



## Sistemas de Información Geográfica y distribución espacial de casos de COVID 19 en México

Fernando Flores Vilchez<sup>1</sup>; Armando Ávalos Jiménez<sup>2</sup>; Oyolsi Nájera González<sup>3</sup>; Mario Guadalupe González Pérez<sup>4</sup>

Recibido: 12 de mayo del 2021 / Enviado a evaluar: 6 de julio del 2021 / Aceptado: 20 de abril del 2022

**Resumen.** Este estudio analiza la evolución de la distribución espacial en áreas con alta densidad de contagios. La información está organizada y vinculada a una base de datos geográfica considerando las divisiones políticas y administrativas por estado y municipios. Posteriormente, se aplicaron métricas de distribución y estadísticas espaciales para detectar patrones de distribución. Desde noviembre de 2020 se ha identificado una tendencia en la concentración de casos hacia la zona central de México. El estudio reconoce la toma de decisiones del gobierno a través de la aplicación y seguimiento estricto de medidas restrictivas como el distanciamiento social y el uso de mascarillas tapabocas; una prioridad en las regiones con mayor riesgo de propagación. La implementación de Sistemas de Información Geográfica para el monitoreo, seguimiento, prevención y control de la pandemia permite identificar y reportar con precisión las áreas con mayor riesgo de contagio del virus.

**Palabras clave:** Contagios; Covid 19; distribución espacial; evolución; Sistemas de Información Geográfica.

### [en] Geographic Information Systems and spatial distribution of COVID 19 cases in Mexico

**Abstract.** This study analyzes the evolution of the spatial distribution in areas with a high density of infections. The information is organized and linked to a geographic database considering the political and administrative divisions by state and municipalities. Afterward, delivery metrics and spatial statistics

---

<sup>1</sup> Universidad Autónoma de Nayarit (México).

E-mail: vilchez@hotmail.com

<sup>2</sup> Universidad Autónoma de Nayarit (México).

E-mail: armand18\_a@hotmail.com

<sup>3</sup> Universidad Autónoma de Nayarit (México).

E-mail: oyolsi92@gmail.com

<sup>4</sup> Centro Universitario de Tonalá, Universidad de Guadalajara (México).

E-mail: inge\_united@hotmail.com

were applied to detect distribution patterns. Since November 2020, a trend has been identified in the concentration of cases towards the central zone of Mexico. The study recognizes the decision-making of the government through the application and strict monitoring of restrictive measures like social distancing and the use of masks; a priority in regions with the most significant risk of spread. The enforcement of Geographic Information Systems for the monitoring, follow-up, prevention, and control of the pandemic makes it possible to identify and report the areas with the severest risk of contagion of the virus.

**Keywords:** Contagions; Covid 19; evolution; spatial distribution; Geographic Information Systems.

## [fr] Systèmes d'information géographique et répartition spatiale des cas de COVID 19 au Mexique

**Résumé.** Cette étude analyse l'évolution de la distribution spatiale dans les zones à forte densité d'infections. Les informations sont organisées et liées à une base de données géographique tenant compte des divisions politiques et administratives par État et municipalités. Par la suite, des métriques de livraison et des statistiques spatiales ont été appliquées pour détecter les modèles de distribution. Depuis novembre 2020, une tendance a été identifiée dans la concentration des cas vers la zone centrale du Mexique. L'étude reconnaît la prise de décision gouvernementale par l'application et le contrôle strict de mesures restrictives telles que la distanciation sociale et l'utilisation de masques; priorité dans les régions présentant le plus grand risque de propagation. La mise en place de systèmes d'information géographique pour la surveillance, le suivi, la prévention et le contrôle de la pandémie permettent d'identifier et de signaler les zones présentant le plus grand risque de contagion du virus.

**Mots-clés:** Contagions; Covid 19; évolution; distribution spatiale; systèmes d'information géographique.

**Cómo citar.** Flores Vilchez, F., Ávalos Jiménez, A., Nájera González, O. y González Pérez, M. (2022): Sistemas de Información Geográfica y distribución espacial de casos de COVID 19 en México. *Anales de Geografía de la Universidad Complutense*, 42(1), 65-83.

**Sumario.** 1. Introducción. 1.1. Revisión de la literatura. 2. Materiales y métodos. 3. Resultados. 4. Discusión. 5. Conclusiones. 6. Referencias.

## 1. Introducción

La enfermedad COVID 19 causada por el virus SARS-Cov-2 fue declarada emergencia de salud pública internacional el 30 de enero de 2020, y solo cuatro meses después del primer caso confirmado en China, la Organización Mundial de la Salud la clasificó como pandemia el 12 de marzo del mismo año (OMS, 2020). A partir de ahí, se activaron protocolos de emergencia en la mayoría de los países afectados para reducir la velocidad de contagio, mitigar el número de casos y prevenir el colapso de los sistemas de salud mediante la aplicación de medidas restrictivas, siendo Italia y China los primeros países en aplicar el bloqueo de movilidad, distanciamiento social y confinamiento (Bonaccorsi et al., 2020).

Actualmente, la pandemia ha afectado a más de 212 países en el mundo, ya que el 13 de octubre de 2020 se registraron más de 38 millones de casos confirmados y más de 1.08 millones de defunciones (JHU, 2020), y al 14 de diciembre de 2020, la cifra era ya de alrededor de 1.6 millones de muertos (Orús, 2020). En efecto, el primer caso

confirmado de COVID 19 ocurrió en diciembre de 2019 en Wuhan, China (Huang et al., 2020; Zhang et al., 2020), convirtiéndose en el epicentro de la enfermedad y expandiéndose rápidamente a países cercanos (Corea y Japón). En Europa, Italia y España fueron las primeras ciudades afectadas con reportes de casos confirmados el 31 de enero de 2020 y para marzo de 2020, Italia fue el epicentro europeo con 105 mil casos y 12,400 muertes en solo dos meses. En América por su parte, Washington en Estados Unidos identificó el primer caso el 21 de febrero. La expansión siguió a países como México, ya que en el 27 de febrero se confirmó el primer caso (Suárez et al., 2020).

A nivel mundial se suspendieron los vuelos internacionales entre las principales ciudades del mundo, y en general toda la actividad económica, cierre de escuelas públicas y privadas, cierre de bares y restaurantes, centros de reuniones y espacios públicos. De acuerdo con las fases de emergencia epidemiológica establecidas por la OMS (2020), la evolución de la enfermedad determinó la primera fase denominada transmisión de la enfermedad. Las personas que viajaron a otros países se infectaron y regresaron a México trayendo el virus, principalmente de Europa (Italia, Francia, Alemania y España), Asia (China, Turquía y Singapur), Estados Unidos de América y Canadá, además de algunos de América del Sur (Perú, Colombia, Brasil y Argentina); en este sentido, se tuvo un registro de un total de 746 personas (Suárez et al., 2020).

En México, la suspensión de actividades económicas se implementó a partir del 24 de marzo de 2020, cuando se ingresó a la segunda fase, restringiendo las concentraciones masivas y recomendando el aislamiento en el hogar. El primer caso se reportó en marzo, la segunda fase se inició con la expansión a través de infectados comunitarios o locales, siendo el 21 de abril cuando la Secretaría de Salud declaró el inicio de la fase tres, involucrando a más severas medidas de restricción, esta situación ha continuado hasta el día de hoy, el fin de la pandemia no ha terminado. El 30 de marzo de dicho año, la Secretaría de Salud decretó el estado de Emergencia Sanitaria Nacional, implementando estrictas medidas restrictivas como la suspensión total de actividades calificadas como no esenciales (SSA, 2020).

