

# Cartografía epidemiológica: comparación de tres métodos de análisis espacial con SIG y software libre para la COVID-19 en Málaga, España

Epidemiological cartography: Comparison between three methods by using GIS and free software for COVID-19 in Malaga, Spain

Sebastián Alejandro Vargas Molina<sup>1</sup>

*Recibido 4 de enero de 2025; aceptado 14 de marzo de 2025*

## RESUMEN

Este trabajo presenta tres medidas epidemiológicas: tasa de prevalencia, exceso de riesgo y riesgo relativo, junto con su representación en unidades espaciales discretas (distritos censales y celdas de malla) y superficies continuas, superando diferencias entre delimitaciones administrativas. Estos métodos se comparan a escala intraurbana en Málaga, España, usando datos a nivel domiciliario de casos positivos de COVID-19 recolectados durante la fase aguda de la pandemia (2020-2022), los cuales son procesados y analizados con SIG y *software* libre y de código abierto. Los cálculos vectoriales estiman un área de mayor riesgo relativo de 7 km<sup>2</sup>, con 63,655 personas, mientras que los ráster amplían el área a 16 km<sup>2</sup>, con 206,900 personas, y con un riesgo 40% por encima de la prevalencia base. La comparación muestra que las superficies ráster son más sólidas al superar límites espaciales arbitrarios, aunque requieren datos puntuales, usualmente inaccesibles. Por el contrario, las estimaciones basadas en polígonos son menos precisas, y subestiman tanto la extensión del área como a la población en mayor riesgo por mitad, pero el tipo de datos son de mayor disponibilidad. Se concluye que en epidemiología, salud pública y geografía de la salud es crucial comparar indicadores y representaciones cartográficas tanto para la comunicación de

<sup>1</sup> Departamento de Geografía, Universidad de Málaga, España, correo electrónico: [sa.vargasm@uma.es](mailto:sa.vargasm@uma.es).  
ORCID: <https://orcid.org/0000-0002-3668-4606>

resultados adecuados y transparentes, como para la toma de decisiones precisas, y se sugieren pasos siguientes para el análisis.

*Palabras clave: epidemiología, cartografía, Sistema de Información Geográfica, salud pública, análisis espacial.*

## ABSTRACT

This paper presents three epidemiological measures: prevalence rate, excess risk, and relative risk, alongside their representation through both discrete spatial units (such as census districts and grid cells) and continuous surfaces. These methods are compared at an intraurban scale in Málaga, Spain, using household-level positive COVID-19 cases data from the acute phase of the pandemic, spanning 2020 to 2022, which are processed and analyzed with free open-source software and GIS. Vector-based calculations estimate the area of highest relative risk in Málaga to be approximately 7 km<sup>2</sup>, encompassing a population of 63,655 people. In contrast, raster-based calculations estimate an area of 16 km<sup>2</sup>, containing a population of 206,900 people, and a 40% higher risk when compared to baseline prevalence. The comparison demonstrates that raster-based relative risk surfaces are more robust, as they overcome the limitations of arbitrary spatial boundaries. However, generating these surfaces require point-level case data, which is often publicly unavailable. Conversely, polygon-based estimations are less precise, and underestimate both the extent and the amount of population at-risk by half, but rely on more readily accessible aggregated data. The study concludes by emphasizing the importance of comparing between indicators and cartographic representation for both results communication and accurate decision-making in the fields of epidemiology, public health, and health geography, as well as by suggesting further steps in the analysis.

*Key words: epidemiology, cartography, Geographic Information System, public health, spatial analysis.*

## 1. Introducción

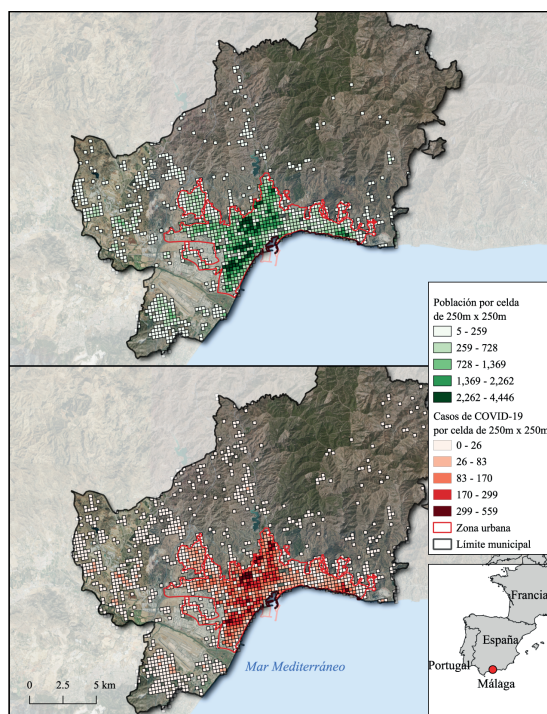
### 1.1 Cartografía epidemiológica y epidemiología espacial

Aunque no hay definición estandarizada sobre el campo de la epidemiología, se trata del estudio de la distribución de los fenómenos de enfermedad a nivel poblacional (Celentano & Szklo, 2020), aunque textos fundacionales incluyen su dimensión temporal y espacial (Susser, 1991). A pesar de esto, los estudios sobre la variación geográfico-espacial de las enfermedades suelen ser menos frecuentes, en comparación con los ensayos clínicos y los estudios temporales (Kirby *et al.*, 2017). No obstante, su relevancia se ha comentado en Iberoamérica desde hace casi cuatro décadas (Narro Robles & Ponce de León, 1986).

Con ello, la epidemiología espacial se ha desarrollado como un campo especializado, sobre todo en Reino Unido y Norteamérica (Walter, 2000). Las contribuciones a este campo suelen venir de las matemáticas y la estadística

aplicadas (Diggle, 2023; Elliot *et al.*, 2001; Kirby *et al.*, 2017; Moraga, 2019), en conjunto con la medicina. Por el contrario, las contribuciones de la geografía, en lo general, han sido menos frecuentes, con la excepción de la geografía de Reino Unido (Cliff & Haggett, 1989; Gatrell *et al.*, 1996; Gatrell & Elliott, 2015). Así, este campo se entiende como aquel enfocado en describir y comprender la variación espacial del riesgo sobre enfermedades, particularmente en áreas pequeñas. De manera general, se subdivide en cuatro grandes áreas, que en la práctica se encuentran estrechamente relacionadas: 1) mapeo de enfermedades, 2) estudios de correlación geográfica, 3) la evaluación del riesgo con respecto de una fuente lineal o puntual, y 4) la detección de conglomerados (*clusters*) de alguna enfermedad en cuestión (Elliot *et al.*, 2001).

Además, una característica fundamental de esta subdisciplina es que se estudia de manera específica al *riesgo relativo* como la variable de interés (Elliot *et al.*, 2001). Partiendo de que la mayoría de los casos registrados de una enfermedad están estrechamente ligados con la cantidad de población en un área dada (Figura 1), el interés cambia inmediatamente a 1) buscar zonas



**Figura 1.** Málaga. Ubicación geográfica de la zona de estudio y distribución espacial de la población y de casos positivos de COVID-19 entre 2020 y 2022. Método de clasificación de los intervalos por quiebres naturales, dada la distribución sesgada del indicador (Slocum *et al.*, 2023).

Fuente: elaboración propia con base en datos de la Tabla 1.

en las que los casos se encuentran bastante por encima (o por debajo) de lo esperado con respecto de la población subyacente, y 2) a intentar explicar estas variaciones a partir de otras covariables. En este sentido, se utilizan una variedad de mediciones e indicadores de carácter relativo, como las aplicadas en este trabajo.

## 1.2 Cartografía epidemiológica en la escala intraurbana, área de oportunidad en Iberoamérica

La cartografía y el análisis espacial en geografía de la salud con Sistemas de Información Geográfica (SIG) tiene una importante trayectoria en Iberoamérica, principalmente en el estudio de la distribución de equipamientos sanitarios, y en mediciones de accesibilidad a los mismos, con ejemplos en México (Garrocho & Campos, 2006; Reyna Sevilla *et al.*, 2013; Terán-Hernández, 2017), Argentina (Briatore *et al.*, 2024; Villanueva, 2010) y España (Escalona Orcao & Díez Cornago, 2003), por mencionar algunos.

