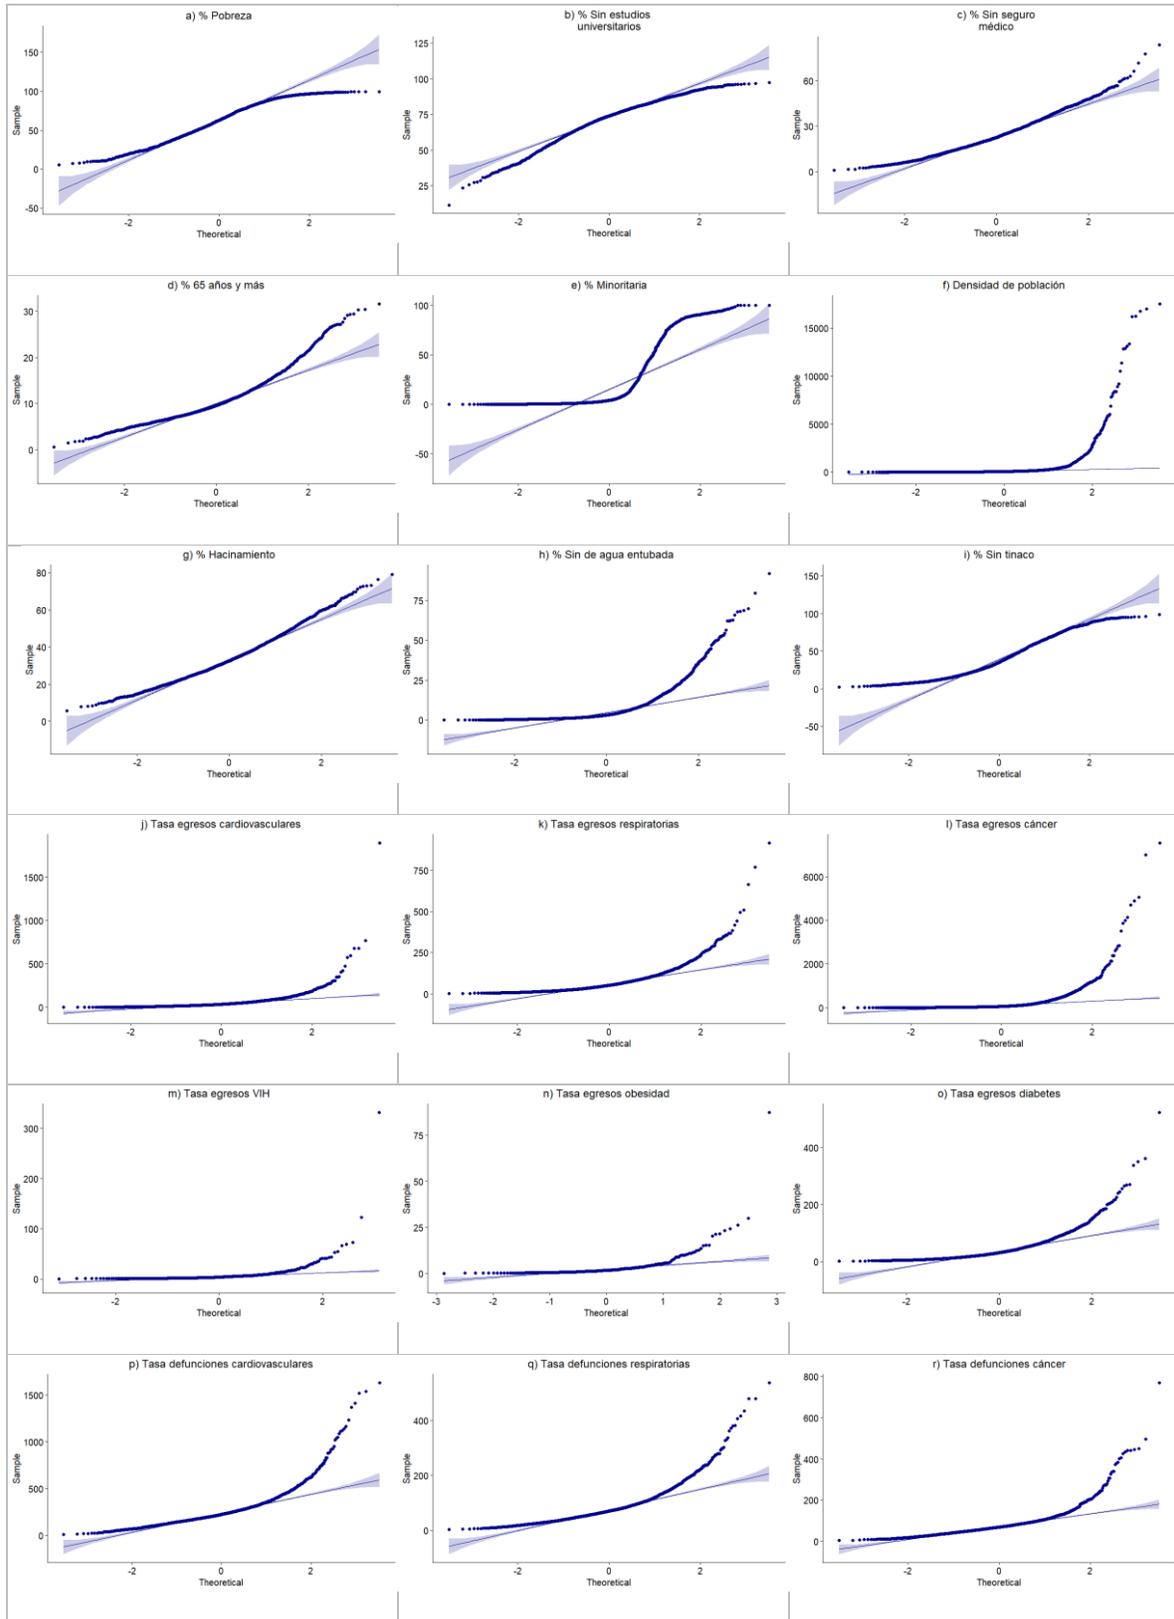
No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
18	Santa Catarina Quiané	Oaxaca (118): Santa Cruz Papalutla, Asunción Ocotlán, Coatecas Altas, Ciénega de Zimatlán, La Compañía, Cuilápam de Guerrero, Heroica Ciudad de Ejutla de Crespo, Guadalupe Etla, Magdalena Teitipac, Magdalena Apasco, Monjas, Nazareno Etla, La Pe, Oaxaca de Juárez, Ocotlán de Morelos, San José del Progreso, Reyes Etla, Rojas de Cuauhtémoc, San Agustín Etla, San Agustín de las Juntas, San Agustín Yatareni, San Andrés Huayápam, San Andrés Ixtlahuaca, San Andrés Nuxiño, San Baltazar Chichicápam, San Andrés Zautla, San Dionisio Ocotepec, San Antonino Castillo Velasco, San Antonino el Alto, San Antonio de la Cal, San Antonio Huitepec, San Bartolo Coyotepec, San Bernardo Mixtepec, San Dionisio Ocotlán, San Felipe Tejalápam, San Francisco Lachigoló, San Francisco Sola, San Francisco Telixtlahuaca, San Jacinto Amilpas, Ánimas Trujano, San Juan Bautista Guelache, San Juan Guelavía, San Juan Chilateca, San Juan del Estado, San Juan Tamazola, San Juan Teitipac, San Lucas Quiavini, San Lorenzo Albarradas, San Lorenzo Cacaotepec, San Luis Amatlán, San Martín Lachilá, San Martín Tilcajete, Capulálpam