



OTROS

REVISTA DE  
**Biología Tropical**

<https://doi.org/10.15517/rev.biol.trop..v72i1.58835>

## Patrones geoespaciales de la morbilidad por covid-19 en Costa Rica: marzo 2020 a mayo 2022

Horacio Alejandro Chamizo-García<sup>1\*</sup>; <https://orcid.org/0000-0001-7442-0671>

Juan José Romero-Zúñiga<sup>2</sup>; <https://orcid.org/0000-0002-5252-1604>

Suyén Alonso Ubieta<sup>3</sup>; <https://orcid.org/0000-0002-0563-6759>

Lilliam Quirós-Arias<sup>4</sup>; <https://orcid.org/0000-0001-9627-6316>

1. Escuela de Tecnologías en Salud, Facultad de Medicina, Universidad de Costa Rica, San Pedro, Costa Rica; horacio.chamizo@ucr.ac.cr (\*Correspondencia)
2. Escuela de Medicina Veterinaria, Universidad Nacional de Costa Rica, Heredia, Costa Rica; juan.romero.zuniga@una.cr
3. Centro Internacional de Política Económica para el Desarrollo Sostenible, Universidad Nacional de Costa Rica, Heredia, Costa Rica; salonso@una.cr
4. Escuela de Ciencias Geográficas, Facultad de Ciencias de la Tierra y el Mar, Universidad Nacional de Costa Rica, Heredia, Costa Rica; lilliam.quiros.arias@una.cr

Recibido 16-II-2024. Corregido 04-VIII-2024. Aceptado 06-IX-2024.

### ABSTRACT

#### Geospatial patterns of morbidity due to covid-19 in Costa Rica: March 2020 to May 2022

**Introduction:** The COVID-19 epidemic has manifested geographically as clusters of high morbidity (hot zones) and as cold spots of low incidence, which have been explained based on social variables.

**Objective:** To characterize morbidity patterns due to COVID-19 in Costa Rica from March 2020 to May 2022 and to explain them through social determinants of health in the geographical context.

**Methods:** An ecological study at the district level was designed with data on vaccination against COVID-19, weekly reports on speed of advance of the epidemic, development level, and other demographic data. Thematic maps were constructed, and spatial morbidity patterns were identified and characterized, which were explained using linear and geographically weighted regression models.

**Results:** In the Greater Metropolitan Area and surrounding area, clusters of hot spots were identified, and cold spots flanked these high-incidence areas. The linear regression model, built from the variables: average number of vaccines per person, speed in weekly case reporting, social development in its economic, educational, and health dimensions, as well as the proportion of overcrowded homes and people born in the outside, explained more than 70 % of the spatial variations of the incidence of cases (crude and standardized by age and sex). The geographically weighted model corrected autocorrelation problems, improving the explanatory capacity to 82 %.

**Conclusions:** morbidity during the COVID-19 epidemic until May 2020 was configured spatially through well-established clusters of hot and cold spots. This structure could be explained from the social determinants of health, proving that effects on morbidity are generated, differentiated territorially.

**Key words:** epidemic; risk; territory; clusters; geographic regression.

RESUMEN



**Introducción:** En distintos países, la epidemia de covid-19 se ha manifestado en el espacio geográfico como conglomerados de alta morbilidad o zonas calientes, y como conglomerados de puntos fríos de baja incidencia, los que han sido explicados a partir de variables sociales.

**Objetivo:** Caracterizar los patrones de morbilidad de covid-19 en Costa Rica entre marzo del 2020 y mayo del 2022, y explicarlos desde los determinantes sociales de la salud en el contexto geográfico.

**Métodos:** Se diseñó un estudio ecológico a nivel distrital, con datos sobre vacunación contra covid-19, reportes semanales sobre la velocidad de avance de la epidemia, el nivel de desarrollo, y otros datos demográficos. Se construyeron mapas temáticos, se identificaron y caracterizaron los patrones geoespaciales de la morbilidad explicados a partir de modelos de regresión lineal y geográficamente ponderada.

**Resultados:** Se identificaron conglomerados de puntos calientes en la Gran Área Metropolitana y su entorno, y puntos fríos que flanquean esta zona de alta incidencia. El modelo de regresión lineal que incluyó el promedio de vacunas por persona, la velocidad en el reporte de casos semanal, el desarrollo social en sus dimensiones económica, educacional y sanitaria, así como la proporción de viviendas hacinadas y de personas nacidas en el exterior, explicó más del 70 % de las variaciones espaciales de la incidencia de casos (bruta y estandarizada por edad y sexo). El modelo geográficamente ponderado corrigió problemas de autocorrelación mejorando la capacidad explicativa a un 82 %.

**Conclusiones:** La morbilidad durante la epidemia de covid-19, en Costa Rica, durante el período evaluado, se configuró mediante conglomerados espaciales de puntos calientes y fríos muy bien establecidos. Esta estructura se pudo explicar desde los determinantes sociales de la salud, comprobando que se generan efectos en la morbilidad, diferenciados territorialmente.

**Palabras claves:** epidemia; riesgo; territorio; conglomerados; regresión geográfica.

## INTRODUCCIÓN

La pandemia de covid-19 ha avanzado a través de las desigualdades. Un aspecto explícito recomendado por las autoridades internacionales en salud se ha dirigido a los datos, la información y el conocimiento científico sobre las brechas sociales, así como la identificación de los grupos de personas y territorios más desfavorecidos económicamente, para definir estrategias de abordaje del problema de salud (Organización Mundial de la Salud, 2021a).

Los estudios ecológicos con fundamento geográfico han sido ampliamente utilizados en la investigación del curso de la pandemia de covid-19. La cartografía y los Sistemas de Información Geográfica (SIG) son las herramientas que, por lo general, se emplean para ordenar y procesar los datos de dichos estudios. El propósito ulterior es orientar medidas de control epidemiológico espacialmente diferenciadas para orientar la toma de decisiones (Almeida et al., 2021; Almendra et al., 2021; Ismail et al., 2021; Kabir et al., 2021; Maroko et al., 2020). En estas investigaciones se aborda el análisis de tendencias para reconocer, en primer lugar, patrones geoespaciales (Almeida et al., 2021; De Oliveira

et al., 2022; Ismail et al., 2021; Miramontes-Carballada & Balsa-Barreiro, 2021; Orozco et al., 2021; Vicente-Ferreira et al., 2020); además, la identificación de conglomerados espacio-temporales (Martines et al., 2021).

Las disparidades en salud entre grupos de personas se asocian a sus circunstancias de la vida diferenciadas por factores materiales, de conducta, biológicos, psicosociales, mediados por el sistema de atención en salud que finalmente influyen en la distribución de la salud y el bienestar (Organización Mundial de la Salud, 2008). El desempeño en la implementación de políticas no suele ser el mismo en todo el territorio de cualquier país, existen desigualdades geográficas que no solo se explican por los factores ambientales, económicos, sociales propios de su población, sino por la respuesta social en salud (Organización Mundial de la Salud, 2021b). Los determinantes sociales de la salud (DSS) tienen asidero en contextos; aquí, el territorio es una parte fundamental del mismo, establece condiciones de vida y genera disparidades en salud (Organización Mundial de la Salud, 2008).

Una gama amplia de factores recorren los determinantes ambientales, demográficos y

económicos, así como la prevalencia de comorbilidades en la población, según los estudios ecológicos consultados (Pérez-Rodríguez et al., 2020). A nivel mundial, el nivel de desarrollo del territorio se ha planteado como variable explicativa del riesgo de enfermar, es el caso de barrios más deprimidos socioeconómicamente, habitados por población negra e hispana, los que incrementaron su riesgo (Duan et al., 2021). La asimetría en el nivel educativo ha sido uno de los aspectos cruciales en la comunicación del riesgo en el contexto de la pandemia. A partir de un estudio referido a países en desarrollo, se ha corroborado la importancia de la pertenencia a redes sociales y el acceso a internet (Ataguba & Ataguba, 2020). En los Estados Unidos de América, la escolaridad explicó la disposición a acceder a los servicios de salud para vacunarse (Viswanath et al., 2021), así como en un estudio ecológico comparativo de puntos fríos y calientes entre Nueva York y Chicago (Maroko et al., 2020). En el caso de la India, la tasa de alfabetización resultó con poder explicativo (Khobragade & Kadam, 2021).

La determinación social de esta enfermedad en el mundo (a partir de una revisión sistemática) se ha visto asociada a la comprensión de la exposición y el riesgo por parte de las personas. Los hallazgos más contundentes, hasta mediados del año 2020, tienen que ver con elementos de carácter sociocultural ligados a la raza, la etnia, la privación socioeconómica y a la estrecha relación con la probabilidad de desarrollar covid-19 y la hospitalización, ante el agravamiento del cuadro infeccioso (Upshaw et al., 2021).