Por otro lado, hay esfuerzos de instituciones de salud pública nacionales para la caracterización territorial de los problemas de salud más importantes dentro de sus fronteras, en forma de atlas. Estos trabajos suelen presentar cartodiagramas y mapas coropléticos en escalas nacionales o regionales. En el caso de México, el *Atlas Nacional de Salud en México* (Alcántara-Ayala *et al.*, 2010), y en España, el *Atlas Nacional* con un subsegmento destinado a la Sanidad, aunque enfocado en la infraestructura sanitaria en el país (Instituto Geográfico Nacional, s/f). El de Colombia, por otro lado, sí utiliza mediciones de riesgo relativo, aunque en una escala regional (MINSALUD, 2015).

Y a pesar de que en diferentes latitudes de la región se ha reconocido el potencial de los SIG en epidemiología, los trabajos disponibles en la literatura arbitrada son tribunas o editoriales que dan un breve panorama general para incentivar su uso (Ascuntar-Tello & Jaimes, 2015; Valbuena García & Rodríguez Villamizar, 2018). En otros casos, se aplican métodos de análisis espacial basados en funciones de distancia, las cuáles que ya no utilizan a la cartografía como resultado principal (Abellán *et al.*, 2002).

Mención aparte merece la cuantiosa producción de trabajos enfocados en la COVID-19, los cuáles siguieron técnicas clásicas en cartografía como los atlas nacionales previamente mencionados. Como ejemplo de lo anterior, los mapas de vulnerabilidad a nivel municipal en México (Suárez Lastra *et al.*, 2020) la cartografía producida por el Instituto Geográfico Nacional de España sobre los casos por COVID-19 a nivel de comunidad autónoma (Sancho Comíns & Olcina Cantos, 2021), o la cartografía por sección sanitaria para la provincia de Castilla y León en el mismo país (Andrés López *et al.*, 2021). De manera cercana a la propuesta de este trabajo, García-Morata *et al.* (2022) comparan tasas a nivel de sección censal contra un estudio de casos y controles a nivel puntual en Albacete.

Para Málaga también hubo trabajos enfocados en la descripción de los patrones geográficos de dicha enfermedad, como respuesta a la emergencia

sanitaria (Marín-Cots & Palomares-Pastor, 2020; Perles *et al.*, 2021; Roselló *et al.*, 2021, 2021). En estos trabajos se hicieron propuestas novedosas para analizar y representar la variación geográfica de dicha enfermedad en la escala intraurbana, aunque el uso de los métodos propios de la epidemiología espacial ha quedado pendiente.

No obstante, fuera de Iberoamérica, la producción científica y académica en epidemiología espacial con datos desagregados sí ha sido más cuantiosa, tanto para la COVID-19, como para otras enfermedades. Así, se han elaborado superficies de riesgo relativo a nivel de país para toda Inglaterra (Elson *et al.*, 2021), a nivel de ciudad para Berlín, Alemania (Lambio *et al.*, 2023), así como análisis de autocorrelación espacial con unidades discretas en Irán (Jesri *et al.*, 2021) y Slovakia (Vilínová & Petrikovicová, 2023). Sin embargo, una característica común en estos trabajos es que no se comparan distintas unidades espaciales y medidas epidemiológicas, ni se discuten las implicaciones de estas diferencias (excepto por García-Morata *et al.*, 2022). Por lo tanto, en este trabajo se busca hacer una contribución al respecto, al comparar tres métodos de cartografía epidemiológica aplicados al análisis de la variación geográfica del riesgo relativo por COVID-19 dentro de la ciudad de Málaga, con los objetivos de 1) caracterizar dicho fenómeno, y 2) de explorar las ventajas y limitaciones de estos métodos, dada su importancia para la toma de decisiones en salud pública en su dimensión territorial.

## 2. Metodología

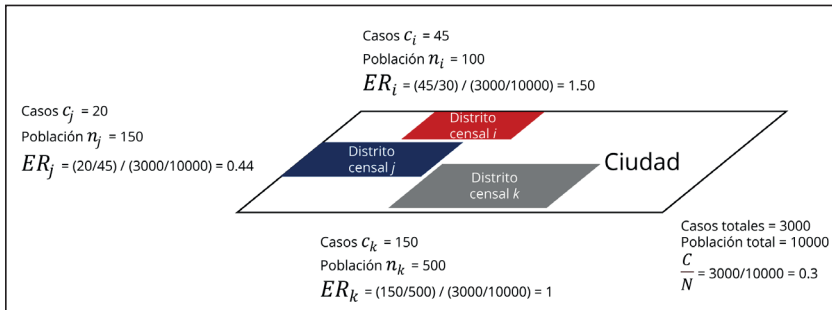
### 2.1 Zona de estudio

El municipio de Málaga se encuentra en la costa sur de España, dentro de los límites de la comunidad autónoma de Andalucía. Forma parte de la zona denominada Costa del Sol, a las orillas del Mar Mediterráneo. Su ubicación geográfica en conjunto con su patrimonio histórico y cultural, han establecido a esta ciudad como un importante destino turístico.

Demográficamente, en toda su extensión habitan aproximadamente 578,063 personas, aunque la mayoría se concentra en la zona urbana, con ~545,000 habitantes.

Urbanísticamente hablando, se trata de una ciudad compacta y policéntrica, con una extensión de ~46 km<sup>2</sup>, en la que el grueso de las viviendas son edificios plurifamiliares. De allí que su densidad poblacional promedio sea de 11,800 personas por km<sup>2</sup>.

Sobre el fenómeno de interés, y como puede notarse, el patrón de la densidad poblacional está estrechamente ligada con el de los casos totales (Figura 1), lo que refuerza el interés de la epidemiología espacial por el análisis del riesgo relativo.



**Figura 2.** Cálculo del Exceso de Riesgo con cantidades artificiales.

Fuente: elaboración propia.

## 2.2 Materiales

Para el análisis se utilizó el conjunto de datos de casos positivos de la enfermedad, y datos censales de población. Los primeros son el total de datos a nivel domiciliario de casos de COVID-19 (n= 60,165) detectados por pruebas PCR y de antígenos, provistas por el Hospital Regional de Málaga. Cabe mencionar que estos datos no están disponibles para el público en general, en concordancia con la legislación de España (Ley Orgánica 3/2018), las regulaciones de la Unión Europea (2016/679) y la Declaración de Helsinki (Principio 24).

Dichos datos se geocodificaron siguiendo los procedimientos diseñados por Perles, Sortino y Mérida (2021) para obtener una capa de datos vectoriales con la ubicación puntual de los casos positivos, pues estos autores trabajaron con un subconjunto de estos datos cuando la pandemia estaba en curso.

Para los datos poblacionales se utilizaron los resultados del Censo Anual de Población 2024, del Instituto Nacional de Estadística de España (INE).

Sobre las capas base utilizadas, es recurrente que, en términos administrativos y de gestión de datos, aquellos recolectados por instituciones públicas sean agregados en diferentes niveles y tipos de unidades geográficas, como regiones, estados, comunidades o departamentos, por mencionar algunos ejemplos en Iberoamérica.

La unidad más pequeña suele tomar la forma de bloque, sección o distrito censal, generalmente a escala intraurbana. Éstos son polígonos de áreas y formas muy variadas, lo que vuelve difícil su comparación, y expone el Problema de la Unidad de Área Modificable (MAUP por sus siglas en inglés), en el cual los resultados del análisis (como la detección de conglomerados o la correlación entre variables) están condicionados por el tamaño y forma de los polígonos con datos agregados (Openshaw & Taylor, 1979).

Para superar estas limitaciones, el Instituto de Estadística y Cartografía de Andalucía (IECA) desarrolló una rejilla con datos censales para una resolución mayor, con cuadrantes de 250x250 metros, lo cual permite superar algunas limitaciones de otro tipo de polígonos administrativos (Escudero-Tena *et al.*, 2023), aunque el tamaño y la forma de la celda son problemas en sí mismos. En la Tabla 1 resume el conjunto de datos utilizados en el trabajo.

**Tabla 1.** Conjuntos de datos utilizados

<i>Conjunto de datos</i>	<i>Fuente</i>	<i>Disponibilidad</i>
Casos positivos de COVID-19	Hospital Regional de Málaga	Datos no disponibles al público en general
Población total por sección censal	Censo Anual de Población 2024	Instituto Nacional de Estadística (España)
Capa de secciones censales	Cartografía secciones censales y callejero de Censo Electoral	Instituto Nacional de Estadística (España)
Malla estadística 250m x 250m	Datos espaciales en malla estadística	IECA
Polígono municipal de Málaga	Datos Espaciales de Referencia de Andalucía	IECA
Área urbana de Málaga	Datos Espaciales de Referencia de Andalucía	IECA
Ortofotografía en color, pancromática e infrarrojos a 0,25 metros/píxel (año 2022)	Imágenes y ortofotografías	IECA

**Fuente:** elaboración propia.

## 2.3 Instrumentos y herramientas

Todas las medidas epidemiológicas calculadas, así como la cartografía resultante, fueron producidos con *software* libre y de código abierto, lo que puede permitir que este tipo de análisis pueda replicarse con mayor facilidad y apertura.