de Méndez, Villa Sola de Vega, San Miguel Mixtepec, San Miguel Peras, San Pablo Cuatro Venados, San Pablo Etla, San Pablo Huitzo, San Pablo Huixtepec, San Pablo Villa de Mitla, San Pedro Apóstol, San Pedro Cajonos, San Pedro Ixtlahuaca, San Pedro Totolápam, San Pedro Mártir, Santa Ana Zegache, San Pedro Teozacoalco, Villa de Etla, San Raymundo Jalpan, San Sebastián Abasolo, Santa Ana del Valle, San Sebastián Teitipac, San Sebastián Tutla, San Simón Almolongas, Santa Ana Tlapacoyan, Santa Catarina Ixtepeji, Santa Catarina Lachatao, Santa Catarina Quiané, Santa Cruz Amilpas, Santa Cruz Mixtepec, Santa María Lachixío, Santa Cruz Xoxocotlán, Santa Gertrudis, Santa Inés del Monte, Santa Lucía del Camino, Santa Lucía Ocotlán, Ayoquezco de Aldama, Santa María Atzompa, Santa María Coyotepec, Santa María del Tule, Santa María Guelacé, Santa María Peñoles, Santa María Sola, Santa María Zoquitlán, Santiago Apóstol, Santo Domingo Nuxaá, Santiago Matatlán, Santiago Suchilquitongo, Santiago Tenango, Santiago Tlazoyaltepec, Santiago Xiacuí, Santo Domingo Tomaltepec, Santo Tomás Jalieza, Santo Tomás Mazaltepec, San Vicente Coatlán, Teococuilco de Marcos Pérez,	2020/9 - 2021/4	1273	706.92	1.80	183.20	<0.001