La densidad poblacional y el hacinamiento han sido utilizadas para ajustar modelo explicativos (Turner et al., 2021). La aglomeración poblacional en las ciudades se asoció con patrones espaciales concentrados de mayor riesgo también en Brasil (Almeida et al., 2021) y en Santiago de Cuba (Zamora-Matamoros et al., 2021). La condición de hacinamiento en la vivienda puede ser una variable aún más explicativa de las tasas de incidencia que la densidad poblacional, como se comprobó durante la

primavera del año 2020 en la ciudad de Nueva York (Maroko et al., 2020). El hacinamiento se utilizó como parte del estudio sobre la resiliencia social frente al covid-19 en Argelia (Habibi et al., 2020), también como factor explicativo en el incremento del riesgo en territorios contiguos a grandes ciudades en Galicia, España (Miramontes-Carballada & Balsa-Barreiro, 2021), así como parte de la jerarquización de las ciudades en Córdoba, Argentina (Buffalo & Rydzewski, 2021) y en el triángulo sur de Minas Gerais, Brasil (Vicente-Ferreira et al., 2020) o en Sao Paulo (Matsumoto et al., 2020).

Entre los determinantes demográficos, el porcentaje de personas mayores de 65 años se tomó en cuenta como un indicador de vulnerabilidad en el estudio ecológico a nivel de país, en Brasil (Matsumoto et al., 2020), y en otro de similar diseño pero a nivel planetario, utilizando a los países como unidad de observación, se evidenció que se trata de un factor explicativo del avance de la pandemia (Wang et al., 2021). La avanzada edad y el sexo masculino han sido identificados como uno de los factores de riesgo más relevantes (Bashash et al., 2021; Muñoz et al., 2021). La movilidad poblacional se ha constituido en factor de interés en la morbilidad por covid-19. El porcentaje de personas que se desplazan entre municipios tuvo un importante papel en la explicación geográfica de las disparidades en la incidencia de la enfermedad en la India (Khobragade & Kadam, 2021) y también en otro estudio, específicamente asociado al desplazamiento de turistas en Baja California, México (Brugués-Rodríguez et al., 2021). Asimismo, la función socioeconómica o relevancia administrativa del territorio se ha utilizado como variables proxy de la movilidad y el nivel de contacto e intercambio poblacional, incidiendo en la propagación de la epidemia de covid-19 (Matsumoto et al., 2020; Wang et al., 2021).

El presente estudio tiene el objetivo de constatar las variaciones espaciales en la incidencia de la covid-19 en Costa Rica entre marzo del 2020, cuando inició la epidemia en el país, hasta el 30 de mayo del 2022 (momento en el que se interrumpe en el país el acceso a



datos de la enfermedad); asimismo, explicar los patrones geospaciales a partir de los determinantes sociales de la salud (DSS).

## MATERIALES Y MÉTODOS

**Fuentes de datos:** Se realizó un estudio de tipo observacional cuantitativo, ecológico, con fundamento geográfico, tomando los distritos como unidades de análisis. Los datos son de carácter secundario a partir de los registros que soportan el sistema de vigilancia epidemiológica en Costa Rica del Ministerio de Salud, para los años 2020 a 2022. Los datos provienen de fuentes diversas: los casos de personas positivas reportadas se tomaron del Observatorio Geográfico en Salud, a partir de bases de datos anonimizadas avaladas por el Ministerio de Salud, que es la autoridad en materia de vigilancia epidemiológica. Los datos de población por edad y sexo provienen de las proyecciones demográficas que reporta el Instituto Nacional de Estadística y Censos de Costa Rica (INEC) (Instituto Nacional de Estadística y Censos, s. f.)

Los datos sobre los determinantes sociales de la salud (DSS) se obtuvieron a partir de la consulta a las bases de datos del INEC: Censo Nacional de Población y Viviendas del año 2011 (últimos datos censales disponibles), y del Ministerio de Planificación (MIDEPLAN) correspondiente a dimensiones del Índice de Desarrollo Social (IDS) reportados en el año 2017 (Ministerio de Planificación de la República de Costa Rica, 2017). Asimismo, se obtuvo la información sobre la cobertura de vacunación contra covid-19, reportada por la Caja Costarricense del Seguro Social (CCSS), que fue la institución encargada de esta tarea en el país. Los mapas básicos de polígonos distritales fueron capturados a partir del sitio oficial del Instituto Geográfico Nacional (IGN) de Costa Rica. En la tabla 1 se presenta una lista de las variables empleadas en el presente estudio.

Se calculó morbilidad bruta y estandarizada por sexo y edad, a partir de la cartografía temática distrital. Estas morbilidades se obtuvieron a partir del Índice de Morbilidad Estandarizado (IME) (Rué & Borrell, 1993).

$$\text{Índice de Morbilidad Estandarizado} = \frac{\text{Casos observados}}{\text{Casos esperados}}$$

Los casos observados son el total reportado, para cada distrito del país.

Los casos esperados se calcularon mediante la fórmula:

$$\sum_{0-4}^{65 \text{ y más}} I_a (\text{nacional según sexo}) * \text{población distrito (según sexo)}$$

La sumatoria considera el sexo para cada uno de los grupos de edades quinquenales.

Los software QGIS (QGIS, 2019) y ArcGis (Environmental Systems Research Institute, 2021), se utilizaron en la cartografía descriptiva y analítica respectivamente.

**Análisis:** La identificación de patrones geospaciales consideró dos indicadores de autocorrelación espacial global: la I de Moran y el estadístico G (Getis-Ord) (Environmental Systems Research Institute, 2021). En el caso de la I de Moran se establecen pruebas de hipótesis a partir del cálculo del estadístico Z y su probabilidad (p). Los valores positivos de Z indican la presencia de conglomerados espaciales, en caso contrario se concluye que el patrón es disperso. En el caso de la prueba de Getis-Ord, un valor de Z alto y una p pequeña evidencian la presencia de un conglomerado espacial de riesgos altos, en tanto un valor de Z bajo y una probabilidad alta, indican la presencia de puntos fríos o de bajo riesgo.

Se presenta la cartografía que permite identificar patrones geospaciales locales. En los mapas que señalan puntos fríos y calientes. Se representa con el color blanco a aquellos distritos en los que la probabilidad de desarrollar la enfermedad no es significativamente distinta a la de sus vecinos. Asimismo, con los colores de la gama de los rojos y de los azules, se representa cartográficamente a los distritos con proporciones altas (puntos calientes) y bajas (puntos fríos), respectivamente.

Se incorporan a los mapas, diagramas que sintetizan información sobre la evaluación global del patrón espacial. La cartografía temática del Índice de Anselin (I de Morán local) localiza espacialmente a los conglomerados calientes y fríos. El cartograma muestra también el nivel

**Tabla 1**

Lista de variables dependientes e independientes correspondientes a los modelos explicativos. / **Table 1.** List of dependent and independent variables corresponding to the explanatory models.

Variable	Definición operativa
<ul style="list-style-type: none"> <li>• Incidencia acumulada bruta de casos de covid-19 (marzo de 2020 a mayor 2022).</li> </ul>	<ul style="list-style-type: none"> <li>• Número de casos acumulados por cada 1000 personas.</li> </ul>
<ul style="list-style-type: none"> <li>• Índice de Morbilidad Estandarizado (marzo de 2020 a mayo 2022), estandarizada por edad y sexo, por el método indirecto.</li> </ul>	<ul style="list-style-type: none"> <li>• Exceso de riesgo o protección respecto al promedio nacional, estandarizado por edad y sexo.</li> </ul>
<ul style="list-style-type: none"> <li>• Dimensión Económica del IDS.</li> </ul>	<ul style="list-style-type: none"> <li>• Promedio de razón de consumo de electricidad residencial.</li> <li>• Porcentaje de viviendas con acceso a internet residencial.</li> </ul>
<ul style="list-style-type: none"> <li>• Dimensión educativa del IDS.</li> </ul>	<ul style="list-style-type: none"> <li>• Cobertura de programas educativos especiales (segundo idioma e informática) estado de la infraestructura educativa (servicio de agua, electricidad, estado técnico de las aulas), escuelas unidocentes la cobertura de la educación pública secundaria.</li> </ul>
<ul style="list-style-type: none"> <li>• Dimensión salud del IDS.</li> </ul>	<ul style="list-style-type: none"> <li>• El peso corporal inadecuado (bajo peso, obesidad, desnutrición), mortalidad en menores de cinco años, nacimientos en madres solteras menores de diecinueve años la cobertura residencial de agua potable.</li> </ul>
<ul style="list-style-type: none"> <li>• Cobertura de vacunación contra covid-19.</li> </ul>	<ul style="list-style-type: none"> <li>• Promedio de vacunas contra covid-19 por habitante.</li> </ul>
<ul style="list-style-type: none"> <li>• Dinámica de la epidemia.</li> </ul>	<ul style="list-style-type: none"> <li>• Cantidad de semanas para alcanzar el máximo reporte de casos.</li> </ul>
<ul style="list-style-type: none"> <li>• Densidad poblacional.</li> </ul>	<ul style="list-style-type: none"> <li>• Cantidad de habitantes por kilómetro cuadrado.</li> </ul>
<ul style="list-style-type: none"> <li>• Porcentaje de viviendas hacinadas.</li> </ul>	<ul style="list-style-type: none"> <li>• Porcentaje de viviendas clasificadas como hacinadas a partir de la cantidad de habitantes por viviendas.</li> </ul>
<ul style="list-style-type: none"> <li>• Porcentaje de viviendas hacinadas por dormitorio.</li> </ul>	<ul style="list-style-type: none"> <li>• Porcentaje de viviendas clasificadas como hacinadas a partir de la cantidad de habitantes por dormitorios en la vivienda.</li> </ul>
<ul style="list-style-type: none"> <li>• Porcentaje de personas mayores de 65 años.</li> </ul>	<ul style="list-style-type: none"> <li>• Cantidad de personas mayores de 65 años por cada cien habitante.</li> </ul>
<ul style="list-style-type: none"> <li>• Porcentaje de personas nacidas fuera del país.</li> </ul>	<ul style="list-style-type: none"> <li>• Cantidad de personas nacidas fuera del país por cada 100 personas.</li> </ul>

de certeza para afirmar que se trata de una unidad espacial (distrito) caliente o frío respecto a su entorno inmediato (Environmental Systems Research Institute, 2021).