Para el procesamiento general de capas y el diseño cartográfico, se utilizó QGIS ver. 3.40 Bratislava. El cálculo del exceso de riesgo, así como de los conglomerados mediante la  $I$  de Moran local, fue realizado con GeoDa ver. 1.22.0.2 (Anselin, 2019). Finalmente, el cálculo de la superficie de riesgo relativo fue realizado mediante el lenguaje de programación R, y, en específico, las librerías especializadas en estadística espacial sobre datos puntuales *spatstat* (Baddeley *et al.*, 2016) y en epidemiología espacial *sparr* (Davies *et al.*, 2011, 2018).

## 2.4 Mediciones

La tasa de prevalencia (Celentano & Szkló, 2020; Villa Romero *et al.*, 2011) es una medida puntual en el tiempo  $t$  que estima el total de casos en relación con la población en la cual podría ocurrir. Puede expresarse como proporción, porcentaje o tasa con algún número de base 10. En este caso, a la notación también se añade el área  $i$ , que puede representar una sección censal dada, o una celda dentro de la rejilla disponible. El resultado se multiplica por 1000, para tener una tasa por cada 1000 habitantes, y así facilitar la interpretación del resultado mostrado cartográficamente (Ecuación 1).

$$P_{ti} = (C_{ti}/N_{ti}) \times 1000 \quad (1)$$

El Exceso de Riesgo  $ER_i$  (Anselin, 2024) aparece con varios sinónimos en la literatura especializada, por lo que también se le conoce como Razón de Incidencia Estandarizada (SIR por sus siglas en inglés), y como Razón de Mortalidad Estandarizada (SMR por sus siglas en inglés) cuando se trata de defunciones (Anselin, 2024; Moraga, 2019).

Con esta medición se busca describir si hay más o menos riesgo con respecto de una línea base, como lo puede ser la prevalencia general. Nominalmente, se adopta el término propuesto por Luc Anselin, dado que así está implementado en el SIG GeoDa. Pero, para su exposición, formalmente se adopta una expresión similar a la usada por el Centro de Control de Enfermedades (CDC por sus siglas en inglés) (2022), dada su sencillez de cálculo (Ecuación 2).

$$ER_i = \frac{c_i}{n_i} / \frac{C}{N} \quad (2)$$

En la que  $\frac{c_i}{n_i}$  representa la proporción casos observados con respecto de la población dentro de una unidad de observación  $i$  (barrio, sección censal, condado, celda en una rejilla), y  $\frac{C}{N}$  representa la proporción de casos totales, con respecto de la población total en la ciudad o región de interés. Para Málaga, considerando la fase aguda como un periodo en sí mismo, esta es de  $60,165/578,063 = .104$ , o 10.4%.

Su interpretación es como sigue: si  $ER_i = 1$ , el riesgo en la zona  $i$  es igual a la tasa general; si  $ER_i < 1$ , el riesgo en la zona  $i$  es menor que lo esperado; finalmente, si  $ER_i > 1$ , el riesgo es mayor que lo esperado.

Nótese que el cálculo tiene como base la tasa de prevalencia mencionada, pero en lugar de tratar con cantidades específicas, se busca dilucidar si en una zona dada la enfermedad es mayor o menor a la proporción general de toda el área de estudio (Figura 2). De allí que se intente medir el exceso de riesgo.

Luego, es posible evaluar espacialmente a las dos mediciones previas mediante el Índice  $I_i$  de Moral Local (Anselin, 1995, 2024).

El objetivo principal de este procedimiento es el de hacer inferencias sobre la distribución y configuración espacial de la variable de interés (Fotheringham & Brunson, 2004); en este caso, la tasa de prevalencia y el exceso de riesgo. Así, la hipótesis nula corresponde con una configuración aleatoria, mientras que se cuenta con dos hipótesis alternativas: la dispersión o la concentración de unidades similares en cuanto a la variable de interés.

Formalmente, se toma el estadístico global  $I$  de Moran, que resume la autocorrelación espacial en una sola medida resumen para toda el área de estudio (Ecuación 3).

$$I = \frac{\sum_i \sum_j w_{ij} z_i z_j}{\sum_i z_i^2} \quad (3)$$


En la que  $z_i = x_i - \bar{x}$ . Luego, éste se adapta para cada una de las unidades de observación (sección censal, celda de malla), en donde autocorrelación sólo se calcula únicamente para los polígonos vecinos  $j$  (Ecuación 4).

$$I_i = z_i \sum_j w_{ij} z_j \tag{4}$$

La significancia estadística de  $I_i$  se evalúa mediante permutaciones de los valores calculados (habitualmente entre 99 y 99,999), para estimar la probabilidad de que el arreglo espacial observado fuera producto del azar. Esto permite reclasificar a todo el conjunto de unidades espaciales en cinco categorías, en función de su ubicación en el diagrama de dispersión de la  $I$  de Moran global: sin significancia, alto-alto, bajo-bajo, alto-bajo, y bajo-alto (Anselin, 1995, 2024).

Es importante notar que, de manera predeterminada, el nivel de significancia estadística establecido por este algoritmo es de  $p < 0.05$ , el cual puede ser demasiado laxo en análisis basados en permutaciones, limitando su utilidad a una exploración inicial de patrones espaciales. Por lo anterior, Luc Anselin (2024), desarrollador del método y del *software* recomienda trabajar con niveles más bajos ( $p < 0.01$  o incluso  $< 0.001$ ), para filtrar con mayor certeza las ubicaciones en las que los valores son demasiado atípicos como para ser producto del azar, y que pueden deberse a otras covariables de interés.

Finalmente, para representaciones continuas, puede calcularse una superficie de riesgo relativo (Davies *et al.*, 2018).



**Figura 3.** Esquema del cálculo de las superficies de densidad tipo *kernel* para casos y controles con valores artificiales.

Fuente: elaboración propia.

El detalle técnico y formal de las superficies de densidad tipo *kernel* es abordado en otros trabajos (Baddeley *et al.*, 2016; Fotheringham *et al.*, 2024; O'Sullivan & Unwin, 2010). Básicamente, se trata de cuantificar la densidad de puntos dentro de un ancho de banda (*bandwidth*) determinado. De esta manera, se pasa de la representación vectorial de puntos, a la representación continua tipo ráster, lo que permite visualizar con mayor facilidad las zonas con mayor concentración del fenómeno de interés (Figura 3).

Así, se trata del cálculo de una tasa simple, pero a nivel de píxel en una capa tipo ráster, en lugar de una unidad discreta como una sección censal. Y al igual que con el exceso de riesgo, se trata de una medida estandarizada, aunque en una escala logarítmica para evitar que divisiones entre valores muy pequeños arrojen sobreestimaciones artificiales. Formalmente, la superficie de riesgo relativo se expresa como sigue (Davies *et al.*, 2018; Sarojinie Fernando & Hazelton, 2014) (Ecuación 5):

$$RR = \log \left( \frac{f(x)}{g(x)} \right) \quad (5)$$

En donde *RR* es el riesgo relativo,  $f(x)$  es la densidad de probabilidad de la capa de puntos de casos, y  $g(x)$  la de los controles, o, en otras palabras, la población susceptible, la cual generalmente se trata de una capa de puntos que simula a la población subyacente, con base en la cantidad de población en cada polígono de una capa con datos censales (Gatrell *et al.*, 1996; González & Moraga, 2023). En términos de SIG, se trata de la producción de dos “mapas de calor” con un ancho de banda similar.

Sin embargo, la selección del ancho de banda es un aspecto crucial en este tipo de análisis, pues la extensión del fenómeno, en este caso el riesgo relativo, puede ser fácil y arbitrariamente reducido o expandido. En ese sentido, la paquetería *sparr* está diseñada específicamente para superar limitaciones de los algoritmos tradicionales en distintos SIG, pues en lugar de un ancho de banda fijo, el paquete utiliza uno adaptativo (Davies *et al.*, 2018), es decir, que en zonas con muchos casos, el ancho de banda disminuya (para evitar sobreestimaciones), y en zonas con pocos, aumente (para evitar subestimaciones).