La aplicación de medidas restrictivas provocó una parálisis en la producción industrial, y la pérdida del empleo afectó la economía global (Sánchez, 2020); por ejemplo, el colapso de los mercados financieros generó que los precios del petróleo alcanzaran ratios negativos por primera vez en la historia (Cedeño et al., 2020). En este sentido, la Comisión Económica para América Latina y el Caribe estimó que en América Latina habrá una contracción económica del 1.8% del Producto Interno Bruto (PIB), una tasa de desempleo promedio del 10%, y las personas que viven en la pobreza oscilarán entre 185 millones y 220 millones y las personas en pobreza extrema entre 67.4 millones y 90 millones (CEPAL, 2020). No obstante, las mismas medidas de restricción implementadas no solo están teniendo un impacto negativo, sino que también están generando efectos positivos en el medio ambiente, ya que se han estimado reducciones en las emisiones de gases de efecto invernadero; concretamente, contaminantes como el óxido de nitrógeno y el dióxido de azufre) (Forster et al., 2020). Asimismo, las actividades relacionadas con el transporte han

disminuido hasta un 25%, para los países más afectados como China o Italia (Acuto, 2020).

En este contexto, el objetivo de este estudio analiza la evolución de la distribución espacial en las áreas con mayor densidad de casos de COVID 19, a través de herramientas de Sistemas de Información Geográfica, y métricas de distribución espacial, para identificar las áreas con mayor riesgo de contagio, y por tanto, la determinación de áreas donde se encuentran las fuentes de propagación. El estudio cuestiona cómo las autoridades gubernamentales podrían utilizar la información obtenida y tomar decisiones a favor de la población.

### **1.1. Revisión de la literatura**

Se han realizado varios estudios de la enfermedad COVID 19, y se ha demostrado que se transmite por contacto cercano de persona a persona y por contacto con superficies contaminadas (Centro para el Control y la Prevención de Enfermedades, 2019). Por otro lado, se han identificado algunos efectos de la enfermedad, como los estudios realizados por Suárez et al., (2020), quienes sugieren que la enfermedad afecta más a personas en condición vulnerable; es decir, a personas que tienen una o múltiples comorbilidades como hipertensión, diabetes y obesidad que a personas sanas; y que la población más afectada responde a personas mayores de 48 años. Otro estudio indica que el 80% de la población afectada corresponde a mayores de 60 años (COVID y Team, 2020). Asimismo, Padilla et al., (2020) concluyen que el 80% de la población afectada por COVID 19 resultan ser personas de 60 años o más, e incluso adultos mayores con alguna otra enfermedad crónica y mayormente hombres que mujeres; por tanto, mueren más hombres.

En función de lo anterior, los sistemas de información geográfica (SIG) han contribuido a la comprensión de las enfermedades infecciosas. Por ejemplo, en 1964 se utilizaron para estudiar la fiebre amarilla en Nueva York (Barret, 2000). Asimismo, para el análisis espacial de múltiples enfermedades como Cáncer (Brewer, 2006; Parrott et al., 2020), Asma (Rob, 2003; AIDousari y AISahli, 2017), muertes cardiovasculares (Sepehrvand et al., 2020), Diabetes (Zepka et al., 2019) y Obesidad (Jia et al., 2019). Lyseen et al., (2014) relacionaron 865 manuscritos sobre el uso de SIG en ciencias de la salud. Los SIGs se ha implementado en varios países, a veces combinados con técnicas de análisis de datos (big data) o con herramientas de inteligencia artificial (Cascon, 2020; Sarfo y Karuppanan, 2020), para comunicar y difundir casos de COVID 19, a través de portales geográficos que ayudan a hacer conciencia sobre la exposición y riesgo en áreas con mayor incidencia.

Pulido et al. (2020) indican que el uso de SIG es posible identificarlos en organismos oficiales de México como el Consejo Nacional de Ciencia y Tecnología (CONACYT) en coordinación con el Centro de Investigaciones en Ciencias de la Información Geoespacial (Geo Center), el Laboratorio Nacional de Geointeligencia (GeoInt), y el Laboratorio de Datos (DataLab), a través del portal de internet <https://datos.covid-19.conacyt.mx/>, para la visualización de casos por COVID 19. Sin embargo, estas aplicaciones solo muestran la información específica a la fecha actual,

sin posibilidad de poder ver como ha evolucionado la distribución de la pandemia. En este documento aprovechamos la capacidad de las herramientas SIG y estadísticas espaciales para poder analizar la evolución de la distribución. De ahí, la importancia del monitoreo, seguimiento, prevención y control de la pandemia.

## 2. Materiales y métodos

La metodología tuvo dos etapas: a partir de una recopilación de información sobre los casos de COVID 19 reportados para México. Posteriormente, la información se organizó y vinculó en una base de datos geográfica, considerando datos estatales y municipales para su clasificación y análisis. Asimismo, se aplicaron herramientas de análisis espacial y herramientas de estadística espacial. Además, de considerar los límites político-administrativos de la División Política Estatal y Municipal de México, a escala: 1: 250,000, del Instituto Nacional de Estadística y Geografía (INEGI, 2019), a través del portal de geoinformación 2020, y el catálogo de metadatos geográficos de la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO).

Los mapas de distribución espacial de COVID se obtuvieron a través de SIG, aplicando métodos de clasificación de campo estándar con simbología graduada para cada dato temporal a nivel Municipal. Asimismo, solo el número de casos positivos para SARS-COV-2 emitidos por el laboratorio de la Red Nacional de Laboratorios de Vigilancia Epidemiológica (INDRE, LESP y LAVE) y laboratorios privados avalados por InDRE, cuyos resultados son registrados y considerados en SISVER. En un catálogo de claves y descriptores del mismo conjunto de datos, se descartaron los casos no localizados por entidad y municipios. El análisis de la evolución de la distribución de casos de COVID 19 aplicó un análisis estadístico mediante la transformación del conjunto de datos para analizar la variabilidad de la distribución y compararlos con la media aritmética para determinar el comportamiento de cada estado. El valor estándar ( $z$ ) da como resultado el uso de la Ecuación 1:

$$z_i = \frac{x_i - \bar{x}}{\sigma} \quad (\text{Ec. 1})$$

dónde:

$z_i$  = valor normal estándar

$x_i$  = número de casos por estado y municipio

$\bar{x}$  = media aritmética

$\sigma$  = desviación estándar

Además, se utilizó una técnica que estima los atributos de una población (Silverman, 1981); la cual expresa la densidad de ocurrencia de varios tipos de fenómenos en el espacio denominada Densidad Kernel; la cual fue propuesta en 1956 por Rosenblatt para formular funciones de probabilidad y describir el gradiente del comportamiento de los datos. Las estimaciones a partir de los datos observados en las secciones contiguas se analizaron de acuerdo con las dimensiones de la ventana de

análisis seleccionada a criterio del analista y las características de interés (Moreno, 1991). La utilidad de esta herramienta ha sido probada en múltiples estudios, para estimar la densidad de caminos y su correlación con la fragmentación del paisaje (Cai et al., 2013), la estimación de la densidad de tránsito y accidentes, la detección de áreas más peligrosas (Hashimoto et al., 2016), el análisis de la frecuencia de inundaciones (Santhosh et al., 2013) y la distribución de casos de enfermedades epidemiológicas (Bithell, 1990).