Dos tipos de modelos explicativos del comportamiento espacial de la Ia fueron diseñados: los modelos globales de regresión (GLR, global linear regression) y el modelo local de regresión o regresión geográficamente ponderada (GWR, geographically weighted regression) (Environmental Systems Research Institute, 2021). Las variables dependientes fueron la Ia bruta y la estandarizada por edad y sexo (IME), en tanto las independientes fueron los DSS.

Se consideró en primer lugar la regresión lineal por el método de mínimos cuadrados. Los modelos fueron evaluados para verificar el cumplimiento de supuestos (análisis de residuos): normalidad (prueba de normalidad de los residuos) y varianzas homogéneas graficando para comprobar su dispersión, también la independencia entre residuos (a través de la prueba de Durbin Watson), colinealidad de las variables revisando el factor de inflación de la varianzas ( $VIF < 5$ ) así como las proporciones de varianzas entre variables, y la identificación de valores influyentes (residuos estandarizados  $> 3$  unidades y distancias de cook  $> 1$  que puedan



afectar el hiperplano de regresión y por lo tanto los coeficientes de regresión). La ecuación de regresión lineal se define por la siguiente expresión (Colton, 1979):

$$y_i = \beta_0 + \sum_k \beta_k X_{ik} + \epsilon_i$$

Finalmente se procedió, con la GWR para identificar las variaciones espaciales de los coeficientes para cada una de las variables explicativas consideradas, cuyo modelo se plantea (Almendra et al., 2021):

$$y_i = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i) X_{ik} + \epsilon_i.$$

En la ecuación anterior las letras “u” y “v” son las coordenadas de los puntos (centroides).  $\beta_k$  son los coeficientes de regresión de cada variable independiente, y  $\epsilon_i$  es el error del modelo, o varianza de  $y_i$  no explicada.

Los coeficientes en la ecuación final correspondientes a cada variable fueron reportados mediante cartografía para conocer el efecto diferenciado geoespacialmente de cada una, así como los coeficientes de regresión ajustados para evidenciar el desempeño del modelo en el espacio. El mapa de residuos fue sometido a la prueba de autocorrelación espacial de la I de Morán (Environmental Systems Research Institute, 2021).

## RESULTADOS

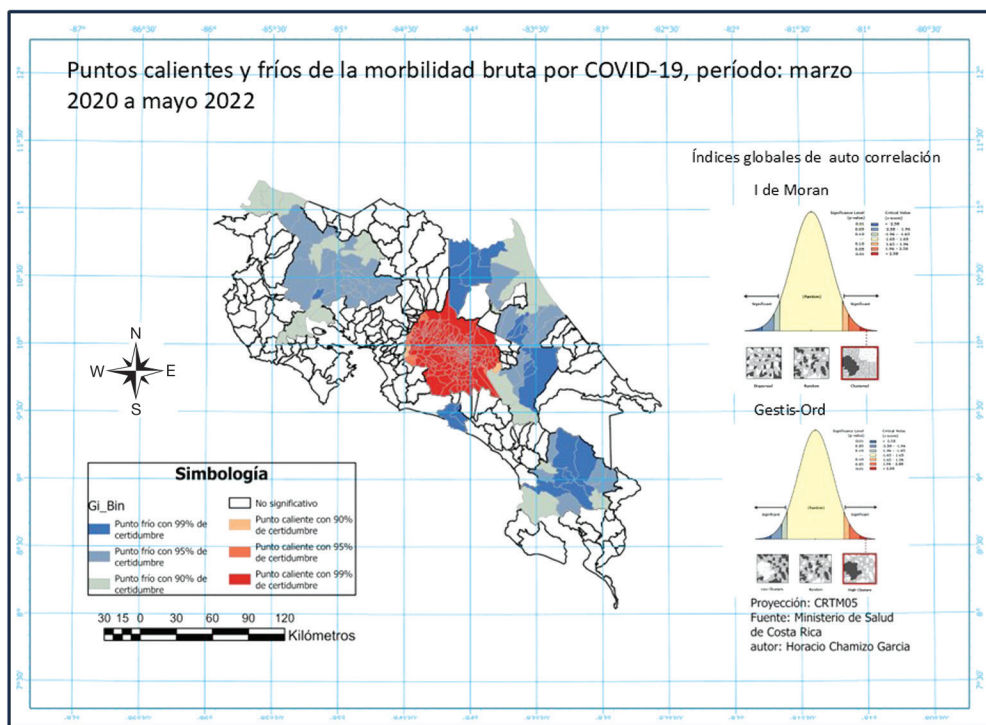
Respecto a la autocorrelación espacial medida mediante el Índice de Morán, existe menos del 1 % de probabilidad de que el patrón observado sea debido al azar, es decir, se asume que el comportamiento espacial de la incidencia acumulada de covid-19 no ocurre por azar. Asimismo, la puntuación de  $Z > 0$  permite rechazar la hipótesis de una distribución dispersa, es decir, se observan conglomerados espaciales. El valor de  $p < 0$ , correspondiente al geoestadístico de Getis Ord, evidencia que los conglomerados son fuertes, dada la alta puntuación de  $Z$ . Se trata de agrupaciones de altos valores de incidencia acumulada de la enfermedad.

La cartografía de puntos fríos y calientes de la morbilidad bruta y estandarizada se presentan en la Fig. 1. Se incorporan diagramas del Índice de Morán y Getis Ord, que aportan a la decisión geoestadística para aceptar la presencia de conglomerados espaciales, así como determinar si incorporan puntos fríos y calientes.

En la Fig. 1 se observa un conglomerado prominente de puntos calientes localizado en la Gran Área Metropolitana (GAM) y su entorno con un 99 % de certidumbre. Se trata de un conglomerado fuerte con algunos pocos distritos ubicados en los bordes que poseen una certeza menor (95 % de certeza). Existen también puntos fríos con un 99 % y 95 % de certeza, representados con la gama de azules, ubicados hacia el nordeste y este-nordeste (sectores de la zona del Caribe y Norte del país), en ambos casos, bordeando al conglomerado de altos valores. En la zona sur del país también se identifican puntos fríos agrupados en conglomerados de valores bajos. Los conglomerados de puntos fríos, por su nivel de certeza y ubicación en el espacio, resultan menos notables que los puntos calientes, aunque constituyen sectores que se distribuyen por todo el país, eso sí, fuera la GAM y su entorno.

Las pruebas de reconocimiento de patrones globales de la distribución espacial del IME, estandarizadas por sexo y edad, muestran puntuaciones de  $Z$  de 12.27 para el Índice de Morán y de 11.79 para el de Getis Ord, ambos con valores de  $p < 0.001$ .

El Índice de Morán indica que existe menos del 1 % de probabilidad de que el patrón observado sea debido al azar, es decir, se asume que el comportamiento espacial del IME de covid-19 no ocurre por azar. Asimismo, la puntuación de  $Z > 0$  permite rechazar la hipótesis nula de una distribución dispersa, es decir, se observan conglomerados espaciales. La puntuación de  $Z$  y el valor de  $p < 0.05$  del geoestadístico de Getis Ord, evidencia que los conglomerados sugeridos son de altos valores (de exceso de riesgo) de covid-19 y se trata de agrupaciones fuertes, con muy alto nivel de certeza. También se corrobora que existen conglomerados de puntos calientes que se localizan en la GAM y



**Fig. 1.** Puntos calientes y fríos de morbilidad bruta por covid-19, en Costa Rica, entre marzo del 2020 y marzo del 2022. / **Fig. 1.** Hot and cold spots of gross morbidity due to covid-19, in Costa Rica, between March 2020 and March 2022.

su entorno con un 99 % de certidumbre y conforman un sector extenso más allá de la GAM, bordeándola ampliamente.

Los resultados de los modelos globales de regresión (GLR), en este caso la regresión lineal, para los dos modelos explicativos de las variables dependientes Ia e IME, se reportan en la Tabla 2.