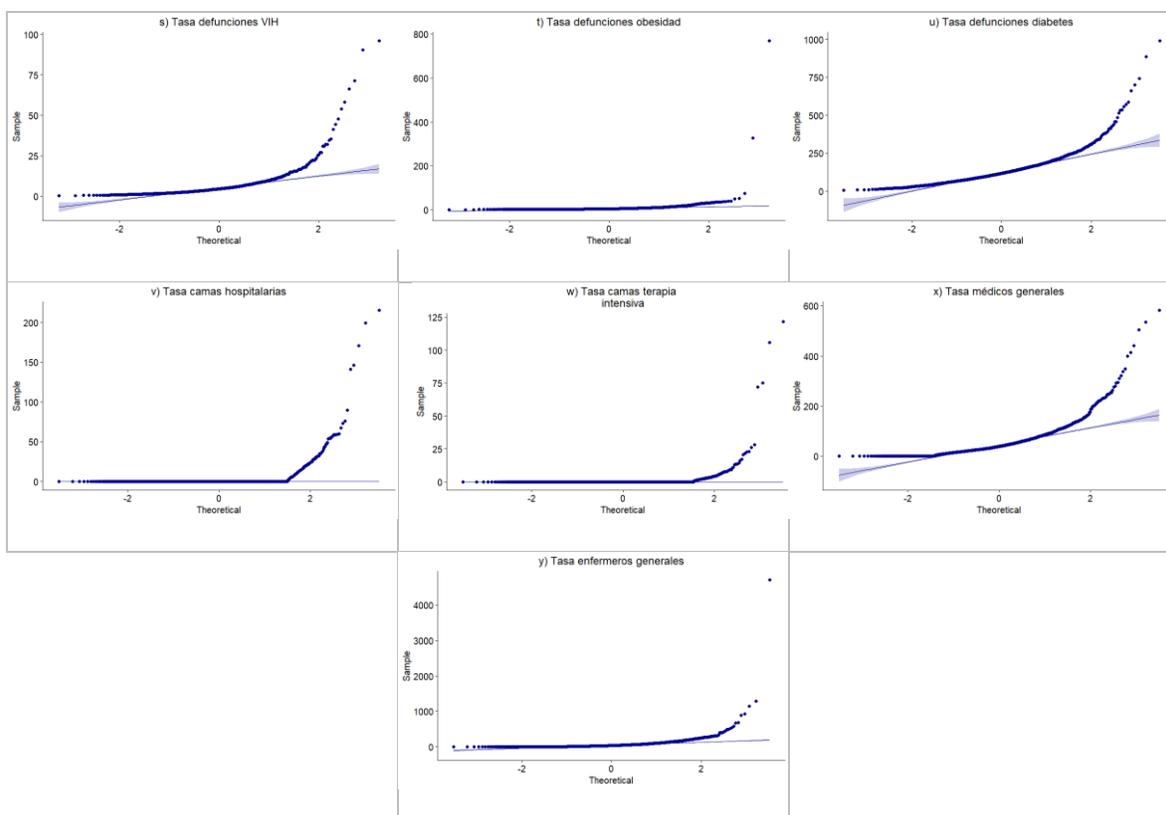
No.	Ubicación	Municipios	Duración	Obs.	Esp.	RR	RPL	p-value
		Soledad Etlá, Tanicte, Teotitlán del Valle, San Jerónimo Tlacochahuaya, Zimatlán de Álvarez, Tlacolula de Matamoros, Tlaxiaco de Cabrera, Trinidad Zaachila, Villa Díaz Ordaz, Yoganá, Villa de Zaachila						
19	Abasolo	Nuevo León (22): Los Aldamas, Allende, General Bravo, General Terán, General Zaragoza, Los Herreras, Aramberri, Cadereyta Jiménez, China, Doctor Arroyo, Doctor Coss, Doctor González, Galeana, Hualahuises, Iturbide, Linares, Melchor Ocampo, Mier y Noriega, Montemorelos, Los Ramones, Rayones, Santiago; San Luis Potosí (7): Tamuín, Cedral, Ciudad del Maíz, Ciudad Valles, Ebano, Matehuala, El Naranjo; Tamaulipas (39): Abasolo, Aldama, Altamira, Antigua Morelos, Burgos, Bustamante, Camargo, Casas, Ciudad Madero, Cruillas, Gómez Farías, González, Güémez, Gustavo Díaz Ordaz, Hidalgo, Jaumave, Miquihuana, Nuevo Morelos, Jiménez, Soto la Marina, Tampico, Tula, Llera, Mainero, El Mante, Matamoros, Méndez, Miguel Alemán, Ocampo, Padilla, Palmillas, Reynosa, Río Bravo, San Carlos, San Fernando, Valle Hermoso, Victoria, Villagrán, Xicoténcatl; Veracruz de Ignacio de la Llave (2): Pánuco, Pueblo Viejo	2020/3 - 2020/8	2711	1914.30	1.42	147.60	<0.001