Se obtuvieron dos métricas similares: a) distancia estándar (SD) y b) distribución direccional o desviación elipse estándar (SDE) para medir la evolución de la distribución espacial de los casos de COVID 19. La SD mide el grado en que las entidades se concentran o dispersan alrededor de su centro medio geométrico y surge de la correlación de datos de distancia multivariados (Edelmann et al., 2017). Es una estadística útil que proporciona una única medida resumida de la distribución de características en su centro. Es similar a la SDE, que mide la distribución de valores de datos alrededor de la media estadística; sin embargo, la SD crea una nueva entidad que contiene un polígono circular centrado en el promedio del conjunto de casos. Según Mitchel (2005), la SD es más útil cuando hay poca o ninguna tendencia direccional. En este caso, se utilizaría la SDE. El cálculo de la SD se realizó en el programa *Arcmap* versión 10.3, y a través de la ecuación 2.

$$SD = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n} + \frac{\sum_{i=1}^n (y_i - \bar{Y})^2}{n}} \quad (\text{Ec. 2})$$

donde:

$x_i/y_i$  = coordenadas para el estado “i”

$\bar{X}/\bar{Y}$  = promedio de todos los estados y municipios

n = número total de estados y municipios

La SDE es una medida estadística clásica que representa la dispersión de un conjunto de entidades alrededor de su entorno, lo que siempre resulta en una elipse (Wang et al., 2015). Lefever lo definió como la media del área central de un conjunto de puntos, donde el punto promedio constituye el origen de los ejes de distribución (Yuill, 1971). Es una herramienta de SIG que sirve para delinear la tendencia de la distribución geográfica para conjuntos de datos que tienen relación directa con características físicas delimitadas por un polígono elíptico centrado para todas las entidades, obteniendo dos valores de SD, tanto para el eje longitudinal como para la sección transversal, así como la orientación de la elipse, e indican la tendencia, el grado de dispersión y la orientación de los datos (Mitchel, 2005).

El análisis SDE se utiliza en varias áreas geográficas para analizar la orientación de partículas contaminantes (Baojun et al., 2008), ubicación y distribución de casos de delitos o escenas de delitos (Kent et al., 2007; Mukherjee y Rajendran, 2015), identificación de la distribución de patrones espacio-temporales de enfermedades como el dengue (Abd et al., 2019; Acharya et al., 2018), infecciones como el virus de

la influencia (Dong et al., 2017), detección de patrones y efectos de la expansión urbana (Umaru et al., 2015; Rizwan et al., 2020), entre muchas otras aplicaciones. El cálculo de la SDE se realiza utilizando el programa *Arcmap* versión 10.3, aplicando la primera desviación estándar para contener la densidad más alta del número de casos en el radio de dispersión más pequeño, calculado a partir de la ecuación 3.

$$SDE_x = \sqrt{\frac{\sum (x_i - \bar{X})^2}{n}} \quad SDE_y = \sqrt{\frac{\sum (y_i - \bar{Y})^2}{n}} \quad (\text{Ec. 3})$$

donde:

$x_i/y_i$  = coordenadas para el estado “i”

$\bar{X}/\bar{Y}$  = promedio de todos los estados y municipios

n = número total de estados y municipios

En una distribución normal estándar, el patrón espacial de los estados se concentra en el centro, donde se encuentra el mayor número de estados (SD y SDE). Se espera que el 68 % de todos los puntos del conjunto estén dentro del radio de una longitud estándar más corta; un polígono con dos desviaciones estándar contendrá el 95 %, y tres desviaciones estándar cubrirán el 99 % del conjunto total de datos.

### 3. Resultados

Se consideró mostrar la evolución de la distribución espacial de los casos de COVID 19, tomando como primer día el 12 de abril, para lo cual existen registros oficiales de reportes de datos. Se observó que el 12 de abril se registraron 4,658 casos nacionales positivos. En este primer mes analizado, el promedio nacional apenas superó los 140 casos, siendo los estados con mayor proporción la Ciudad de México, Estado de México, Puebla, Sinaloa y Quintana Roo. Al 12 de mayo se alcanzó un promedio de casi 1,200 casos, y el estado con mayor número en un mes fue la Ciudad de México, con 10,526 (Tabla 1).

Tabla 1. Casos acumulados de COVID 19 por Estado.

Estado	12 Abril 2020	12 Mayo 2020	12 Junio 2020	12 Julio 2020	12 Agosto 2020	12 Septiembre 2020	12 Octubre 2020	12 Noviembre 2020
1 Aguascalientes	55	382	1400	2,904	4,623	6,330	7,981	11,082
2 Baja California	334	2573	6,761	10,876	14,876	18,295	22,337	24,255
3 Baja California Sur	119	400	922	2,414	5,798	8,870	11,163	13,331
4 Campeche	20	211	925	2,931	5,062	5,772	6,272	6,596
5 Coahuila	161	584	1,884	7,107	16,575	23,905	28,872	7,612

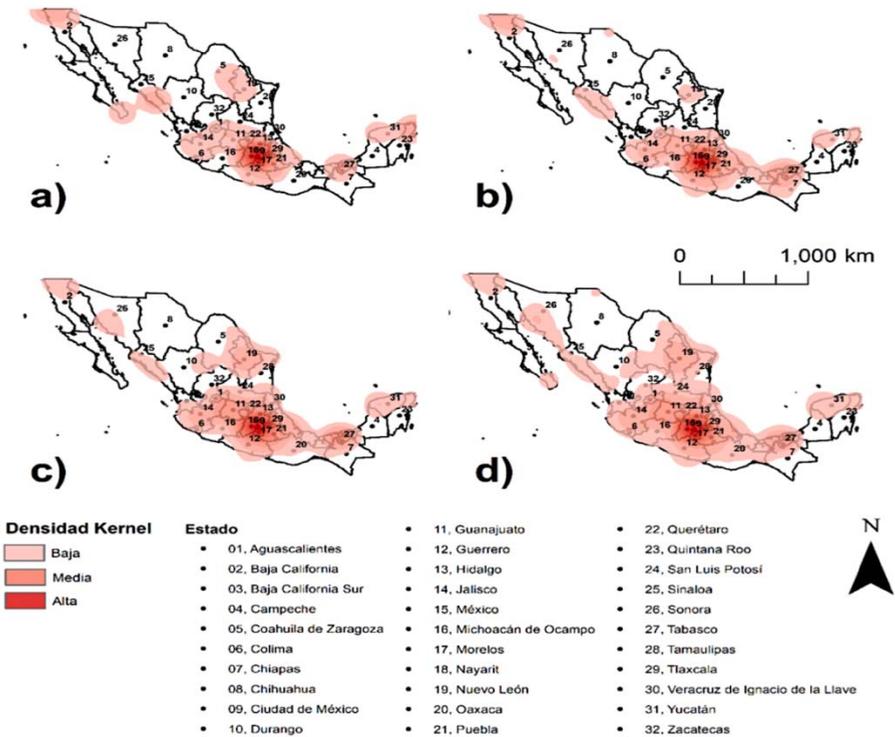
		12	12	12	12	12	12	12	12
	Estado	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre
		2020	2020	2020	2020	2020	2020	2020	2020
6	Colima	7	46	264	898	2,475	4,160	5,810	24,090
7	Chiapas	43	433	3,099	5,201	5,990	6,373	7,373	175,940
8	Chihuahua	62	730	2,150	3,802	6,277	8,945	13,019	37,135
9	Ciudad de México	1173	10526	35,269	57,671	82,506	110,805	140,519	6,898
10	Durango	18	123	856	2,771	4,970	7,628	10,178	17,026
11	Guanajuato	83	544	3,221	12,285	25,243	36,390	43,659	53,278
12	Guerrero	73	622	3,178	7,494	12,811	16,424	20,702	22,888
13	Hidalgo	60	601	2,602	4,798	8,107	11,311	13,954	16,939
14	Jalisco	157	671	3,743	9,275	15,953	23,120	29,995	37,262
15	México	653	6,537	22,391	42,289	59,069	73,229	88,870	102,264
16	Michoacán	61	612	3,335	7,122	11,690	17,479	22,254	26,446
17	Morelos	49	873	1,822	3,426	4,586	5,648	6,493	7,396
18	Nayarit	23	244	932	2,314	3,983	5,326	6,181	6,747
19	Nuevo León	119	687	2,333	9,747	22,575	33,501	45,048	59,123
20	Oaxaca	44	278	2,826	7,790	12,053	14,820	19,032	22,759
21	Puebla	255	1,168	5,143	14,200	23,243	28,972	33,155	37,132
22	Querétaro	59	270	1,369	2,484	4,534	7,602	10,407	16,722
23	Quintana Roo	226	1,144	2,384	5,237	8,952	11,055	12,761	13,811
24	San Luis Potosí	52	308	1,570	4,493	13,152	20,584	24,814	31,019
25	Sinaloa	228	1,579	5,314	10,103	14,174	17,289	20,108	22,812
26	Sonora	69	567	3,714	11,574	19,529	23,054	35,590	39,962
27	Tabasco	152	1,876	6,284	14,958	24,954	29,911	33,082	35,419
28	Tamaulipas	56	787	2,811	8,845	18,928	26,777	30,224	33,466
29	Tlaxcala	40	398	1,624	3,336	5,311	6,845	7,973	8,739
30	Veracruz	82	1,497	6,133	13,782	24,687	30,788	35,089	38,149
31	Yucatán	109	883	2,423	6,215	12,001	16,453	19,610	22,420
32	Zacatecas	16	160	501	1,394	3,673	6,290	8,498	13,092
	Total	4,658	38,314	139,183	299,736	498,360	663,951	821,023	991,810*