En los dos modelos de la Tabla 2 se alcanzan valores de los coeficientes de correlación lineal múltiple y coeficiente de determinación, altos. Asimismo, en el diagnóstico de regresión se cumplen los supuestos, salvo que existen dudas sobre la independencia entre residuos pues los resultados de la prueba de Durbin Watson se ubican en la zona de indefinición ( $DW = 1.87, p = 0.04$ ). Lo anterior indica que puede existir algún nivel de autocorrelación que podría ser, en buena medida, una autocorrelación espacial. También se comprobó que existen muy pocos datos raros, los que no

tuvieron un impacto importante en los coeficientes de regresión, y que las variables en las ecuaciones presentaron valores bajos de colinealidad determinados mediante el factor de inflación de la varianza (FIV).

Las variables en la ecuación logran explicar el 71 % de la variación espacial en el caso de la morbilidad bruta, y el 70 % de la estandarizada por edad y sexo. En la medida que se incrementa el desarrollo del distrito, en sus tres dimensiones, así como la proporción de personas nacidas fuera del país y la frecuencia de viviendas hacinadas (personas por dormitorio) se produce un aumento de la incidencia acumulada de casos, tanto en la Ia como en el IME.

La velocidad alcanzada por la epidemia en su período de mayor reporte se correlaciona con la incidencia acumulada (Ia y el IME), una vez controlado el efecto del resto de variables en las ecuaciones. A mayor número de semanas para alcanzar el máximo reporte de casos



**Tabla 2**

Resultados del modelo global de regresión (GLR), para explicar la incidencia acumulada (bruta y estandarizada) de covid-19 en Costa Rica, entre marzo de 2020 y marzo de 2022, a partir de determinantes sociales de la salud (DSS), por coeficientes y significancia estadística. / **Table 2.** Results of the global regression model (GLR), to explain the cumulative incidence (crude and standardized) of covid-19 in Costa Rica, between March 2020 and March 2022, based on social determinants of health (DSS), by coefficients and statistical significance.

Variables dependientes	Variables independientes	Coefficientes no estandarizados	Coefficientes estandarizados	p
Ia*	Dosis (vacunas) por persona	77.21	0.61	< 0.01
	Dimensión salud (IDS)	0.85	0.16	< 0.01
	Dimensión educación (IDS)	0.58	0.12	< 0.01
	Dimensión económica (IDS)	1.14	0.28	< 0.01
	Número de semanas para alcanzar el máximo reporte de casos	-6.01	-0.12	< 0.01
	% de personas nacidas fuera del país	1.83	0.16	< 0.01
	% de viviendas hacinadas (por dormitorio)	1.88	0.12	< 0.01
IME**	Dosis (vacunas) por persona	0.41	0.60	< 0.01
	Dimensión salud (IDS)	0.005	0.16	< 0.01
	Dimensión educación (IDS)	0.003	0.12	< 0.01
	Dimensión económica (IDS)	0.006	0.29	< 0.01
	Número de semanas para alcanzar el máximo reporte de casos	-0.03	-0.12	< 0.01
	% de personas nacidas fuera del país	0.01	0.15	< 0.01
	% de viviendas hacinadas (por dormitorio)	0.01	0.14	< 0.01

\*Modelo 1:  $R = 0.85$ ,  $R^2$  ajustado = 0.71, ( $p < 0.05$ ). \*\*Modelo 2:  $R = 0.84$ ,  $R^2$  ajustado = 0.70, ( $p < 0.05$ ).

(menor velocidad), se observa una menor incidencia acumulada de casos nuevos. También se evidencia que el aumento en el promedio de vacunas por persona genera un incremento de la incidencia acumulada de casos a nivel de distritos (Ia y el IME), esta es la variable más fuertemente correlacionada con la incidencia acumulada de casos.

Las variables de densidad poblacional, proporción de personas mayores de 65 años y porcentaje de viviendas hacinadas no mostraron correlaciones significativas, por lo que no fueron incluidas en ninguna de las dos ecuaciones de GRL.

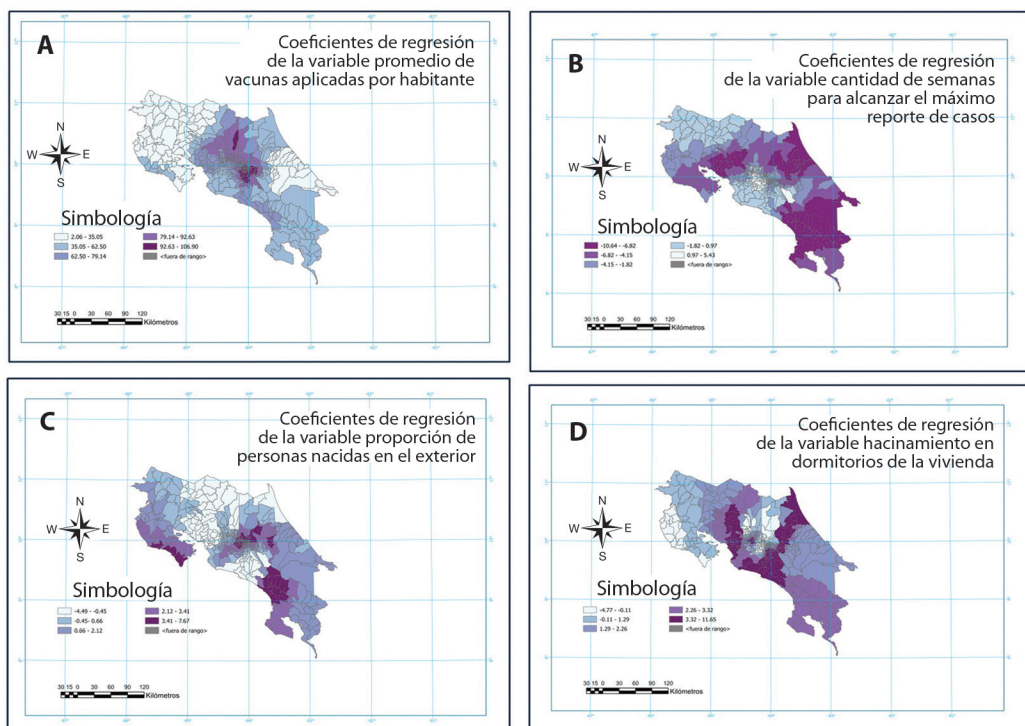
Para el modelo de GWR de la Ia se reporta un  $R^2 = 0.86$  y un  $R^2$  ajustado = 0.82, por lo que se concluye que la bondad de ajuste, considerando además un valor del criterio de información de Akaike (AIC) menor que lo observado en el GLR, es sensiblemente mejor que lo presentado por el modelo de GLR. El modelo GWR corrige las dudas sobre la autocorrelación espacial y aporta una mejor comprensión de los patrones geoespaciales.

Por otra parte, el promedio de vacunas por habitante, el número de semanas para alcanzar el máximo reporte de casos, el desarrollo socioeconómico local (dimensiones económicas, educativa y de salud), así como la proporción de viviendas hacinadas a nivel de dormitorio y la proporción de personas extranjeras (nacidas fuera del país), explican el 82 % de las variaciones espaciales de la Ia bruta, controlando la autocorrelación espacial o las dependencias entre territorios vecinos cercanos.

Los residuos del modelo GWR, analizados mediante la I de Morán, no muestran tendencia significativa a la autocorrelación, por lo que los coeficientes presentados se encuentran, en buena medida, depurados de las dependencias entre territorios vecinos.

En la Fig. 2 se puede observar que el promedio de vacunas por habitante tiene mayor capacidad de explicación de la Ia, sobre todo, en el centro del país, en el entorno de la GAM (sobre todo en los cantones del sur de la GAM) y hacia la región norte. Por cada dosis que se incrementa el promedio de vacunas aplicadas,





**Fig. 2.** Distribución espacial de los coeficientes de regresión de las variables promedio de vacunas por habitante. **A.** Número de semanas para alcanzar el máximo reporte de casos. **B.** Proporción de personas extranjeras (nacidas fuera del país). **C.** Proporción de viviendas hacinadas a nivel de dormitorio. **D.** Según el modelo GWR de la Ia bruta de covid-19 en Costa Rica, entre marzo de 2020 y marzo de 2022. / **Fig. 2.** Spatial distribution of the regression coefficients of the average vaccines per inhabitant variables. **A.** Number of weeks to reach the maximum case report. **B.** Proportion of foreign people (born outside the country). **C.** Proportion of overcrowded housing at bedroom level. **D.** According to the GWR model of the gross AI of covid-19 in Costa Rica, between March 2020 and March 2022.

se reporta un aumento de entre 79 y 106 personas reportadas positivas, acumuladas durante todo el período, por cada mil personas. Este efecto se observa en menor medida hacia el nordeste y el sur del país.

Asimismo, por cada semana que se demore un territorio en alcanzar el máximo reporte de casos (menor velocidad), disminuye entre 4 y 10 personas positivas por cada mil personas en la zona del Caribe, sur y pacífico centro-norte del país. En el entorno de la GAM esta variable tiene mucho menor efecto.