Con la selección del ancho de banda adaptativa, ambas capas son sometidos a una operación de álgebra de mapas, en la que el ráster de densidad de casos se divide entre el ráster de densidad de controles. A dicha división se aplica el logaritmo natural, lo que resulta en una superficie en escala logarítmica. Su interpretación es similar al Exceso de Riesgo. Así,  $RR = 0$  implica un riesgo relativo similar al general de toda el área de estudio;  $RR > 0$  implica un riesgo relativo mayor al esperado, y  $RR < 0$ , un riesgo relativo menor.

## 2.5 Procedimientos

En esta sección se indican, de manera resumida, las herramientas y los (geo) procesos utilizados en cada una para lograr los resultados presentados. En principio, este flujo de trabajo puede ser replicado para cualquier área de

estudio y evento de salud-enfermedad de interés, siempre que se dispongan de los datos necesarios.

El proceso comienza en QGIS, cargando las capas necesarias: puntos que representan casos y polígonos como secciones censales o una malla cuadrículada. Para contar los puntos dentro de los polígonos, se utiliza la herramienta "Contar puntos en polígonos", lo que genera un nuevo atributo en la capa de polígonos con el conteo correspondiente. Este resultado se guarda como un archivo *shapefile* con coordenadas proyectadas.

Luego, para generar una capa combinada de casos y controles, se crean puntos aleatorios limitados por los polígonos seleccionados, tomando como referencia el atributo de población para definir el número de puntos. Un aspecto importante de este algoritmo es que los puntos pueden asignarse en ubicaciones en las que no hay viviendas o asentamientos humanos, por lo que es importante contar con una capa de referencia, de manzanas o edificios, que permita asegurar que no se están creando controles en lugares deshabitados. Los puntos generados se combinan con los casos existentes, y la capa resultante se guarda en formato *shapefile*, con coordenadas proyectadas.

En GeoDa, se importa el *shapefile* que contiene el conteo de casos. Así, se calculan las tasas crudas a partir de los atributos de casos y población, y también el exceso de riesgo, guardando ambos resultados como nuevos atributos en la tabla de datos. Posteriormente, se genera una matriz de pesos espaciales de tipo "Reina" para analizar las relaciones espaciales entre polígonos vecinos. Con esta matriz, se realiza un análisis de autocorrelación espacial utilizando la de *I* Moran Local, identificando patrones espaciales significativos que también se guardan como atributos adicionales. Finalmente, el *shapefile* enriquecido se exporta para ser utilizado en pasos posteriores.

En R (R Studio), se preparan los datos cargando librerías especializadas como *spatstat*, *sparr*, *raster* y *sf*. Las capas de puntos y el polígono de la zona de estudio se importan para crear un objeto de tipo "colección de puntos" (*ppp*), que luego se subdivide (*subset*) en entre casos y controles. Usando estas colecciones, se calcula un ancho de banda óptimo y se genera una superficie de riesgo relativo, adaptando el análisis para identificar zonas de riesgo con significancia estadística. Estas zonas se exportan como archivos ráster que representan tanto la superficie de riesgo como las áreas con p-valores significativos ( $p < 0.05$ ).

Finalmente, en QGIS se realiza la composición cartográfica y la comparación de resultados. Se cargan las capas enriquecidas y los rásteres generados, configurando mapas temáticos con simbología adecuada para visualizar tasas, exceso de riesgo, y resultados del *I* de Moran Local. Los rásteres de riesgo relativo y significancia estadística se representan con bandas de pseudocolor y con una paleta de colores opuestos. Para complementar el análisis, se superponen las áreas de mayor riesgo con datos poblacionales mediante una intersección geoespacial, permitiendo estimar el tamaño de área y la población afectada en las zonas identificadas como de mayor riesgo.

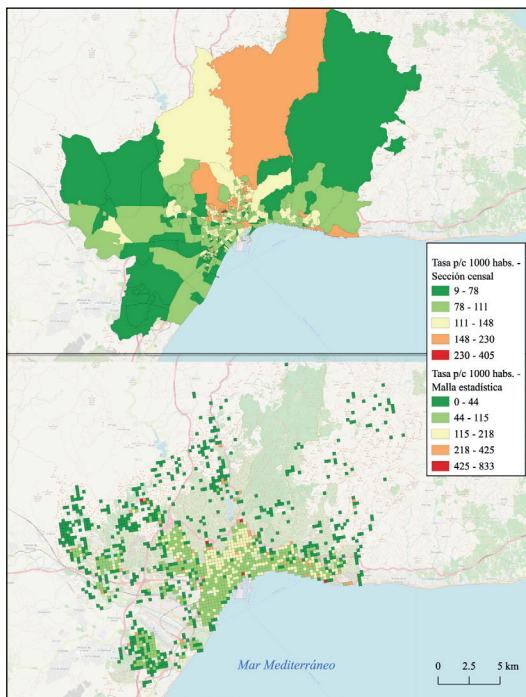
Para las unidades discretas (áreas censales y celdas de la malla estadística), se pueden resumir el área y población totales del conglomerado alto-alto

del exceso de riesgo, y así comparar los resultados entre indicadores y unidades espaciales.

### 3. Resultados

En esta sección se presentan las diferencias entre mediciones epidemiológicas y tipos de unidades espaciales, así como la comparación entre el área y población de riesgo relativo resaltado por cada método, y la comparación entre el riesgo relativo alto estadísticamente significativo contra la prevalencia base para la zona urbana de Málaga, al ser el epicentro de la crisis sanitaria. Las implicaciones de estos aspectos, así como los de su representación cartográfica, se comentan detalladamente en la discusión.

Primero, al utilizar secciones censales de gran extensión, sobresalen aquellas que aparecen marcadas con una tasa de prevalencia alta (Ecuación 1), dando la impresión de un problema de gran extensión. No obstante, cuando el mismo indicador se expresa con ayuda de una rejilla regular que únicamente marca zonas en donde hay población, es evidente que se trata de una zona des poblada (Figura 4).

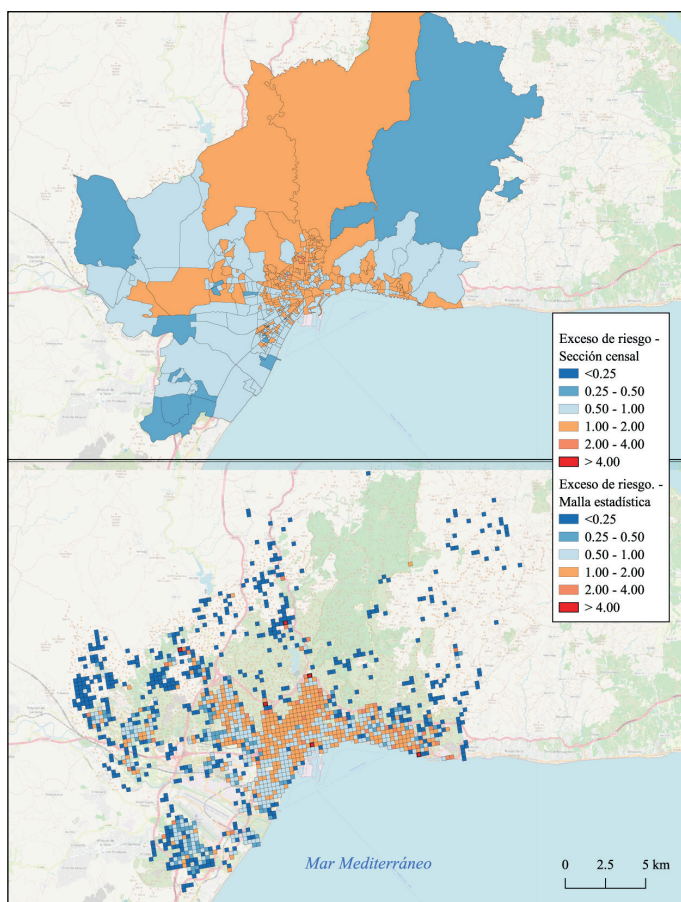


**Figura 4.** Tasa de prevalencia de COVID-19 p/c 1000 hab. Comparación entre secciones censales y malla estadística. Método de clasificación de los intervalos por quiebres naturales, dada la distribución sesgada del indicador (Slocum *et al.*, 2023).

Fuente: elaboración propia con base en datos de la Tabla 1.

Por ello, cuando se toma un fenómeno de salud-enfermedad medido a través de una tasa de prevalencia, es notorio cómo puede distorsionarse la variación geográfica de la distribución de una enfermedad cuando se utilizan secciones censales como unidades geográficas.