\*No incluye 25 casos reportados espacialmente no ubicados (Estado y Municipio no fueron especificados en las bases de datos).

Fuente: Elaboración propia con base en datos del Departamento de Epidemiología de la Secretaría de Salud (2020).

La aplicación de la Densidad de Kernel muestra la tendencia en la densidad de distribución de la población infectada por COVID 19 y el área donde se concentra la mayor población infectada. Para los meses de abril, junio, agosto, octubre y noviembre, la Densidad de Kernel mostró la evolución de los casos de COVID 19. En el mes de abril, la densidad fue en la región central, y algunas zonas del norte y oriente de México (Ciudad de México, Guanajuato, Hidalgo, México, Morelos, Puebla, Querétaro y Tlaxcala), y también se distribuyó parcialmente en Baja California, Baja California Sur, Coahuila, Guerrero, Jalisco, Nuevo León, Quintana Roo, Sinaloa y Tabasco. En el mes de octubre, la densidad se expande hacia los estados contiguos: Aguascalientes, Ciudad de México, Guanajuato, Guerrero, Hidalgo, México, Morelos, Puebla, Querétaro y Tlaxcala y parcialmente en Coahuila, Jalisco, Nuevo León, Sonora, Tabasco y Yucatán (Figura 1).

Figura 1. Densidad de Kernel\*

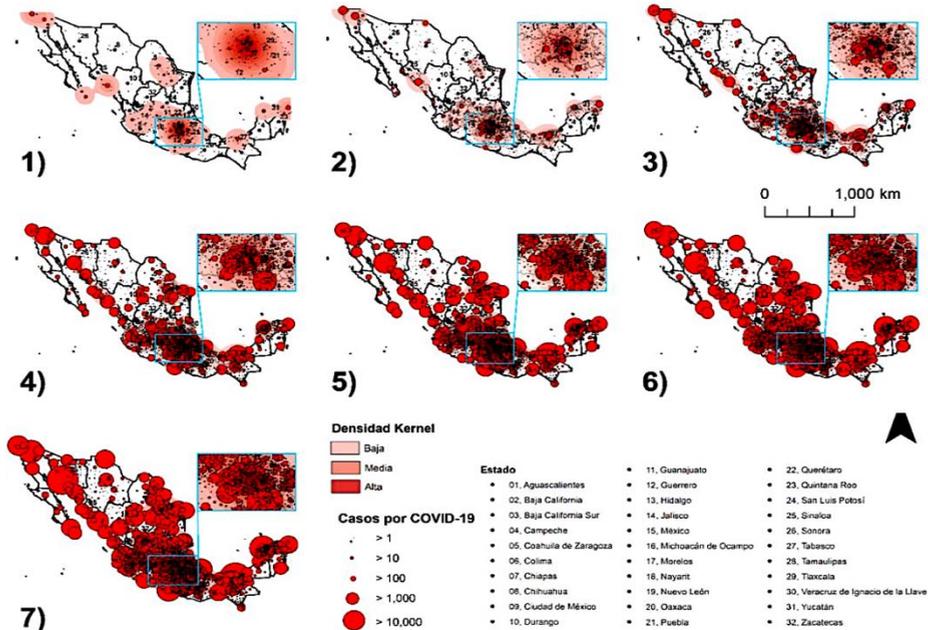


\* Solo se muestran cuatro meses para mejorar la visualización: a) 12 de abril de 2020; b) 12 de junio de 2020; c) 12 de agosto de 2020 y d) 12 de octubre de 2020

Fuente: Elaboración propia con base en datos del Departamento de Epidemiología de la Secretaría de Salud (2020).

Durante los primeros meses, los casos de COVID 19 mostraron un patrón disperso por todo el territorio mexicano (Figura 2). Sin embargo, en junio comenzó a observarse una concentración en la región central, y a medida que continuaron los casos reportados, la distribución se extendió al estado contiguo en una distribución en forma de conglomerados.

Figura 2. Evolución de la distribución espacial de casos de COVID 19.



Fuente: Elaboración propia con base en datos del Departamento de Epidemiología de la Secretaría de Salud (2020).

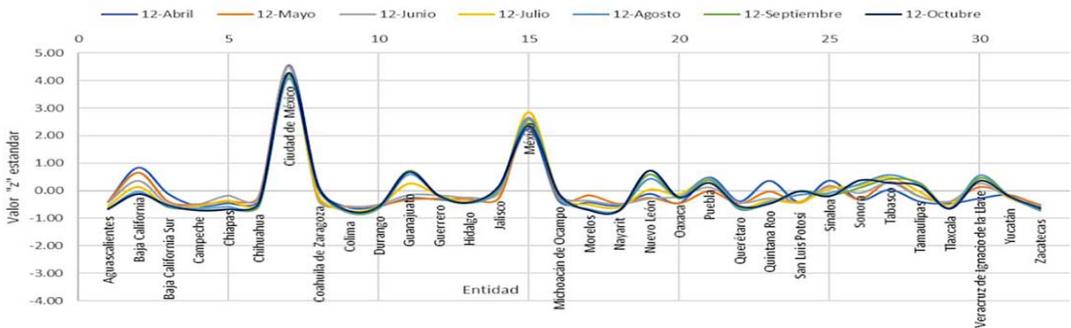
Estados como Michoacán, Puebla, Tabasco, Durango y Yucatán han tenido un comportamiento irregular, ya que la variabilidad de los casos ha ido alternando; siendo un mes por debajo del promedio, el siguiente mes por encima y nuevamente, por debajo del promedio. Así, iguales pero con un comportamiento estable son Campeche, Colima, el Estado de México y Zacatecas, que en el período analizado se mantuvieron con el número de casos reportados, los dos primeros por debajo del promedio nacional mensual y el tercero por encima. Específicamente, los estados de Jalisco y Ciudad de México, debido a las medidas de restricción implementadas para reducir el número de contagios, pero que en los últimos meses han visto un aumento en el conteo.