El efecto de la proporción de personas nacidas en el exterior sobre la Ia es mayor fuera de a GAM, excepto en algunos cantones del entorno sur. Por cada punto porcentual de

incremento de las personas nacidas en exterior se incrementa entre 0.66 y 7.67 personas reportadas positivas por cada mil, en la zona del Caribe, la región sur y en los sectores costeros del pacífico norte. En otros territorios fuera de la GAM, como es la mayor parte del sector norte del país, el efecto de esta variable fue muy bajo.

También se puede observar que por cada punto porcentual de incremento de viviendas hacinadas (por dormitorio) se incrementa entre 1 y 12 personas reportadas positivas por cada mil personas. Este efecto se nota en casi todo el país, excepto en territorios costeros del pacífico norte y en algunos distritos del norte del entorno de la GAM.

En la Fig. 3, adicionalmente, se evidencia que el aumento del desarrollo económico a nivel distrital genera un incremento en el reporte de 1 a 4 personas positivas por cada mil. El efecto es muy bajo o inverso en la GAM y su entorno, donde a mayor desarrollo disminuye la probabilidad de una persona de ser reportada positiva. Asimismo, a mayor desarrollo desde el punto de vista educativo, se incrementa la Ia en la mayor parte del país, sobre todo en el entorno de la GAM; sin embargo, hacia el noroeste y el sureste del país el efecto es contrario (pendiente negativa) y los avances educativos disminuyeron la Ia.

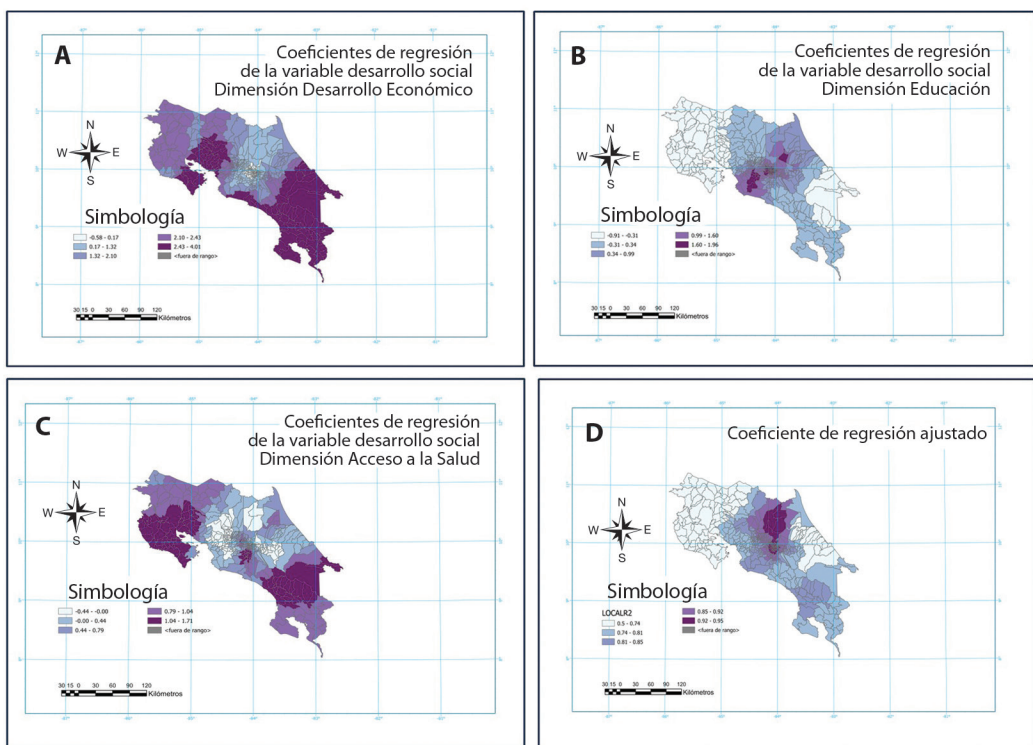
Además, se constató que un mayor desarrollo visto como acceso a la salud generó un incremento de la Ia en la mayor parte del país. El mayor efecto se aprecia fuera de la GAM,

hacia el noroeste y el sur; sin embargo, el efecto es diferenciado respecto a otros distritos en los que una mejor situación de desarrollo significó una menor Ia acumulada en todo el período.

Finalmente, el mapa del coeficiente de regresión local ajustado muestra un muy buen desempeño explicativo del modelo utilizado pues explica la Ia, en más del 74 % en la mayoría de los distritos del país. En los distritos de la zona del Pacífico Norte y el noroeste, así como en muchos distritos de la vertiente del Caribe, la capacidad explicativa desciende a un rango de fuerza media entre el 50 y 74 %.

## DISCUSIÓN

Desde el punto de vista geográfico, la comprensión de las tendencias espaciales del



**Fig. 3.** Distribución espacial de los coeficientes de regresión de las variables desarrollo socioeconómico local para la dimensión económica. **A.** Dimensión educativa. **B.** Dimensión de salud. **C.** Coeficiente de regresión general del modelo y  $R^2$  ajustado. **D.** Según el modelo GWR de la Ia bruta de covid-19 en Costa Rica, entre marzo de 2020 y marzo de 2022. / **Fig. 3.** Spatial distribution of the regression coefficients of the local socioeconomic development variables for the economic dimension. **A.** Educational dimension. **B.** Health dimension. **C.** Overall regression coefficient of the model and adjusted  $R^2$ . **D.** According to the GWR model of the gross AI of covid-19 in Costa Rica, between March 2020 and March 2022.

riesgo por covid-19 utilizando SIG ha generado conocimiento epidemiológico útil para el control (Almeida et al., 2021; De Oliveira et al., 2022; Ismail et al., 2021; Miramontes-Carballada & Balsa-Barreiro, 2021; Orozco et al., 2021; Vicente-Ferreira et al., 2020). Al explorar la autocorrelación espacial local mediante la cartografía de puntos fríos y calientes, se observó que el conglomerado más fuerte tiende a localizarse hacia el centro del país en la GAM y su entorno, formando una zona de alto riesgo o puntos calientes con una certeza del 99 %, en tanto hacia el exterior de la GAM se tienden a concentrar valores más bajos de riesgo, formando algunos conglomerados significativos estadísticamente, de bajo riesgo o puntos fríos. Hacia el exterior de la GAM y hacia las fronteras y costas (excepto la costa del Pacífico Central) se enfrió, apareciendo conglomerados de relativamente baja probabilidad de desarrollar covid-19. A pesar de que el conglomerado de puntos fríos fue menos fuerte, por el nivel de certeza, que el de puntos calientes, su distribución espacial parece contener el alto nivel de propagación hacia una buena parte del resto del país. Se estableció así un amplio sector de contacto entre conglomerados de alta incidencia y los de baja incidencia, que podría interpretarse como un sector de contención o amortiguamiento del conglomerado de puntos calientes ubicado hacia el centro del país.

Los patrones concentrados en el espacio, fuertemente contrastados con territorios vecinos que muestra el presente estudio, se han reconocido también en Brasil: se localizaron conglomerados de alta incidencia de covid-19, coincidiendo con comunidades en severas condiciones de vulnerabilidad social (Alencar-do Nascimento et al., 2022; Dos Santos-Alves et al., 2023). También en Brasil, en el Estado de Bahía, se determinaron conglomerados fríos y calientes bien definidos espacialmente (Souza et al., 2022). En el caso de Indonesia, en la Regencia de Sukoharjo, se localizaron conglomerados de alta incidencia (Hastari et al., 2023), lo mismo que en la ciudad de Yakarta, que se identificó como un territorio influyente en la propagación de la epidemia. El análisis espacial constató el

desplazamiento de los conglomerados de alto y bajo riesgo en el tiempo, pero también se identificaron territorios con tendencia a prevalecer en el tiempo como conglomerados fríos o calientes (Dhewantara et al., 2022).

En el presente estudio, se observó un efecto fuerte y directo de la variable promedio de vacunas contra covid-19 aplicadas por persona por territorio, existe una tendencia clara de que un mayor promedio de dosis aplicadas produce un incremento de la Ia, lo que podría entenderse como un efecto inesperado. La vacunación masiva de la población tuvo un impacto decisivo en el decrecimiento del riesgo de enfermar en Botocuto y Serrada en un 80 %, en Sao Pablo, Brasil (Silva et al., 2022), y en las consultas de emergencia en hospitales, así como en la mortalidad en Estados Unidos de América (Topf et al., 2022). La falta de acceso a seguros de salud tuvo un papel explicativo muy relevante en el esclarecimiento de las variaciones espaciales de mortalidad en Estados Unidos de América a nivel de condado.