Notas: Obs: Número de casos observados en el conglomerado; Esp: Número de casos esperados en el conglomerado; RR: Riesgo relativo; RPL: Relación de probabilidad logarítmica

Fuente: Elaboración propia a partir de los resultados de análisis espaciotemporal.

Anexo 6. Gráfico Q-Q de factores de riesgo relacionados con COVID-19





Fuente: Elaboración propia a partir de los resultados de la prueba de normalidad Shapiro-Wilk.

Anexo 7. Importancia de los componentes

	CP1	CP2	CP3	CP4	CP5	CP6
Desviación estándar	3.6030	1.11796	1.03397	0.69877	0.67688	0.58822
Proporción de la varianza	0.7212	0.06943	0.05939	0.02713	0.02545	0.01922
Proporción acumulada	0.7212	0.79062	0.85001	0.87714	0.90259	0.92181
	CP7	CP8	CP9	CP10	CP11	CP12
Desviación estándar	0.54581	0.4666	0.44465	0.42745	0.38137	0.33457
Proporción de la varianza	0.01655	0.0121	0.01098	0.01015	0.00808	0.00622
Proporción acumulada	0.93836	0.9505	0.96145	0.97160	0.97968	0.98590
	CP13	CP14	CP15	CP16	CP17	CP18
Desviación estándar	0.31485	0.29785	0.2123	0.12421	0.06211	0.04087
Proporción de la varianza	0.00551	0.00493	0.0025	0.00086	0.00021	0.00009
Proporción acumulada	0.99140	0.99633	0.9988	0.99969	0.99991	1.00000

Fuente: Elaboración propia a partir de los resultados del ACP.