En función de lo anterior, siguió aumentando el número de casos de COVID 19 en Chihuahua, Ciudad de México, Durango, Jalisco, Nuevo León, Querétaro y Zacatecas. Los estados de Coahuila y San Luis Potosí presentaron una variabilidad menor al

promedio; no obstante, debido a la relajación de las medidas restrictivas para el mes de noviembre mostró un nuevo aumento. Por otro lado, la mayoría de los estados continuaron implementando medidas restrictivas. El comportamiento reflejó ligeros cambios al alza o a la baja pero con una tendencia constante en la variabilidad de los datos (Aguascalientes, Baja California, Baja California Sur, Campeche, Hidalgo, Estado de México, Michoacán, Morelos, Nayarit, Quintana Roo, Colima, San Luis Potosí, Yucatán, Chiapas, Guanajuato, Oaxaca, Tabasco, Tamaulipas y Tlaxcala); específicamente, en los últimos meses se incrementó en los estados de Guerrero, Tabasco, Tamaulipas, Puebla, Veracruz y Sonora, y en noviembre disminuyó la variabilidad de los casos reportados.

El índice estándar que describe la variabilidad de los datos con respecto al promedio mensual se muestra en la figura 4 y se puede inferir que estados como Aguascalientes, Baja California, Quintana Roo y Sinaloa comenzaron con valores estándar por encima del promedio durante los primeros meses. Posteriormente, se mantuvieron por debajo del promedio hasta octubre, o por el contrario donde Nuevo León, San Luis Potosí, Guanajuato y Tamaulipas, que comenzaron con una baja tasa de casos en los primeros meses y posteriormente mostraron una cifra por encima del promedio de casos.

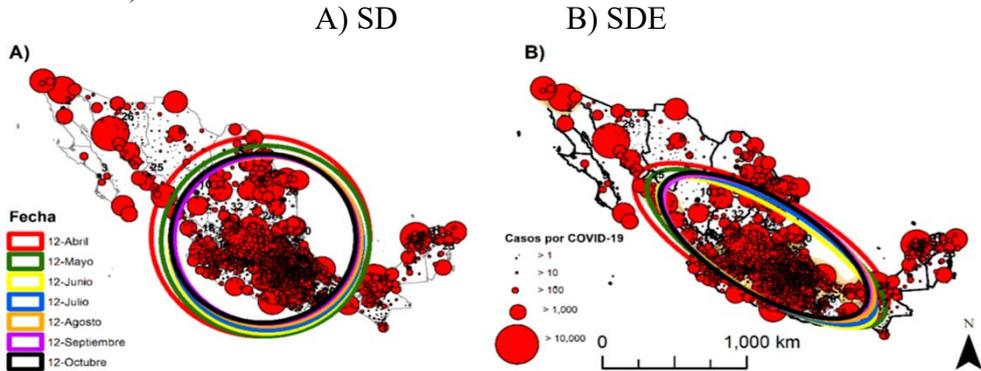
Figura 3. Variabilidad de casos por COVID 19, respecto a la media.



Fuente: Elaboración propia con base en datos del Departamento de Epidemiología de la Secretaría de Salud (2020).

Las medidas de restricción implementadas fueron evaluadas en cada estado mexicano a través del índice estándar, el cual detectó que algunos estados estuvieron por encima del promedio reportado, y que posteriormente redujeron el número de casos de COVID 19 (Baja California, Baja California Sur, Sinaloa, Quintana Roo, Aguascalientes, Tlaxcala, Nayarit, Chiapas, Campeche e Hidalgo) y presentaron un índice estándar alto y luego bajaron su valor, resultando en una reducción en la variabilidad de los datos referidos al promedio general, para cada período evaluado.

Figura 4. Métricas de distribución geográfica aplicadas a casos de COVID 19 (12 de abril-12 de noviembre).



Fuente: Elaboración propia con base en datos del Departamento de Epidemiología de la Secretaría de Salud (2020).

La SD y SDE mostraron que la evolución espacial de los casos de COVID 19 ocurrió en la parte central de México. Además, los anillos de distribución mostraron solo pequeñas variaciones, reduciendo gradualmente el espacio en esta área (figura 5).

#### 4. Discusión

Las medidas de restricción aplicadas en todo el mundo han implicado en ocasiones un control estricto en aspectos de la movilidad que no siempre son aceptados libremente por la población en general. Incluso, esto llevó a la necesidad, en algunos casos, de utilizar la fuerza pública, el uso de vallas sanitarias y el cierre de fronteras para contener la propagación de la enfermedad COVID 19. Las medidas tomadas por los gobernantes no siempre se aplicaron correctamente, debido a la falta de información sobre la ubicación espacial de las fuentes de contagio, implementando medidas generalizadas que afecten a una gran población. En este sentido, las herramientas de SIG como las utilizadas en este estudio ayudaron a identificar con precisión las áreas de contagio y sus tendencias de distribución, permitiendo que esta información implemente medidas sanitarias para una población compacta que involucre la menor población posible. Además, mitigar los efectos adversos para una población más grande.

La utilidad de los SIG en el contexto de la pandemia ha sido reconocida en la literatura científica como una herramienta indispensable para el seguimiento de los casos notificados y el seguimiento espacial de los casos confirmados de COVID 19, así como apoyo para la toma de decisiones (Irwansyah et al., 2020; Ahasan et al., 2020; Zhou et al., 2020; Rosenkrantz et al., 2020). De tal manera, encontrar las fuerzas impulsoras o variables espaciales y sociodemográficas que están relacionadas

con la enfermedad y que podrían ayudar a prevenirla y controlarla (Pourghasemi et al., 2020; Nath et al., 2020).

Investigar la susceptibilidad de la población a la enfermedad (Sarkar, 2020), para la visualización espacial, análisis y difusión de información epidemiológica mediante la elaboración de mapas epidemiológicos y de distribución geográfica de la propagación de la enfermedad por COVID 19 (Melin et al., 2020; Da Silva, 2020; Ghanbarian et al., 2020; Bhatia et al., 2020; Zambrano et al., 2020; Dagnino et al., 2020; Mousavi, 2020); así como para la clasificación espacial o segmentación de la pandemia en función del nivel del riesgo (Kanga et al., 2020; Santana, 2020; Gaona et al., 2020). Incluso, para la predicción de la distribución de casos de infección mediante modelos matemáticos (Torrealba et al., 2020; Vivanco 2020), para el equilibrio y la gestión de las cadenas de suministro de salud ante la pandemia (Govindan et al., 2020).

La formulación, implementación y evaluación del impacto de las medidas de prevención y control para reducir la probabilidad de recurrencia (Akter, 2020; Orozco et al., 2020; Nicola et al., 2020; Chinazzi et al., 2020); y, para la implementación de mecanismos regulatorios para prevenir casos futuros, es un soporte de información espacial para la toma de decisiones en materia COVID 19 (Zhou et al., 2020). Los métodos de SD y SDE para analizar la evolución de la distribución espacial de casos de COVID 19 son útiles para modelar la propagación de la enfermedad mediante la definición del centro de distribución, el grado de compacidad y la tendencia de la distribución espacial. Por ejemplo, observar la propagación de la pandemia y establecer áreas de mayor riesgo de contagio; además, es una base de información esencial para implementar medidas de restricción social y movilidad. En este sentido, el análisis y comparación del tamaño, forma y superposición de los anillos de distribución generados por las métricas aplicadas también sirven para ayudar a indicar la existencia de rebrote en el tiempo.