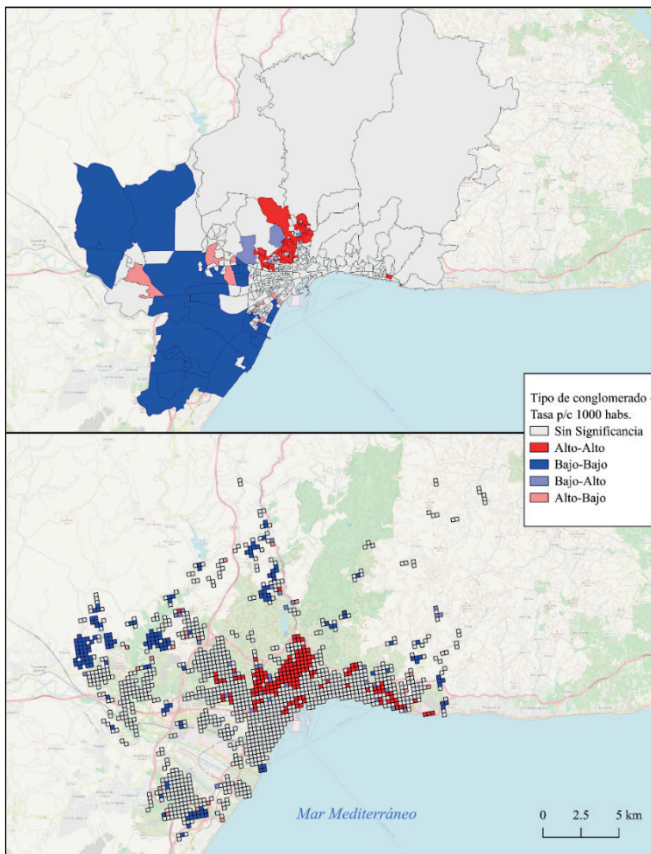
No obstante, el problema se mantiene cuando se utiliza una medición estandarizada. Así, cuando se expresa la distribución y variación geográfica de una enfermedad a través del exceso de riesgo (Ecuación 2), la variabilidad en forma y tamaño de las secciones censales puede tener el efecto de que dos zonas distintas de la ciudad parezcan similares, las cuáles desaparecen cuando se utiliza una rejilla regular (Figura 5).



**Figura 5.** Exceso de riesgo de COVID-19. Comparación entre secciones censales y malla estadística. Método de clasificación por intervalos iguales, dada la simetría propia del indicador. Paleta de colores orientada al contraste de valores divergentes (Anselin, 2019).

Fuente: elaboración propia con base en datos de la Tabla 1.

Luego, un problema compartido tanto por la tasa de prevalencia como por el exceso de riesgo es la dificultad de detectar visualmente conglomerados de valores altos de una u otra medición. En este sentido, los indicadores locales de asociación espacial (LISA por sus siglas en inglés) como la  $I$  de Moran Local (Ecuaciones 3 y 4) son de gran utilidad para detectar conglomerados estadísticamente significativos. En este sentido, se vuelve indistinto calcular estos conglomerados a partir de la tasa de prevalencia o del exceso de riesgo, pues el segundo se construye con base en el primero (Figura 6).



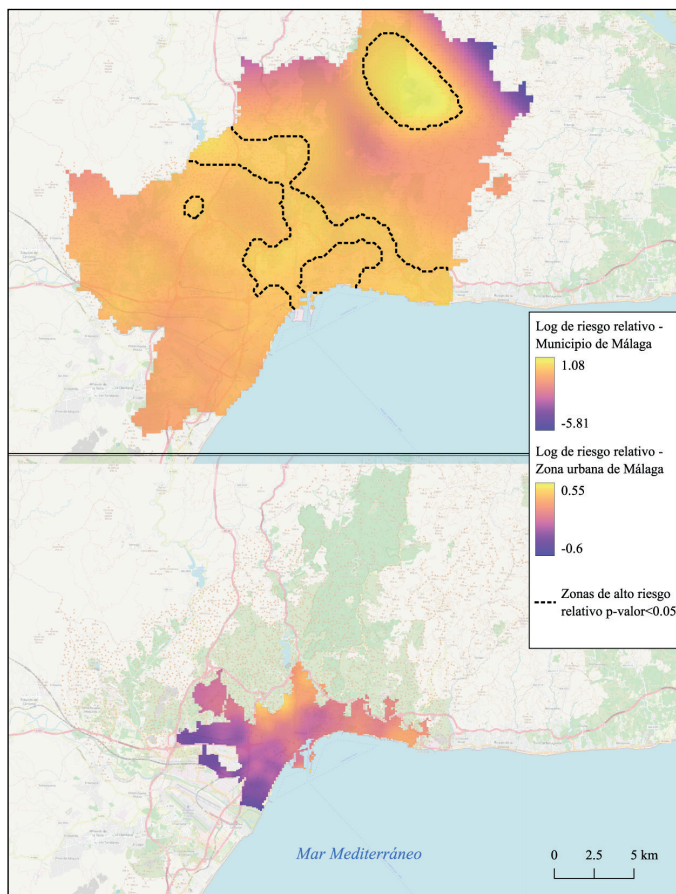
**Figura 6.** Conglomerados estadísticamente significativos de valores altos de la tasa de COVID-19 p/c 1000 hab. Comparación entre secciones censales y malla estadística.

Fuente: elaboración propia con base en datos de la Tabla 1.

Por otro lado, las superficies continuas de riesgo relativo se muestran particularmente sensibles al cambio en escala de la unidad de análisis. En este tipo de representación se superan las limitaciones presentes en los distintos

tipos de unidades administrativas, a saber, su arbitrariedad. Pero, al tratarse de una representación “difuminada”, la variación geográfica puede representarse más o menos concentrada en función de la extensión del área de estudio.

Así, el riesgo relativo muestra márgenes mayores y zonas con significancia estadística en un área de mayor extensión, como el municipio de Málaga en su totalidad, y, al contrario, cuando sólo se considera la zona urbana, que es en donde se concentran la gran mayoría de los casos (Figura 7).



**Figura 7.** Riesgo relativo de COVID-19. Comparación entre el municipio de Málaga y su zona urbana.

Fuente: elaboración propia con base en datos de la Tabla 1.

Finalmente, ha de notarse que el área de mayor riesgo relativo, así como la población que habita en ellas, se incrementa conforme aumenta la especificidad del tipo de representación cartográfica. Mientras la capa de secciones censales

aparenta ser mucho mayor, el área de mayor riesgo relativo y la población en ella aparecen subestimados.

Por el contrario, el resultado con la superficie de riesgo relativo es más específico, a la vez que permite detectar una zona de riesgo relativo más alta, y, consecuentemente, una cantidad mayor de población susceptible de estar en mayor riesgo relativo (Tabla 2).

**Tabla 2.** Comparación de resultados entre indicadores y tipo de unidad espacial

Unidad territorial	Indicador	Comparación de área de mayor riesgo			Comparación de población en el área de mayor riesgo		
		Área total (km <sup>2</sup> )	Área total zonas de riesgo más alto (km <sup>2</sup> )	% del área total	Pob. total	Pob. total en zonas de riesgo más alto	% Pob. total
Sección censal	Tasa/ Exceso de riesgo	390	7	1.79%	586,000	63,655	10.86%
Malla estadística	Tasa/ Exceso de riesgo	94	10	10.64%		140,441	23.97%
Superficie de riesgo (zona urbana)	Log. de riesgo relativo	46	16	34.78%	545,000	206,910	37.97%

**Fuente:** elaboración propia con base en los procedimientos realizados sobre los datos de la Tabla 1.

Estas diferencias en resultados indican que, dependiendo del tipo de dato espacial y medición utilizados, se pueden tomar decisiones de mayor o menor extensión y alcance. Así, el uso de secciones censales como dato espacial base puede tener por efecto la subestimación del riesgo en su extensión y población afectada.

Luego, dentro de la zona urbana es posible estimar que la población en la zona estadísticamente significativa tiene un riesgo doble en comparación con el riesgo base de la ciudad (Tabla 3). Esto permite cuantificar la diferencia potencial de riesgo dentro de una misma ciudad.