A partir de un estudio de evaluación del impacto del programa de vacunación en Estados Unidos de América hasta abril del 2022, se ha mencionado que el impacto de las vacunas podría ser limitado ante la circulación de nuevas variantes (Topf et al., 2022). Desde la perspectiva de la Organización Mundial de la salud (OMS) y a partir del reporte de los países miembros, la pandemia continúa aunque las tasas de hospitalización, el ingreso a cuidados intensivos y las muertes se han reducido considerablemente (Organización Panamericana de la Salud, 2023) y no constituye una emergencia sanitaria global en el 2024, no debe detenerse la vigilancia (Naciones Unidas, 2024) . Si bien las vacunas no se diseñaron para prevenir la infección, sino la enfermedad grave y la muerte, más allá de la infección post vacunación (efecto esperable), la inmunización podría haber relajado las conductas de protección individual y social incrementando la exposición y el riesgo de infección, hipótesis que se maneja en el presente estudio y abre espacio para estudios más específicos (Organización Panamericana de la Salud, 2023).



En el presente estudio se observó que el nivel de desarrollo alcanzado por cada territorio es un factor explicativo importante. Las desigualdades socio económicas tuvieron un significativo potencial explicativo de las variaciones territoriales de la *Ia* de casos. Se trata de relaciones directas a mayor desarrollo económico, mayor riesgo, pero esto no se verifica en el entorno de la GAM del país, donde se constata una relación inversa, a mayor desarrollo socioeconómico menor *Ia*. El índice de desarrollo humano y la desigualdad entre unidades geográficas y también el porcentaje de personas bajo la línea de pobreza y el de hogares vulnerables, han sido establecidos como predictores directos de la incidencia de covid-19 en el nordeste de Brasil (Dos Santos-Alves et al., 2023). La existencia de hogares con severas condiciones de vulnerabilidad social evidenciaron un incremento en el riesgo de transmisión en esas localidades (Alencar-Do Nascimento et al., 2022). Asimismo, las desigualdades socioeconómicas por ingreso de las personas habitantes de las localidades, explican las variaciones en el riesgo de enfermar en Almería (España), donde el riesgo de nuevas infecciones fue mayor en las áreas más desfavorecidas (Fernández-Martínez et al., 2022). Sin embargo, en un estudio ecológico en el en el estado de Amapá (norte de Brasil) se observaron resultados contradictorios con lo mencionado anteriormente; ahí, las localidades con IDH superior resultaron las más afectadas (Leal-Lima et al., 2021), similar a lo encontrado en el estado de Bahía, donde se reportan correlaciones positivas entre el IDH y la incidencia acumulativa (Souza et al., 2022).

La dimensión educativa del desarrollo social se ha estudiado como determinante para la covid-19. El nivel de instrucción de la población mayor de 10 años de edad emerge como uno de los factores con mayor capacidad de explicación del riesgo de enfermar (Alencar-do Nascimento et al., 2022). El índice de desarrollo educacional municipal y el porcentaje de analfabetismo fueron predictores del riesgo en el nordeste de Brasil (Dos Santos-Alves et al., 2023). Sin embargo, en la presente investigación, el mayor desarrollo educativo se asoció

con un exceso de riesgo en esos territorios, pero en las zonas alejadas de las GAM (nordeste y sureste), la relación es inversa, un mayor desarrollo educativo implicó una disminución del riesgo. El presente estudio mostró que, en términos generales, un mayor nivel de desarrollo desde el punto de vista sanitario, referido a mejores condiciones de salud de la población, genera una mayor *Ia*. De manera particular, esta tendencia se verifica hacia el noroeste (Pacífico Norte) y sureste, pero no sucede lo mismo en la GAM y su entorno, donde mejores condiciones de salud de los territorios se asocian con una *Ia* más baja.

Respecto a la velocidad de la epidemia en los países, se ha señalado que a mayor velocidad de la epidemia, a partir del reporte de casos diarios, se incrementa el riesgo de desarrollar covid-19 (Villalobos-Dintrans et al., 2021). Esto coincide con lo reportado en este estudio en que una menor velocidad de la epidemia ha implicado una *Ia* más baja. La presente investigación no encontró un efecto importante de factores demográficos sobre la morbilidad por covid-19. Este hallazgo diverge respecto de otros estudios consultados; por ejemplo, un estudio ecológico mundial, a nivel de país, se destaca que el porcentaje de personas mayores de 65 años de edad presentan una correlación directa con el riesgo de enfermar (El Mouhayyar et al., 2022).

Las variaciones en el porcentaje personas nacidas fuera del país se asoció, en este estudio con un incremento del riesgo de enfermar, coincidiendo con lo encontrado en un estudio de revisión bibliográfica a partir de seis estudios en España, Italia y Suiza, en que se identifican diferencias significativas en el riesgo de enfermar frente a la población local (Jalja et al., 2022). Esta variable adquirió mayor capacidad predictiva hacia la frontera sur y el sur de la GAM, así como en el Pacífico Norte, probablemente asociada a la movilidad poblacional. Se conoce, de otras investigaciones que las restricciones a la movilidad de la población tienen un impacto en la contención de la propagación de la epidemia en Colombia (Paternina-Caicedo et al., 2022).

Los factores ambientales han sido considerados como predictores del riesgo. En Bolivia, por ejemplo, se constató el mayor riesgo relativo para la población urbana (Villca-Villegas et al., 2022). El incremento de la densidad de viviendas generó incrementó el riesgo de transmisión, así como las zonas que presentan problemas higiénicos por el abastecimiento de aguas mediante pozo (Dhewantara et al., 2022). Al respecto, las áreas geográficas con mayor densidad población resultaron las de mayor riesgo de transmisión (Leal-Lima et al., 2021), y, en el Estado de Bahía (Brasil), la densidad población correlacionó con la incidencia de casos y resultó un predictor importante (Souza et al., 2022). En el presente estudio, si bien la densidad poblacional a nivel comunal no resultó un factor predictivo, si lo fue el hacinamiento en la vivienda; de ese modo, a mayor proporción de viviendas con hacinamiento (habitantes por dormitorio) mayor riesgo, tendencia observada en el sur de la GAM y en la mayor parte del país. Las viviendas con más de cuatro personas incrementa el riesgo de transmisión (Alencardo Nascimento et al., 2022) y, en un estudio ecológico internacional a nivel de país, se destaca que el tamaño de la vivienda o espacio por persona, explica el riesgo de transmisión (El Mouhayyar et al., 2022).

En el presente estudio, el modelo de regresión geográfica (GWR) evidenció un comportamiento diferenciado. Un mejor desempeño del modelo, es decir, mayor capacidad explicativa de la variable  $I_a$  (sobre el 80 %) hacia el centro del país (GAM y hacia el centro norte del país) y una capacidad explicativa más baja, cayendo a valores entre 50 y 80 % hacia el Caribe, nordeste y sur del país. Este comportamiento, en términos cualitativos, se ha mantenido así diferenciado como tendencia, al analizar cada una de las variables predictivas, lo que sugiere que los factores analizados adquieren relevancia y poder explicativa variable según zonas geográficas y por lo tanto una determinación del riesgo distinta.

Los modelos ecológicos que utilizan la regresión geográfica (GWR) permiten estimar una diversa de coeficientes de acuerdo al

número de individuos o unidades geográficas involucradas y las variables incluidas (predictores), por lo que hace posible visualizar el papel cambiante de cada predictor en el espacio geográfico y por lo tanto su influencia diferenciada en la probabilidad de enfermar (Almendra et al., 2021), para despejar así, el papel de autocorrelación espacial o influencia de la vecindad geográfica como parte de su explicación (Buffalo & Rydzewski, 2021; Brugués-Rodríguez et al., 2021; Obuekwe et al., 2021; Wang et al., 2021). Este conocimiento es fundamental para orientar estudios individualizados, así como la política de salud, a las particularidades de cada contexto geográfico.

El comportamiento de la morbilidad por covid-19 en los distritos de Costa Rica, en el periodo de marzo del 2020 a mayo del 2022, siguió patrones geoespaciales bien definidos, incluso una vez controlados los efectos de la estructura por edad y sexo. El exceso de riesgo en todo el período se concentró en la GAM y su entorno inmediato, configurando un conglomerado de puntos calientes. En tanto, hacia el exterior de esta zona geográfica, los conglomerados de puntos fríos significativos parecen contener el exceso de riesgo. Esta estructura se pudo explicar desde los determinantes sociales de la salud, comprobando que se generan efectos en la morbilidad, diferenciados territorialmente.

**Declaración de ética:** los autores declaran que todos están de acuerdo con esta publicación y que han hecho aportes que justifican su autoría; que no hay conflicto de interés de ningún tipo; y que han cumplido con todos los requisitos y procedimientos éticos y legales pertinentes. Todas las fuentes de financiamiento se detallan plena y claramente en la sección de agradecimientos. El respectivo documento legal firmado se encuentra en los archivos de la revista.

#### AGRADECIMIENTOS

Se agradece a la Escuela de Tecnologías en Salud de la Universidad de Costa Rica y a



la Universidad Nacional de Costa Rica y particularmente al Posgrado Regional en Ciencias Veterinarias Tropicales, por el apoyo académico y financiero brindado.