## 5. Conclusiones

Los SIG sirven como base metodológica en el análisis de la distribución espacial de los casos de COVID 19 a escalas locales y permite evaluar los sitios de distribución con mayor precisión. A noviembre de 2020, la región central de México conformada por los estados de Aguascalientes, Ciudad de México, Guanajuato, Guerrero, Hidalgo, México, Morelos, Puebla, Querétaro y Tlaxcala se identificó como un área con mayor riesgo de propagación de la enfermedad. Asimismo, los estados de Aguascalientes, Guerrero, Hidalgo, Morelos, Puebla, Querétaro y Tlaxcala, Nayarit y Zacatecas han venido manteniendo bajos niveles de contagio por debajo del promedio nacional.

El conocimiento de cómo se distribuye la enfermedad y su tendencia espacial es de vital importancia para los gobernantes a la hora de tomar decisiones. La estricta aplicación y vigilancia de las medidas de restricción, sana distancia y uso de mascarillas cubrebocas debe ser una prioridad en las regiones mexicanas con mayor riesgo de propagación a medida que continúa el número de casos de COVID 19. En

este sentido, la información aquí mostrada puede ayudar a sensibilizar a la población sobre la exposición a zonas de riesgo y también para definir y establecer zonas de seguridad, inducir el no acudir a estos espacios e incidir en la reducción de las tasas de contagio.

Algunas limitaciones para el análisis de la distribución de casos de COVID 19 a escala tienen que ver con la distribución a nivel municipal; sin embargo, la distribución debe considerarse a nivel local (barrio o por asignaciones censales). Los datos a nivel municipal no son útiles y se deben considerar los datos con puntos de ubicación geográfica de cada caso de COVID 19. Se recomienda para futuros estudios analizar la distribución espacial con base en variables sociales, económicas y demográficas para identificar los factores que están más relacionados con la propagación de la enfermedad y determinar la vulnerabilidad en las diferentes regiones de México.

## 6. Referencias

- Abd M. N., Muhamad N. N., & Mohamed, A. F. (2019). Distribution and spatial pattern analysis on dengue cases in Seremban District, Negeri Sembilan, Malaysia. *Sustainability*, 11(13), 3572. <https://doi.org/10.3390/su11133572>
- Acharya, B. K., Cao, C., Xu, M., Chen, W., & Pandit, S. (2018). Spatiotemporal distribution and geospatial diffusion patterns of 2013 dengue outbreak in Jhapa District, Nepal. *Asia Pacific Journal of Public Health*, 30(4), 396-405. <https://doi.org/10.1177/1010539518769809>
- Acuto, M. (2020). COVID-19: Lessons for an urban (izing) world. *One Earth*. <https://doi.org/10.1016/j.oneear.2020.04.004>
- Ahasan, R., Alam, S., Chakraborty, T., & Hossain, M. M. (2020). Applications of GIS and Geospatial analyses in COVID-19 research: A systematic review. *SocArXiv*. August, 31. <https://doi.org/10.31235/osf.io/zqmwa>
- AIDousari, E., & AlSahli, M. M. (2017). Studying the Spatial Distribution of Asthma Patients in the State of Kuwait Using GIS. *Journal of the Social Sciences*, 45(1).
- Akter, S. (2020). The impact of COVID-19 related 'stay-at-home' restrictions on food prices in Europe: findings from a preliminary analysis. *Food Security*, 12(4), 719-725. <https://doi.org/10.1007/s12571-020-01082-3>
- Baojun, W., Bin, S., & Inyang, H. I. (2008). GIS-based quantitative analysis of orientation anisotropy of contaminant barrier particles using standard deviational ellipse. *Soil & sediment contamination*, 17(4), 437-447. <https://doi.org/10.1080/15320380802146784>
- Barrett, F. A. (2000). Finke's 1792 map of human diseases: the first world disease map? *Social Science & Medicine*, 50(7-8), 915-921. [https://doi.org/10.1016/s0277-9536\(99\)00344-5](https://doi.org/10.1016/s0277-9536(99)00344-5)
- Bhatia, A., Kumar, M., & Magotra, R. (2020). Role of GIS in Managing COVID-19. <http://nopr.niscair.res.in/handle/123456789/55154>
- Bithell, J. F. (1990). An application of density estimation to geographical epidemiology. *Statistics in medicine*, 9(6), 691-701. <https://doi.org/10.1002/sim.4780090616>

- Bonaccorsi, G., Pierri, F., Cinelli, M., Flori, A., Galeazzi, A., Porcelli, F., & Pammolli, F. (2020). Economic and social consequences of human mobility restrictions under COVID-19. *Proceedings of the National Academy of Sciences*, 117(27), 15530-15535. <https://doi.org/10.1073/pnas.2007658117>
- Brewer, C. A. (2006). Basic mapping principles for visualizing cancer data using geographic information systems (GIS). *American journal of preventive medicine*, 30(2), S25-S36. <https://doi.org/10.1016/j.amepre.2005.09.007>
- Cai, X., Wu, Z., & Cheng, J. (2013). Using kernel density estimation to assess the spatial pattern of road density and its impact on landscape fragmentation. *International Journal of Geographical Information Science*, 27(2), 222-230. <https://doi.org/10.1080/13658816.2012.663918>
- Cascón K. J. D. (2020). Tecnologías para luchar contra la pandemia Covid-19: geolocalización, rastreo, big data, SIG, inteligencia artificial y privacidad//Technologies to fight the Covid-19 pandemic: geolocation, tracking, big data, GIS, artificial intelligence, and privacy. *Profesional de la información*, 29(4). <https://doi.org/10.3145/epi.2020.jul.29>
- CDC. (2019). NovelCoronavirus (2019-nCoV). <https://espanol.cdc.gov/coronavirus/2019-ncov/prevent-getting-sick/how-covid-spreads.html>
- Cedeño, P. U. L., López, D. A. M., & Bailón, F. M. C. (2020). Consecuencias para el sector petrolero a causa de la pandemia del Covid-19. *E-IDEA Journal of Business Sciences*, 2(6), 1-11. <https://revista.estudioidea.org/ojs/index.php/eidea/article/view/34/28>
- CEPAL (2020). COVID-19. <https://www.cepal.org/es/comunicados/covid-19-tendra-graves-efectos-la-economia-mundial-impactara-paises-america-latina>
- Chinazzi, M., Davis, J. T., Ajelli, M., Gioannini, C., Litvinova, M., Merler, S., & Viboud, C. (2020). The effect of travel restrictions on the spread of the 2019 novel coronavirus (COVID-19) outbreak. *Science*, 368(6489), 395-400. <https://doi.org/10.1126/science.aba9757>
- CONEVAL. (2020). La política social en el contexto de la pandemia por el virus SARS-CoV-2 (COVID-19) en México. [https://www.coneval.org.mx/Evaluacion/IEPSM/Documents/Politica\\_Social\\_COVID-19.pdf](https://www.coneval.org.mx/Evaluacion/IEPSM/Documents/Politica_Social_COVID-19.pdf)
- COVID, T. C., & Team, R. (2020). Severe Outcomes Among Patients with Coronavirus Disease 2019 (COVID-19)-United States, February 12-March 16, 2020. *MMWR Morb Mortal Wkly Rep*, 69(12), 343-346. <https://stacks.cdc.gov/view/cdc/85951>
- Da Silva N. K. W. A. (2020). Mapeamento da COVID-19 no Estado da Paraíba: Elementos para a espacialização e análise em ambiente SIG. *Metodologias e Aprendizado*, 3, 24-39. <https://doi.org/10.21166/metapre.v3i0.1301>
- Dagnino, R., Weber, E. J., & Panitz, L. M. (2020). Monitoramento do Coronavírus (Covid-19) nos municípios do Rio Grande do Sul, Brasil. *SocArXiv*. March, 28. <https://doi.org/10.1016/j.arcmed.2020.06.010>
- Dong, W., Yang, K., Xu, Q., Liu, L., & Chen, J. (2017). Spatio-temporal pattern analysis for evaluation of the spread of human infections with avian influenza A (H7N9) virus in China, 2013–2014. *BMC Infectious Diseases*, 17(1), 704. <https://doi.org/10.1186/s12879-017-2781-2>