**Tabla 3.** Variación del riesgo relativo en la zona urbana

Tipo de zona	Casos	Controles	% afectado	Exceso de riesgo
Riesgo relativo ≤ prevalencia general	33,143	376,964	8.79%	0.83
Riesgo relativo > prevalencia general	23,800	163,036	14.60%	1.38
Prevalencia general	56,943	540,000	10.55%	1.00

**Fuente:** elaboración propia con base en los procedimientos realizados sobre los datos de la Tabla 1.

## 4. Discusión

### 4.1 Disponibilidad y utilidad de datos puntuales en epidemiología y salud pública

El análisis presentado muestra la relevancia de contar con datos a nivel puntual para el abordaje de problemas en salud pública, pues los resultados muestran que, con este tipo de datos, la estimación, tanto en área como en cantidad de población en mayor riesgo, se duplica (Tabla 3). Y aunque tanto la literatura fundacional como contemporánea en métodos epidemiológicos se reconoce la importancia de estos datos como el insumo principal para los métodos más precisos (Baddeley *et al.*, 2016; Elliot *et al.*, 2001; Gatrell *et al.*, 1996; González & Moraga, 2023), también es cierto que, a nivel administrativo y de trabajo de investigación, son los más difíciles de conseguir dadas las implicaciones éticas y legales en cuanto a la privacidad y protección de datos personales. La misma Organización Panamericana de la Salud reconoce que, por estos motivos, los datos abiertos en salud pública se presentan de manera agregada (D'Agostino *et al.*, 2018).

Como alternativas a este problema, se han propuesto datos puntuales a nivel de código postal, como hacen Elson *et al.* (2021) para toda Inglaterra. Pero esto sólo es útil cuando se trata de estudios a niveles regionales o de país, lo cual permite que una ubicación puntual no esté directamente asociada con la dirección personal de algún paciente.

Cuando se trata de estudios intraurbanos, la ubicación puntual de casos puede hacerse con menor precisión, registrando los casos de interés de manera aleatoria dentro de un rango de distancia pequeño, para que no se aluda al domicilio específico de alguna persona, sin perder precisión de la ubicación, como fue hecho por García-Morata *et al.* (2022) en Albacete.

Sin embargo, el levantamiento de datos en salud pública de estas maneras depende principalmente de decisiones administrativas y gubernamentales, aunque el estudio previo sugiere una idea plausible sobre cómo hacerlo.

Por otro lado, los resultados que emanan de estudios con datos de alta resolución y especificidad permiten evaluar con más precisión aquellas zonas en de mayor riesgo relativo, derivando en acciones focalizadas y certeras. Para el caso específico de Málaga, resultados como los presentados pueden integrarse en instrumentos de toma de decisiones como los atlas municipales de riesgo, no sólo para la COVID-19, sino para enfermedades respiratorias infecciosas similares, y, en lo general, para cualquier otra enfermedad infecciosa, e incluso crónico degenerativas.

Como ejemplos de lo anterior, se han producido superficies de riesgo relativo a enfermedades como el cáncer de laringe en Lancashire, Inglaterra (Diggle, 1990), la leucemia en Londres, (Gatrell *et al.*, 1996), e, incluso, dentro de la epidemiología veterinaria, como se ha hecho con la fiebre aftosa (*foot and mouth disease*) en el ganado (Gerber *et al.*, 2002). En todos estos casos, los insumos son prácticamente los mismos que en este trabajo: capas puntuales

para casos, una capa poligonal con datos censales para crear puntos simulados de controles, y un polígono que represente la zona de estudio.

## **4.2 El Problema de la Unidad de Área Modificable y la distorsión de resultados a partir de la unidad espacial seleccionada**

Como se mencionó, la disponibilidad de datos a nivel puntual suele ser limitada e incluso nula, por lo que se vuelve necesario recurrir a la siguiente mejor opción posible, como las capas de unidades discretas con datos agregados. En el caso presentado, los resultados muestran el efecto que diferentes unidades de agregación pueden tener sobre los patrones observados y representados cartográficamente, y refuerza la tesis de Mark Monmonier (1991) sobre cómo un mapa es uno de “infinitos” mapas posibles, que pueden construirse sobre el mismo fenómeno.

Las representaciones con base en áreas censales pueden ser las más fáciles de producir por su disponibilidad, con la desventaja mayor variabilidad y arbitrariedad en su delimitación, pues obedecen a criterios administrativos. En el caso específico de Málaga, esto es notorio en las zonas de baja densidad poblacional, en la que una gran área prácticamente inhabitada sirve de base para una sección censal individual, lo que implica importantes distorsiones visuales en cuanto a la magnitud y extensión del riesgo alto o bajo (Figura 4). Esto podría obstaculizar la focalización de medidas de mitigación en caso de que se redirigieran a zonas con un alto riesgo sobre o subestimado por distorsiones propias de las unidades espaciales.

Por el contrario, las mallas regulares muestran ventajas importantes, pues permiten representaciones consistentes y de mayor granularidad. Esto es particularmente notorio en las zonas poco pobladas, pues las estimaciones o mediciones sobre la prevalencia y riesgo de una enfermedad se vuelven muy específicas (Figura 5). No obstante, la creación y disponibilidad de estos insumos no está generalizada.

Por ejemplo, los países de la Unión Europea, a través de la Oficina de Estadísticas de la Unión Europea (*Eurostat*) han desarrollado rejillas o mallas regulares de 1km<sup>2</sup> con datos censales en unidades territoriales estandarizadas y más desagregadas, bajo el programa GISCO. En Iberoamérica, México ha replicado esta iniciativa con la malla geoestadística que llega a una resolución de 500x500 m, aunque en ambos casos, los datos disponibles sólo son en cuanto a cantidad de población, y no incluyen datos en salud pública.

Las superficies continuas, por lo tanto, se muestran como una representación más específica y sensible a la variación espacial del fenómeno de interés, superando las limitaciones inherentes a las unidades discretas. No obstante, sí son más susceptibles a la distorsión causada por la extensión del área de estudio en sí misma (Figura 7), por lo que la delimitación del área de estudio en términos globales es crucial para este tipo de análisis. En el caso de este trabajo, se consideró que la delimitación a la zona urbana es más pertinente dado que en sus límites se encuentra casi la totalidad de la población del municipio.

### 4.3 Tipos de mediciones y su interpretación: un reto para la comunicación de resultados

Los resultados también muestran el efecto de utilizar distintas mediciones. La tasa de prevalencia (Ecuación 1) se interpreta de manera sencilla y directa, al mostrar la cantidad de casos que podrían esperarse en distintas zonas, considerando un número base de población en riesgo o susceptible de enfermar. Sin embargo, no se cuenta con referencia alguna sobre cuánto es más o menos riesgo.

Por el contrario, el exceso de riesgo (Ecuación 2) sí permite evaluar la preocupación anterior, pues la comparación contra la prevalencia general permite estimar en cuáles zonas se está por encima o por debajo del riesgo base, y por cuanto, en términos proporcionales. Sin embargo, se pierde la cantidad específica de casos.

Finalmente, la superficie de riesgo relativo (Ecuación 8) parte de un principio similar al exceso de riesgo, teniendo como principales diferencias que 1) se trata de una representación continua, en lugar de discreta, y 2) que la escala de referencia cambia a una logarítmica, lo que permite expresar los resultados de manera simétrica alrededor del 0 como valor neutro (riesgo igual a la prevalencia general). Su principal desventaja, al igual que con el exceso de riesgo, es que su interpretación se vuelve más abstracta, al contrario de un indicador concreto como la tasa de prevalencia. No obstante, en su cálculo también es posible incluir y representar las zonas de mayor significancia estadística, y, en este sentido, en un mismo mapa es posible presentar una medición estandarizada en conjunto con las zonas estadísticamente significativas (Figura 7).

### 4.4 Más allá de la cartografía: análisis de covariables y funciones de distancia

Las representaciones cartográficas en salud pública y epidemiología son instrumentos valiosos por varias razones, a saber, su carácter exploratorio, y, con ello, su potencial para establecer hipótesis sobre las causas o factores detrás de la variación geográfica observada (Baddeley *et al.*, 2012; Elliot *et al.*, 2001).

Por otro lado, las representaciones cartográficas son sólo el primer paso en el análisis espacial de un fenómeno epidemiológico. Luego de responder, siempre de manera tentativa, a la pregunta sobre la variación geográfica de una enfermedad, es necesario poner a prueba hipótesis sobre las posibles causas o factores subyacentes a esta variación. Empero, para esta pregunta es necesario recurrir a otro tipo de herramientas estadísticas, como los modelos de regresión lineal, tanto en su versión sencilla (Grekousis, 2020) como en su extensión geográficamente ponderada (A. S. Fotheringham & Brunsdon, 2004), y a funciones de distancia con respecto de covariables espaciales (Baddeley *et al.*, 2012), por mencionar algunos ejemplos.