## REFERENCIAS

- Alencar-do Nascimento, C. M., Freire-de Souza, C. D., de Oliveira-Silva, L. E., Oliveira-Silva, W., Amaro-Barbosa, N., do Carmo, R. F., de Lima-Andrade, E., de Oliveira-Teixeira, S. H., & Matos-Rocha, T. J. (2022). COVID-19 risk areas associated with social vulnerability in northeastern Brazil: An ecological study in 2020. *The Journal of Infection in Developing Countries*, 16(08), 1285–1293. <https://doi.org/10.3855/jidc.15214>
- Almeida, P. D., de Araújo, T. M. E., de Araújo Filho, A. C. A., Fuentes-Ferreira, A., Fronteira, I., de Melo-Júnior, E. B., & Almeida, M. G. (2021). Análise espaço-temporal da covid-19 em um estado brasileiro. *Revista Baiana de Enfermagem*, 35, e42740. <https://doi.org/10.18471/rbe.v35.42740>
- Almendra, R., Santana, P., & Costa, C. (2021). Spatial inequalities of COVID-19 incidence and associated socioeconomic risk factors in Portugal. *Boletín de la Asociación de Geógrafos Españoles*, (91), 1–27. <https://doi.org/10.21138/bage.3160>
- Ataguba, O. A., & Ataguba, J. E. (2020). Social determinants of health: The role of effective communication in the COVID-19 pandemic in developing countries. *Global Health Action*, 13(1), 1788263. <https://doi.org/10.1080/16549716.2020.1788263>
- Bashash, D., Abolghasemi, H., Naseri, P., Cheraghali, A. M., Soltanpoor, M. J., & Imani-Fooladi, A. A. (2021). The Association of Age, Sex, and RT-PCR Results with the Lymphocyte and Neutrophil Counts in SARS-CoV-2 Infection: A Cross-sectional Analysis of 1450 Iranian Patients with COVID-19. *Iranian Journal of Allergy, Asthma and Immunology*, 20(2), 129–139. <https://doi.org/10.18502/ijaai.v20i2.6046>
- Brugués-Rodríguez, A., Fuentes-Flores, N. A., & Ramírez-Cervantes, A. (2021). Análisis del patrón espacio-temporal de transmisión del COVID-19 por municipios de Baja California. *Estudios Fronterizos*, 22, e071. <https://doi.org/10.21670/ref.2108071>
- Buffalo, L., & Rydzewski, A. L. (2021). Dinámica territorial de pandemia COVID-19 en la provincia de Córdoba Argentina. *Boletín de la Asociación de Geógrafos Españoles*, (91), 1–43. <https://doi.org/10.21138/bage.3149>
- Colton, T. (1979). *Estadística en Medicina*. Masson-Little Brown and Company.
- De Oliveira, F. R. A., Cunha, T. B., Herrero-da Silva, J., Atanaka, M., do Nascimento, V. F., & Terças-Trettel, A. C. P. (2022). Comorbidades em mato-grossenses hospitalizados com COVID-19 em 2020. *Revista Sustinere*, 9(2), 582–602. <https://doi.org/10.12957/sustinere.2021.58575>
- Dhewantara, P. W., Puspita, T., Marina, R., Lasut, D., Rian-di, M. U., Wahono, T., Ridwan, W., & Ruliansyah, A. (2022). Geo-clusters and socio-demographic profiles at village-level associated with COVID-19 incidence in the metropolitan city of Jakarta: An ecological study. *Transboundary and Emerging Diseases*, 69(4), e362–e373. <https://doi.org/10.1111/tbed.14313>
- Dos Santos-Alves, J. C., Ribeiro, C. J. N., Lima, S. V. M. A., Morato, G. S., Andrade, L. A., Santos, M. B., Lopes-De Sousa, Á. F., Nogales-Crespo, K. A., Araújo, D. D. C., & Dos Santos, A. D. (2023). Did the COVID-19 Pandemic Disproportionately Affect the Most Socioeconomically Vulnerable Areas of Brazil? *COVID*, 3(6), 924–936. <https://doi.org/10.3390/covid3060067>
- Duan, Y., Ma, J., Huang, Y., Chen, X., & Zheng, Z. J. (2021). State fragility and the coronavirus disease 2019 (COVID-19) pandemic: An ecologic analysis of data from 146 countries. *Global Health Journal*, 5(1), 18–23. <https://doi.org/10.1016/j.glohj.2021.02.002>
- El Mouhayyar, C., Jaber, L. T., Bergmann, M., Tighiouart, H., & Jaber, B. L. (2022). Country-level determinants of COVID-19 case rates and death rates: An ecological study. *Transboundary and Emerging Diseases*, 69(4), e906–e915. <https://doi.org/10.1111/tbed.14360>
- Environmental Systems Research Institute. (2021). *Auto-correlación espacial (I de Moran global) (Estadística espacial)*. [Documentación]. ArcGIS Pro 3.3. [https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-statistics/spatial-autocorrelation.htm#L\\_](https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-statistics/spatial-autocorrelation.htm#L_)
- Fernández-Martínez, N. F., Ruiz-Montero, R., Gómez-Barroso, D., Rodríguez-Torronteras, A., Lorusso, N., Salcedo-Leal, I., & Sordo, L. (2022). Socioeconomic differences in COVID-19 infection, hospitalisation and mortality in urban areas in a region in the South of Europe. *BMC Public Health*, 22, 2316. <https://doi.org/10.1186/s12889-022-14774-6>
- Habibi, Y., Guellouh, S., Filali, A., & Berchiche, R. (2020). Analysis of social resilience to the novel coronavirus (COVID-19) in Algeria. *Geomatics, Landmanagement and Landscape*, (3), 19–29. <https://doi.org/10.15576/GLL/2020.3.19>
- Hastari, W. I., Lolita, D. A., & Fauzi, L. (2023). Spatial and temporal analysis of covid-19 cases distribution in Sukoharjo regency. *Jurnal Berkala Epidemiologi*, 11(2), 151–159. <https://doi.org/10.20473/jbe.V11I22023.151-159>
- Instituto Nacional de Estadística y Censos. (s. f.). *Proyecciones de Población 2000-2025*. <https://inec.cr/estadisticas-fuentes/estadisticas-demograficas?filtertext=proyecciones%2520de%2520poblaci%25C3%25B3n>