- Edelmann, D., Richards, D., & Vogel, D. (2017). The distance standard deviation. arXiv preprint arXiv:1705.05777. <https://arxiv.org/abs/1705.05777>
- Forster, P. M., Forster, H. I., Evans, M. J., Gidden, M. J., Jones, C. D., Keller, C. A., & Schleussner, C. F. (2020). Current and future global climate impacts resulting from COVID-19. *Nature Climate Change*, 10(10), 913-919. <https://doi.org/10.1038/s41558-020-0883-0>
- Gaona P. E. B., Mundo R. V., Méndez G. I., Gómez A. L. M., Ávila A. M. A., Cuevas N. L., & Shamah L., T. (2020). Vulnerabilidad, conocimiento sobre medidas de mitigación y exposición ante COVID-19 en adultos de México: Resultados de la ENSARS-CoV-2. *Salud Pública de México*, 1-20. <https://doi.org/10.21149/11875>
- Ghanbarian, M., Mahdavi, S., Enayatrada, M., Zare, F., MajidNia, M., Emamian, M. H., & Sheibani, H. (2020). Spatial Distribution of COVID-19 in Shahroud, Iran Using GIS. <https://doi.org/10.20944/preprints202007.0018.v1>
- Govindan, K., Mina, H., & Alavi, B. (2020). A decision support system for demand management in healthcare supply chains considering the epidemic outbreaks: A case study of coronavirus disease 2019 (COVID-19). *Transportation Research Part E: Logistics and Transportation Review*, 138, 101967. <https://doi.org/10.1016/j.tre.2020.101967>
- Hashimoto, S., Yoshiki, S., Saeki, R., Mimura, Y., Ando, R., & Nanba, S. (2016). Development and application of traffic accident density estimation models using kernel density estimation. *Journal of traffic and transportation engineering (English edition)*, 3(3), 262-270. <https://doi.org/10.1016/j.jtte.2016.01.005>
- Huang, C., Wang, Y., Li, X., Ren, L., Zhao, J., Hu, Y., & Cheng, Z. (2020). Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. *The lancet*, 395(10223), 497-506. [https://doi.org/10.1016/S0140-6736\(20\)30183-5](https://doi.org/10.1016/S0140-6736(20)30183-5)
- INEGI, (2019). División política estatal 1:250000. Escala: 1:250000. Edición: 1. Instituto Nacional de Estadística y Geografía.
- Irwansyah, E., Budiharto, W., Widhyatmoko, D., Istamar, A., & Panghurian, F. P. (2020). Monitoring Coronavirus COVID-19/SARS-CoV-2 Pandemic using GIS Dashboard: International and Indonesia Context. <https://doi.org/10.20944/preprints202008.0415.v1>
- JHU (2020). Johns Hopkins Coronavirus Resource Center. <https://coronavirus.jhu.edu/>
- Jia, P., Xue, H., Yin, L., Stein, A., Wang, M., & Wang, Y. (2019). Spatial technologies in obesity research: current applications and future promise. *Trends in Endocrinology & Metabolism*, 30(3), 211-223. <https://doi.org/10.1016/j.tem.2018.12.003>
- Kanga, S., Meraj, G., Farooq, M., Nathawat, M. S., & Singh, S. K. (2020). Risk assessment to curb COVID-19 contagion: A preliminary study using remote sensing and GIS. <https://orcid.org/0000-0003-2913-9199>
- Kent, J., & Leitner, M. (2007). Efficacy of standard deviational ellipses in the application of criminal geographic profiling. *Journal of Investigative Psychology and Offender Profiling*, 4(3), 147-165. <https://doi.org/10.1002/jip.72>
- Lyseen, A. K., Nøhr, C., Sørensen, E. M., Gudes, O., Geraghty, E. M., Shaw, N. T., & Bivona-Tellez, C. (2014). A review and framework for categorizing current research and development in health related geographical information systems (GIS) studies. *Yearbook of medical informatics*, 9(1), 110. <https://doi.org/10.15265/IY-2014-0008>
- MEA (2005). *Ecosystems and Human Well-being: Synthesis*. Island Press, Washington, DC.

- Melin, P., Monica, J. C., Sanchez, D., & Castillo, O. (2020). Analysis of Spatial Spread Relationships of Coronavirus (COVID-19) Pandemic in the World using Self Organizing Maps. *Chaos, Solitons & Fractals*, 109917. <https://doi.org/10.1016/j.chaos.2020.109917>
- Mitchel, A. (2005). *The ESRI Guide to GIS analysis, Volume 2: Spatial measurements and statistics*. ESRI Guide to GIS analysis.
- Moreno, J. A. (1991). Modelización cartográfica de densidades mediante estimadores Kernel. *Treballs de la Societat Catalana de Geografia*, 155-170. <https://doi.org/10.2436/TSCG.V0I30.36881>
- Mousavi, S. H., Zahid, S. U., Wardak, K., Azimi, K. A., Hosseini, S. M. R., Wafae, M., & Bonilla-Aldana, D. K. (2020). Mapping the Changes on Incidence, Case Fatality Rates and Recovery Proportion of COVID-19 in Afghanistan Using Geographical Information Systems. *Archives of Medical Research*. <https://doi.org/10.1016/j.arcmed.2020.06.010>
- Mukherjee, F., & Rajendran, V. (2015). Measuring Spatial and Temporal Distribution of Nonviolent Crime Using Multiple Methods. *Papers in Applied Geography*, 1(3), 279-285. <https://doi.org/10.1080/23754931.2015.1014701>
- Nath, B., Majumder, S., Rahman, M. M., & Sen, J. (2020). Dealing with Covid-19 infections in Kolkata, India: A GIS based risk analysis and implications for future scenarios. *medRxiv*. <https://doi.org/10.1101/2020.08.31.20185215>
- Nicola, M., Alsafi, Z., Sohrabi, C., Kerwan, A., Al-Jabir, A., Iosifidis, C., ... & Agha, R. (2020). The socio-economic implications of the coronavirus pandemic (COVID-19): A review. *International journal of surgery (London, England)*, 78, 185. <https://doi.org/10.1016/j.ijssu.2020.04.018>
- OMS, (2020). Organización Mundial de la Salud. [https://www.who.int/csr/swine\\_flu/Preparacion\\_Pand\\_ESP.pdf](https://www.who.int/csr/swine_flu/Preparacion_Pand_ESP.pdf)
- Orozco, O. S. R., Orozco, S. A., Alvarez, I. A. G., & Radaios, V. (2020). The impact of mobility restriction measures on the reproduction index of Covid-19 in the city of Queretaro, Mexico. *medRxiv*. <https://doi.org/10.1101/2020.09.06.20189373>
- Padilla S. F., Maya F. L., & Ferman C. F. (2020). COVID-19 en México: Panorama Epidemiológico. *Revista Cadena de Cerebros*, 4(1), 31-42. <https://doi.org/10.5281/zenodo.3926806>
- Parrott, R., Volkman, J. E., Lengerich, E., Ghetian, C. B., Chadwick, A. E., & Hopfer, S. (2010). Using geographic information systems to promote community involvement in comprehensive cancer control. *Health communication*, 25(3), 276-285. <https://doi.org/10.1080/10410231003711755>
- Pourghasemi, H. R., Pouyan, S., Heidari, B., Farajzadeh, Z., Shamsi, S. R. F., Babaei, S., & Safaeian, R. (2020). Spatial modeling, risk mapping, change detection, and outbreak trend analysis of coronavirus (COVID-19) in Iran (days between February 19 and June 14, 2020). *International Journal of Infectious Diseases*, 98, 90-108. <https://doi.org/10.1016/j.ijid.2020.06.058>
- Pulido, D., Basurto, D., Cándido, M., & Salas, J. (2020). Geospatial Spread of the COVID-19 Pandemic in Mexico. *arXiv preprint arXiv:2006.07784*. <https://arxiv.org/pdf/2006.07784.pdf>
- Rizwan, M., Wan, W., & Gwiazdzinski, L. (2020). Visualization, Spatiotemporal Patterns, and Directional Analysis of Urban Activities Using Geolocation Data Extracted from LBSN.