De esta manera, la cartografía sirve como una base que, acompañada de medidas resumen y métodos de inferencia estadística, puede representar los patrones de conglomerados que podrían ser parcialmente explicados por otras variables de interés, como factores ambientales, sociodemográficos y del entorno construido. Dichos factores también pueden ser analizados espacialmente en sí mismos, lo cual puede aumentar la complejidad y dificultad del análisis.

## 5. Conclusiones

En este trabajo se compararon tres métodos de cartografía epidemiológica sobre la variación geográfica del riesgo relativo para la COVID-19, en la ciudad de Málaga, España. Además, se ejemplificó el procesamiento y análisis de los datos con SIG y *software* libre y de código abierto, lo que puede contribuir a multiplicar análisis similares, a la vez que se señalaron problemas potenciales con los algoritmos utilizados.

Los resultados muestran, por un lado, el grado de distorsión que introduce el uso de diferentes unidades espaciales, principalmente sobre la extensión del área de estudio, y, a su vez, en la estimación de población afectada. Por el otro, se mostraron las diferencias en interpretación de los indicadores epidemiológicos utilizados, pasando de mediciones concretas sin dimensión clara del riesgo, a otras más abstractas que acentúan este aspecto.

Como muestran los resultados, es insuficiente tratar con una sola medición y tipo de unidad espacial, pues mediante su comparación es posible detectar zonas de sub o sobreestimación del riesgo, que, en el caso de Málaga, implicó una diferencia de área de mayor riesgo de 1.79% al 37.78%, y del 10.86% al 37.97% de la población en mayor riesgo. Por otro lado, el uso de mediciones estandarizadas, a pesar de su potencial estadístico, ya no refieren a cantidades concretas, lo cual puede ser útil en términos informativos y divulgativos.

La limitación principal en este tipo de análisis es la disponibilidad de datos epidemiológicos. Si bien la pandemia por COVID-19 trajo consigo la proliferación de datos abiertos en salud pública, su disponibilidad en términos georreferenciados generalmente se encuentra agregada en unidades territoriales variadas, mientras que los datos puntuales no están disponibles al público en general por motivos legales y éticos sobre la protección de la privacidad de las personas.

Finalmente, aunque la descripción de la variación espacial de una enfermedad es crucial en el ámbito de la salud pública, se trata del primer paso en su estudio, pues es necesario continuar con la búsqueda de factores o covariables que puedan ofrecer explicaciones tentativas a los patrones observados. Otros trabajos comentados sobre la COVID-19 y otras enfermedades ofrecen cursos de acción para el análisis de covariables que expliquen los patrones observados.

## Bibliografía

- Abellán, J. J., Martínez-Beneito, M. A., Zurriaga, O., Jorques, G., Ferrándiz, J. & López-Quílez, A. (2002). Procesos puntuales como herramienta para el análisis de posibles fuentes de contaminación. *Gaceta Sanitaria*, 16, 445-449.
- Alcántara-Ayala, I., Graue Wiechers, E., Juárez Gutiérrez, M. del C. & Propín Frejomil, E. (eds.) (2010). *Atlas de la Salud en México: Bicentenario de la Independencia, Centenario de la Revolución*. Instituto de Geografía, UNAM.  
<http://www.publicaciones.igg.unam.mx/index.php/ig/catalog/book/64>
- Andrés López, G., Herrero Luque, D. & Martínez Arnaiz, M. (2021). Cartographies on COVID-19 and functional divisions of the territory: An analysis on the evolution of the pandemic based on Basic Health Areas (BHA) in Castile and Leon (Spain). *Boletín de La Asociación de Geógrafos Españoles*, 91.  
<https://doi.org/10.21138/bage.3153>
- Anselin, L. (1995). Local Indicators of Spatial Association (LISA). *Geographical Analysis*, 27 (2), 93-115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Anselin, L. (2019). *GeoDa. An Introduction to Spatial Data Science* [Software].  
<https://geodacenter.github.io>
- Anselin, L. (2024). *An Introduction to Spatial Data Science with GeoDa Volume 1: Exploring Spatial Data*.
- Ascuntar-Tello, J. & Jaimes, F. (2015). Ronda clínica y epidemiológica: Sistemas de información geográfica (SIG) en salud. *Iatreia*, 29 (1), 97-103.  
<https://doi.org/10.17533/udea.iatreia.v29n1a10>
- Baddeley, A., Chang, Y.-M., Song, Y. & Turner, R. (2012). Nonparametric estimation of the dependence of a spatial point process on spatial covariates. *Statistics and its interface*, 5 (2), 221-236. <https://www.intlpress.com/site/pub/pages/journals/items/sii/content/vols/0005/0002/a007/>
- Baddeley, A., Rubak, E. & Turner, R. (2016). *Spatial Point Patterns. Methodology and Applications with R*. Chapman & Hall/CRC Interdisciplinary Statistics Series.  
<https://doi.org/10.1201/b19708>
- Briatore, H., Elorza, M. E. & Estrada, M. E. (2024). Accesibilidad geográfica al primer nivel de atención de las personas mayores en una ciudad intermedia de Argentina. *Población & Sociedad*, 31 (1), 1-28.  
Redalyc. <https://www.redalyc.org/articulo.oa?id=386978153003>
- Celentano, D. & Szklo, M. (2020). *Gordis Epidemiología*. Elsevier.
- Center for Disease Control and Prevention (CDC). (2022). *Standardized Incidence Ratio (SIR) A Math-based Approach to Evaluating Unusual Patterns of Cancer*.  
<https://www.cdc.gov/cancer-environment/media/pdfs/Standardized-Incidence-Ratio-Fact-Sheet-508.pdf>
- Cliff, A. D., & Haggett, P. (1989). Spatial aspects of epidemic control. *Progress in Human Geography*, 13 (3), 315-347. <https://doi.org/10.1177/030913258901300301>
- D'Agostino, M., Samuel, N. O. & Sarol, M. J. (2018). Open data and public health. *Rev Panam Salud Publica*, 42, 2018. <https://doi.org/10.26633/RPSP.2018.66>
- Davies, T. M., Hazelton, M. L. & Marshall, Jonathan. C. (2011). sparr: Analyzing Spatial Relative Risk Using Fixed and Adaptive Kernel Density Estimation in R. *Journal of Statistical Software*, 39 (1), 1-14. <https://doi.org/10.18637/jss.v039.i01>

- Davies, T. M., Marshall, J. C. & Hazelton, M. L. (2018). Tutorial on kernel estimation of continuous spatial and spatiotemporal relative risk. *Statistics in Medicine*, 37 (7), 1191-1221. <https://doi.org/10.1002/sim.7577>
- Diggle, P. J. (1990). A Point Process Modelling Approach to Raised Incidence of a Rare Phenomenon in the Vicinity of a Prespecified Point. *Journal of the Royal Statistical Society. Series A (Statistics in Society)*, 153 (3), 349-362. <https://doi.org/10.2307/2982977>
- Diggle, P. J. (2023). *Statistical analysis of spatial and spatio-temporal point patterns* (3a. ed.). CRC Press.
- Elliot, P., Wakefield, J., Best, N. & Briggs, D. (eds.) (2001). *Spatial Epidemiology. Methods and Applications*. Oxford University Press.
- Elson, R., Davies, T. M., Lake, I. R., Vivancos, R., Blomquist, P. B., Charlett, A., & Dabrera, G. (2021). The spatio-temporal distribution of COVID-19 infection in England between January and June 2020. *Epidemiology and Infection*, 149, e73. <https://doi.org/10.1017/S0950268821000534>
- Escalona Orcao, A. I. & Diez Cornago, C. (2003). Accesibilidad geográfica de la población rural a los servicios básicos de salud: estudio en la provincia de Teruel. *Ager. Revista de Estudios sobre Despoblación y Desarrollo Rural*, 3, 111-149. Redalyc. <https://www.redalyc.org/articulo.oa?id=29600304>
- Escudero-Tena, M., Ojeda-Casares, S., Moya, L.-Á. & Enrique-Regueira, I. (2023). La malla estadística como unidad de análisis espacial. Razón de mortalidad, población y vivienda. *Revista EURE. Revista de Estudios Urbano Regionales*, 50 (150). <https://doi.org/10.7764/EURE.50.150.11>
- Fotheringham, A., Brunsdon, C. & Charlton, M. (2024). *Quantitative Geography*. SAGE Publications Ltd. <https://doi.org/10.4135/9781849209755>
- Fotheringham, A. S. & Brunsdon, C. (2004). Some thoughts on inference in the analysis of spatial data. *International Journal of Geographical Information Science*, 18 (5), 447-457. <https://doi.org/10.1080/13658810410001658065>
- García-Morata, M., González-Rubio, J., Segura, T. & Najera, A. (2022). Spatial analysis of COVID-19 hospitalised cases in an entire city: The risk of studying only lattice data. *Science of the Total Environment*, 806, 150521. <https://doi.org/10.1016/j.scitotenv.2021.150521>
- Garrocho, C. & Campos, J. (2006). Un indicador de accesibilidad a unidades de servicios clave para ciudades mexicanas: Fundamentos, diseño y aplicación. *Economía Sociedad y Territorio*. <https://doi.org/10.22136/est002006262>
- Gatrell, A. C., Bailey, T. C., Diggle, P. J. & Rowlingson, B. S. (1996). Spatial point pattern analysis and its application in geographical epidemiology. *Transactions of the Institute of British geographers*, 256-274. <https://www.jstor.org/stable/622936>
- Gatrell, A. C. & Elliott, S. J. (2015). *Geographies of health: An introduction*. Wiley Blackwell.
- Gerbier, G., Bacro, J. N., Pouillot, R., Durand, B., Moutou, F. & Chadœuf, J. (2002). A point pattern model of the spread of foot-and-mouth disease. *Spatial Epidemiology*, 56 (1), 33-49. [https://doi.org/10.1016/S0167-5877\(02\)00122-8](https://doi.org/10.1016/S0167-5877(02)00122-8)
- González, J. A. & Moraga, P. (2023). Non-Parametric Analysis of Spatial and Spatio-Temporal Point Patterns. *The R Journal*, 15 (1), 65-82. <https://doi.org/10.32614/RJ-2023-025>
- Grekousis, G. (2020). *Spatial Analysis Methods & Practice. Describe—Explore—Explain through GIS*. Cambridge University Press.