- Ismail, S. N. S., Abidin, E. Z., Rasdi, I., Ezani, N. E., Che, N., & Shamsuddin, A. S. (2021). COVID-19: The Epidemiological Hotspot and the Disease Spread in Malaysia *Malaysian Journal of Medicine and Health Sciences*, 17(S8), 42–50.
- Jaljaa, A., Caminada, S., Tosti, M. E., D'Angelo, F., Angelezzi, A., Isonne, C., Marchetti, G., Mazzalai, E., Gianini, D., Turatto, F., De Marchi, C., Gatta, A., Declich, S., Pizzarelli, S., Geraci, S., Baglio, G., & Marceca, M. (2022). Risk of SARS-CoV-2 infection in migrants and ethnic minorities compared with the general population in the European WHO region during the first year of the pandemic: A systematic review. *BMC Public Health*, 22(1), 143. <https://doi.org/10.1186/s12889-021-12466-1>
- Kabir, K., Taherinia, A., Ashourloo, D., Khosravi, A., Karim, H., Salehi-Shahrabi, H., Hedayat-Yaghoobi, M., Soleimani, A., Siami, Z., Noorisepehr, M., Tajbakhsh, R., Maghsoudi, M. R., Lak, M., Mardi, P., Nouri, B., Mohammadzadeh, M., Azimzadeh, M., & Bakhtiyari, M. (2021). Epidemic size, trend and spatiotemporal mapping of SARS-CoV-2 using geographical information system in Alborz Province, Iran. *BMC Infectious Diseases*, 22(1), 1185. <https://doi.org/10.1186/s12879-021-06870-6>
- Khobragade, A., & Kadam, D. (2021). Spatial mapping and socio-demographic determinants of COVID-19 mortality in India. *Journal of Family Medicine and Primary Care*, 10(11), 4200–4204. [https://doi.org/10.4103/jfmpc.jfmpc\\_903\\_21](https://doi.org/10.4103/jfmpc.jfmpc_903_21)
- Leal-Lima, D., Morais, T. C., Guerrero-Daboin, B., Emidio-Cavalcanti, M. P., Mesaroch, A., Ramos-da Silva, H. M., Guarneri-da Silva, C., Bandeira-de Mello-Monteiro, C., & de Abreu, L. C. (2021). Epidemiological perspective of the evolution of the COVID-19 pandemic in Amapá State, Northern Brazil. *Journal of Human Growth and Development*, 31(3), 414–424. <https://doi.org/10.36311/jhgd.v31i.12610>
- Maroko, A. R., Nash, D., & Pavilonis, B. T. (2020). COVID-19 and inequity: A comparative spatial analysis of New York City and Chicago hot spots. *Journal of Urban Health*, 97(4), 461–470. <https://doi.org/10.1007/s11524-020-00468-0>
- Martines, M. R., Ferreira, R. V., Toppa, R. H., Assunção, L. M., Desjardins, M. R., & Delmelle, E. M. (2021). Detecting space–time clusters of COVID-19 in Brazil: Mortality, inequality, socioeconomic vulnerability, and the relative risk of the disease in Brazilian municipalities. *Journal of Geographical Systems*, 23(1), 7–36. <https://doi.org/10.1007/s10109-020-00344-0>
- Matsumoto, P. S. S., Tenório-Crepaldi, M., Avanzi-Júnior, P. S., Buttler-de Oliveira, M., de Sousa-Regala, R. M., Vasco-Rosseal, T., & Pereira-Caetano-de Lima, J. P. (2020). Mapeamento de covid-19 e isolamento social: Ferramentas de monitoramento e vigilância em saúde pública. *Hygeia: Revista Brasileira de Geografia Médica e da Saúde*, 298–311. <https://doi.org/10.14393/Hygeia0054553>
- Ministerio de Planificación de la República de Costa Rica. (2017). *Índice de Desarrollo Social 2017*. MIDEPLAM.
- Miramontes-Carballada, Á., & Balsa-Barreiro, J. (2021). Territorial impact of the COVID-19 pandemic in Galicia (Spain): A geographical approach. *Boletín de La Asociación de Geógrafos Españoles*, (91), 1–33. <https://doi.org/10.21138/bage.3157>
- Muñoz, E. N., Leon, M. E., Kovacic, F., & Palacios, M. P. (2021). Tendencia de mortalidad no relacionadas con covid-19 en la región del bio-bio, periodo 2016-2020. *Revista ANECEM*, 15(1), 42–48.
- Obuekwe, I. S., Anka, U. S., Ibrahim, S. O., & Adam, U. A. (2021). Quantifying the significance of distance to temporal dynamics of Covid-19 cases in Nigeria using a geographic information system. *Geosfera Indonesia*, 6(1), 40–54. <https://doi.org/10.19184/geosi.v6i1.21405>
- Organización de las Naciones Unidas. (10 de enero de 2024). La Organización Mundial de la Salud pide no bajar la guardia contra el COVID-19. *Noticias de la ONU*. <https://news.un.org/es/story/2024/01/1526977>
- Organización Mundial de la Salud. (2008). *Subsanar las desigualdades en una generación. Alcanzar la equidad sanitaria actuando sobre los determinantes sociales de la salud*. Organización Mundial de la Salud.
- Organización Mundial de la Salud. (6 de abril de 2021a). *Comunicados de prensa: La OMS insta a los países a construir un mundo más justo y saludable tras la pandemia COVID-19*. [Comunicado de prensa]. <https://www.who.int/es/news/item/06-04-2021-who-urges-countries-to-build-a-fairer-healthier-world-post-covid-19>
- Organización Mundial de la Salud. (8 de enero 2021b). *Determinantes Sociales de la Salud: Informe del Director General (EB148/24)*. Consejo Ejecutivo, 148ª reunión. Organización Mundial de la Salud.
- Organización Panamericana de la Salud. (28 de abril de 2023). *Recomendaciones actualizadas sobre las vacunas contra la COVID-19 del Grupo de Expertos en Asesoramiento Estratégico de la Organización Mundial de la Salud, 30 de marzo del 2023*. Organización Panamericana de la Salud. <https://iris.paho.org/handle/10665.2/57418>
- Orozco, A. P., Texidor-Garzón, M. C., Pujol, C. P., Miranda-Reyes, S. C., & Manet-Lahera, L. R. (2021). Teleepidemiología en el enfrentamiento a la COVID-19 en la provincia Santiago de Cuba. *Revista Cubana de Salud Pública*, 47(1), e2672.
- Paternina-Caicedo, A., Alvis-Guzmán, N., Dueñas, C., Narvaez, J., Smith, A. D., & de La Hoz-Restrepo, F. (2022). Impact of mobility restrictions on the dynamics



- of transmission of COVID-19 in Colombian cities. *International Health*, 14(3), 332–335. <https://doi.org/10.1093/inthealth/ihab064>
- Pérez-Rodríguez, N., Noa, R. R., Torres-Reyes, A., Veranes-Miranda, A., Fernández-Lorenzo, J. M., Álvarez, V. O., Garma, D., Más Bermejo, P., & Sánchez-Valdés, L. (2020). Distribución de la población vulnerable a la enfermedad COVID-19 en La Habana, Cuba. *Revista Cubana de Higiene y Epidemiología*, 57(1), e371.
- QGIS. (2019). QGIS (version 3.10 for Desktop, software). <https://docs.qgis.org/3.10/en/docs/index.html>
- Rué, M., & Borrell, C. (1993). Los métodos de estandarización de tasas. *Revisiones en Salud Pública*, (3), 263–295.
- Silva, A. P., Albuquerque-Ribeiro, M., Paiva-Emidio, M., Guerrero-Daboin, B. E., Morais, T. C., Pelegrini-de Oliveira-Abreu, C. I., Pinheiro-Bezerra, I. M., & De Abreu, L. C. (2022). COVID-19 in the municipalities of Botucatu and Serrana, São Paulo, Brazil, the effects of lethality and mortality. *Journal of Human Growth and Development*, 32(2), 302–314. <https://doi.org/10.36311/jhgd.v32.13255>
- Souza, S. S., Costa, E. L., Calazans, M. I. P., Antônio, M. M. P., Dias, C. R. C., & Cardoso, J. P. (2022). Análise espacial dos casos de COVID-19 notificados no estado da Bahia, Brasil. *Cadernos Saúde Coletiva*, 30(4), 572–583. <https://doi.org/10.1590/1414-462x202230040307>
- Topf, K. G., Sheppard, M., Marx, G. E., Wiegand, R. E., Link-Gelles, R., Binder, A. M., Cool, A. J., Lyons, B. C., Park, S., Fast, H. E., Presnetsov, A., Azondekon, G. R., Soetebier, K. A., Adjemian, J., & Barbour, K. E. (2022). Impact of the COVID-19 vaccination program on case incidence, emergency department visits, and hospital admissions among children aged 5-17 Years during the Delta and Omicron Periods-United States, December 2020 to April 2022. *PLOS ONE*, 17(12), e0276409. <https://doi.org/10.1371/journal.pone.0276409>
- Turner, N. A., Pan, W., Martinez-Bianchi, V. S., Maradiaga-Panayotti, G. M., Planey, A. M., Woods, C. W., & Lantos, P. M. (2021). Racial, ethnic, and geographic disparities in novel coronavirus (severe acute respiratory syndrome coronavirus 2) test positivity in North Carolina. *Open Forum Infectious Diseases*, 8(1), ofaa413. <https://doi.org/10.1093/ofid/ofaa413>
- Upshaw, T. L., Brown, C., Smith, R., Perri, M., Ziegler, C., & Pinto, A. D. (2021). Social determinants of COVID-19 incidence and outcomes: A rapid review. *PLOS ONE*, 16(3), e0248336. <https://doi.org/10.1371/journal.pone.0248336>
- Vicente-Ferreira, R., Carvalho, D. M., Souza, A. L. de P., Martines, M. R., & Assunção, L. M. de. (2020). COVID-19 na região de saúde triângulo sul, mg: uma perspectiva cartográfica. *Hygeia: Revista Brasileira de Geografia Médica e da Saúde*, 49–59. <https://doi.org/10.14393/Hygeia0054379>
- Villalobos-Dintrans, P., Castillo, C., de la Fuente, F., & Maddaleno, M. (2021). COVID-19 incidence and mortality in the Metropolitan Region, Chile: Time, space, and structural factors. *PLOS ONE*, 16(5), e0250707. <https://doi.org/10.1371/journal.pone.0250707>
- Villca-Villegas, J. L., Condori-Salluco, N. F., & Alarcon-Arteaga, A. (2022). Estudio ecológico de hogares bolivianos y su relación con la COVID-19, Gestión 2020. *Gaceta Médica Boliviana*, 45(1), 17–22. <https://doi.org/10.47993/gmb.v45i1.360>
- Viswanath, K., Bekalu, M., Dhawan, D., Pinnamaneni, R., Lang, J., & McLoud, R. (2021). Individual and social determinants of COVID-19 vaccine uptake. *BMC Public Health*, 21, 818. <https://doi.org/10.1186/s12889-021-10862-1>
- Wang, L., Xu, C., Wang, J., Qiao, J., Yan, M., & Zhu, Q. (2021). Spatiotemporal heterogeneity and its determinants of COVID-19 transmission in typical labor export provinces of China. *BMC Infectious Diseases*, 21, 242. <https://doi.org/10.1186/s12879-021-05926-x>
- Zamora-Matamoros, L., Sagaró-del-Campo, N. M., Valdés-García, L. E., & Díaz-Silvera, J. (2021). Viajeros internacionales y otros indicadores de la transmisión de la COVID-19 en la provincia Santiago de Cuba International travelers and other indicators of COVID-19 transmission in Santiago de Cuba. *MediSur*, 19(5), 787–797.