- ISPRS International Journal of Geo-Information, 9(2), 137.  
<https://doi.org/10.3390/ijgi9020137>
- Rob, M. A. (2003). Applications of geographical information systems in understanding spatial distribution of asthma. *Informing Science*, 6, 89-99. <https://doi.org/10.28945/516>
- Rosenkrantz, L., Schuurman, N., Bell, N., & Amram, O. (2020). The need for GIScience in mapping COVID-19. *Health & Place*, 102389. <https://doi.org/10.1016/j.healthplace.2020.102389>
- Sánchez, V.A. (2020). Impacto de la crisis del COVID-19 en la distribución del ingreso en la Ciudad de México. *Contaduría y administración*, 65(4), 4. <http://dx.doi.org/10.22201/fca.24488410e.2020.3016>
- Santana, G. (2020). Vulnerabilidad diferencial de los Estados mexicanos frente al COVID-19. *Posición*, Revista de la Universidad de Luján, 3. [https://716132a6-9cf5-45de-bace-6a15e46210f7.filesusr.com/ugd/df634b\\_032caac2c6594df893b4808634950563.pdf](https://716132a6-9cf5-45de-bace-6a15e46210f7.filesusr.com/ugd/df634b_032caac2c6594df893b4808634950563.pdf)
- Santhosh, D., & Srinivas, V. V. (2013). Bivariate frequency analysis of floods using a diffusion based kernel density estimator. *Water Resources Research*, 49(12), 8328-8343. <https://doi.org/10.1002/2011WR010777>
- Sarfo, A. K., & Karuppanan, S. (2020). Application of geospatial technologies in the covid-19 fight of Ghana. *Transactions of the Indian National Academy of Engineering*, 5(2), 193-204. <https://doi.org/10.1007/s41403-020-00145-3>
- Sarkar, S. K. (2020). COVID-19 Susceptibility Mapping Using Multicriteria Evaluation. *Disaster Medicine and Public Health Preparedness*, 1-17. <https://doi.org/10.1017/dmp.2020.175>
- Sarukhán, J. (2006). *Capital natural y bienestar social*. México DF: Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. <https://www.biodiversidad.gob.mx/pais/capitalNatMex.html>
- Sarukhán, J., et al. 2017. *Capital natural de México. Síntesis: evaluación del conocimiento y tendencias de cambio, perspectivas de sustentabilidad, capacidades humanas e institucionales*. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad, México.
- Sepehrvand, N., Alemayehu, W., Kaul, P., Pelletier, R., Bello, A. K., Welsh, R. C., & Ezekowitz, J. A. (2020). Ambulance use, distance and outcomes in patients with suspected cardiovascular disease: a registry-based geographic information system study. *European Heart Journal: Acute Cardiovascular Care*, 9(1\_suppl), 45-58. <https://doi.org/10.1177/2048872618769872>
- Silverman, B. W. (1981). Using kernel density estimates to investigate multimodality. *Journal of the Royal Statistical Society: Series B (Methodological)*, 43(1), 97-99. <https://doi.org/10.1111/j.2517-6161.1981.tb01155.x>
- Snow, J. (1849). *On the Mode of Communication of Cholera*, London: John Churchill. Snow followed this up with a number of articles that refined his theory. <https://doi.org/10.1038/495169a>
- SSA. (2020). Secretaría de Salud. /Suárez, V., Quezada, M. S., Ruiz, S. O., & De Jesús, E. R. (2020). Epidemiología de COVID-19 en México: del 27 febrero al 30 de abril de 2020. *Revista Clínica Española*. <https://doi.org/10.1016/j.rce.2020.05.007>

- Torrealba R. O., Conde G. R. A., & Hernández J. A. L. (2020). Modeling and prediction of COVID-19 in Mexico applying mathematical and computational models. *Chaos, Solitons & Fractals*, 109946. <https://doi.org/10.1016/j.chaos.2020.109946>
- Umaru, T. E., Martins, G. M. I., & Owoyele, S. G. (2015). Effects of Urban Sprawl on Meningococcal Meningitis Incidence in Kaduna Urban Area, Nigeria. *statistics*, 5(8). Recuperado de: <https://core.ac.uk/download/pdf/234674509.pdf>
- Vivanco L. A. (2020). Predicting COVID-19 distribution in Mexico through a discrete and time-dependent Markov chain and an SIR-like model. *arXiv preprint arXiv:2003.06758*. recuperado de: <https://arxiv.org/abs/2003.06758>
- Wang, B., Shi, W., & Miao, Z. (2015). Confidence analysis of standard deviational ellipse and its extension into higher dimensional Euclidean space. *PloS one*, 10(3), e0118537. <https://doi.org/10.1371/journal.pone.0118537>
- WHO (2020). Coronavirus disease 2019 (COVID-19) situation report–57. Geneva, Switzerland: World Health Organization; 2020. [https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200317-sitrep-57-covid-19.pdf?sfvrsn=a26922f2\\_2](https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200317-sitrep-57-covid-19.pdf?sfvrsn=a26922f2_2)
- Yuill, R. S. (1971). The standard deviational ellipse; an updated tool for spatial description. *Geografiska Annaler: Series B, Human Geography*, 53(1), 28-39. <https://doi.org/10.1080/04353684.1971.11879353>
- Zambrano, L. I., Sierra-Santos, M. A., Mejía-Santos, H. M., Palou, E. Y., Muñoz-Lara, F., Lorenzana, I., & Valladares-Rosa, V. M. (2020). Spatial Distribution of COVID-19 in Honduras at the Early Phase of the Pandemic Using Geographic Information Systems (GIS). <https://doi.org/10.20944/preprints202006.0153.v1>
- Zepka, B., Anis, M., Keith, J. D., Barksdale, D., & Rivera, C. (2019). Peer Reviewed: Using Geographic Information Systems to Highlight Diabetes Prevention Program Expansion Areas in Pennsylvania. *Preventing chronic disease*, 16. <https://doi.org/10.5888/pcd16.180493>
- Zhang, S., Diao, M., Yu, W., Pei, L., Lin, Z., & Chen, D. (2020). Estimation of the reproductive number of novel coronavirus (COVID-19) and the probable outbreak size on the Diamond Princess cruise ship: A data-driven analysis. *International journal of infectious diseases*, 93, 201-204. <https://doi.org/10.1016/j.ijid.2020.02.033>
- Zhou, C., Su, F., Pei, T., Zhang, A., Du, Y., Luo, B., & Song, C. (2020). COVID-19: Challenges to GIS with big data. *Geography and Sustainability*. <https://doi.org/10.1016/j.geosus.2020.03.005>