- Instituto Geográfico Nacional (s/f). *Atlas Nacional de España*. Sanidad. Gobierno de España. <https://atlasnacional.ign.es/wane/Sanidad>
- Jesri, N., Saghafipour, A., Koohpaei, A., Farzinnia, B., Jooshin, M. K., Abolkheirian, S. & Sarvi, M. (2021). Mapping and Spatial Pattern Analysis of COVID-19 in Central Iran Using the Local Indicators of Spatial Association (LISA). *BMC Public Health*, 21 (1). <https://doi.org/10.1186/s12889-021-12267-6>
- Kirby, R. S., Delmelle, E. & Eberth, J. M. (2017). Advances in spatial epidemiology and geographic information systems. *Annals of Epidemiology*, 27 (1), 1-9. <https://doi.org/10.1016/j.annepidem.2016.12.001>
- Lambio, C., Schmitz, T., Elson, R., Butler, J., Roth, A., Feller, S., Savaskan, N. & Lakes, T. (2023). Exploring the Spatial Relative Risk of COVID-19 in Berlin-Neukölln. *International Journal of Environmental Research and Public Health*, 20 (10). <https://doi.org/10.3390/ijerph20105830>
- Marín-Cots, P. & Palomares-Pastor, M. (2020). En un entorno de 15 minutos: hacia la Ciudad de Proximidad, y su relación con el Covid-19 y la crisis climática, el caso de Málaga. *Ciudad y Territorio Estudios Territoriales*, 52 (205), 685-700. <https://doi.org/10.37230/CyTET.2020.205.13.3>
- MINSALUD (2015). *Atlas de variaciones geográficas en salud de Colombia. Estudio piloto 2015*. Ministerio de Salud y Protección Social. <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/RIDE/DE/PES/Atlas-variaciones-geograficas-2015.pdf>
- Monmonier, M. (1991). *How to lie with maps*. The University of Chicago Press.
- Moraga, P. (2019). *Geospatial Health Data. Modeling and Visualization with R-INLA and Shiny*. Chapman & Hall / CRC Biostatistics Series. <https://www.paulamoraga.com/book-geospatial/index.html>
- Narro Robles, J., R. & Ponce de León, R. (1986). La representación cartográfica: una herramienta de la epidemiología. *Salud Pública de México*, 28 (3), 283-291. <https://saludpublica.mx/index.php/spm/article/view/358>
- Openshaw, S. & Taylor, P.J. (1979). A million or so correlated coefficients: Three experiment on the modifiable areal unit problem. *Statistical Applications in the Spatial Sciences*. <https://cir.nii.ac.jp/crid/1571135650655620224>
- O'Sullivan, D. & Unwin, D. (2010). *Geographic Information Analysis*. John Wiley & Sons, Inc.
- Perles, M.-J., Sortino, J. F. & Mérida, M. F. (2021). The Neighborhood Contagion Focus as a Spatial Unit for Diagnosis and Epidemiological Action against COVID-19 Contagion in Urban Spaces: A Methodological Proposal for Its Detection and Delimitation. *International Journal of Environmental Research and Public Health*, 18 (6). <https://doi.org/10.3390/ijerph18063145>
- Reyna Sevilla, A., González Castañeda, M. E. & Ramos Herrera, I. M. (2013). Accesibilidad geográfica y social en un servicio de salud de especialidad. Acapulco, Guerrero, México, año 2011. *Terra. Nueva Etapa, XXIX* (46), 69-79. <https://www.redalyc.org/articulo.oa?id=72130181005>
- Roselló, M. J. P., Barrionuevo, J. F. S., Prados, F. J. C., Noblejas, H. C., De la Fuente Roselló, A. L., Orellana-Macías, J. M., Corredera, S. R., Páez, J. M. & Rodríguez, M. M. (2021). Potential of hazard mapping as a tool for facing COVID-19 transmission: The geo-COVID cartographic platform. *Boletín de la Asociación de Geógrafos Españoles*, 91. <https://doi.org/10.21138/bage.3151>
- Sancho Comins, J. & Olcina Cantos, J. (2021). La cartografía temática como recurso idóneo para el conocimiento de la pandemia COVID-19: ejemplo de aplicación en España. *Boletín de la Asociación de Geógrafos Españoles*, 91. <https://doi.org/10.21138/bage.3141>

- Sarojinie Fernando, W. T. P. & Hazelton, M. L. (2014). Generalizing the spatial relative risk function. *Spatial and Spatio-temporal Epidemiology*, 8, 1-10.  
<https://doi.org/10.1016/j.sste.2013.12.002>
- Slocum, T. A., McMaster, R., B., Kessler, F., C. & Howard, H., H. (2023). *Thematic Cartography and Geovisualization (4th edition)*. CRC Press.
- Suárez Lastra, M., Valdés González, C., Galindo Pérez, M. C., Salvador Guzmán, L. E., Ruiz Rivera, N., Alcántara-Ayala, I., López Cervantes, M., Rosales Tapia, A. R., Lee Alardin, W., Benítez Pérez, H., Bringas López, O. A., Oropeza Orozco, O., Peralta Higuera, A. & Garnica-Peña, R. J. (2020). Índice de vulnerabilidad ante el COVID-19 en México. *Investigaciones Geográficas*, 0-2.  
<https://doi.org/10.14350/rig.60140>
- Susser, M. (1991). Conceptos y estrategias en epidemiología. El pensamiento causal en las ciencias de la salud. Fondo de Cultura Económica, Secretaría de Salud.
- Terán-Hernández, M. (2017). Accesibilidad espacial de los servicios de prevención y control del cáncer-cervicouterino en San Luis Potosí. *Investigaciones Geográficas*, 94.  
<https://www.redalyc.org/articulo.oa?id=56962419010>
- Valbuena García, A. M. & Rodríguez Villamizar, L. A. (2018). Análisis espacial en epidemiología: revisión de métodos. *Salud UIS*, 50 (4), 358-365.  
<https://doi.org/10.18273/revsal.v50n4-2018009>
- Vilinová, K. & Petrikovicová, L. (2023). Spatial Autocorrelation of COVID-19 in Slovakia. *Tropical Medicine and Infectious Disease*, 8 (6).  
<https://doi.org/10.3390/tropicalmed8060298>
- Villa Romero, A., Moreno Altamirano, L. & García de la Torre, G. (2011). *Epidemiología y Estadística en Salud Pública*. McGrawHill, Facultad de Medicina, UNAM.
- Villanueva, A. (2010). Accesibilidad geográfica a los sistemas de salud y educación. Análisis espacial de las localidades de Necochea y Quequén. *Revista Transporte y Territorio*, 2, 136-157. <https://www.redalyc.org/articulo.oa?id=333027080005>
- Walter, S. D. (2000). Disease mapping: A historical perspective. *Spatial Epidemiology. Methods and Applications* (pp. 223-239).