





Patrones geospaciales de la dinámica temporal del covid-19 y sus determinantes sociales en Costa Rica

Geospatial patterns of the temporal dynamics of COVID-19 and its social determinants in Costa Rica

Horacio Alejandro Chamizo García¹,  Juan José Romero Zúñiga², 
Suyén Alonso Ubieta³,  Lilliam Quirós Arias⁴, 

DOI: 10.19136/hs.a23n2.5828

Artículo Original

• Fecha de recibido: 4 de abril de 2024 • Fecha de aceptado: 5 de junio de 2024 • Fecha de publicación: 17 de junio de 2024

Autor de correspondencia

Horacio Alejandro Chamizo-García. Dirección postal: Residencial Ayarco 385, casa 20^a, Rio Azul, La Unión, Cartago, Costa Rica.
Correo electrónico: horacio.chamizo@ucr.ac.cr

Resumen

Objetivo: Se analizan los patrones geospaciales de la dinámica temporal de la incidencia de casos de covid-19 en Costa Rica, entre marzo del 2020 y mayo del 2022, se explican desde la perspectiva de los determinantes sociales de la salud (DSS) en el contexto territorial, particularizando de manera comparativa, en dos periodos de tiempo o crestas epidémicas.

Materiales y métodos: Se realizó un estudio ecológico a partir del conteo de semanas hasta alcanzar el máximo reporte de casos durante la primera y la cuarta cresta de la epidemia. Fueron diseñados cartogramas para identificar y analizar los patrones geospaciales y se construyeron modelos explicativos de regresión de Poisson y de Regresión Geográficamente Ponderada (GWR).

Resultados: Se identificó conglomerados geospaciales calientes de alta dinámica temporal de incidencia de casos, así como conglomerados fríos, que evidencia el papel del territorio. Los modelos de regresión señalaron como factores explicativos en la primera cresta epidémica a la densidad poblacional, el hacinamiento de la vivienda por dormitorio, la conexión a internet y el porcentaje de población mayor de 65 años. En la cuarta cresta se identificó la importancia predictiva del desarrollo social territorial en su dimensión económica y el posible papel de otros factores como la movilidad poblacional en zonas costeras del país.

Conclusiones: La dinámica temporal de la epidemia de covid-19, hasta mayo del 2022, se configuró espacialmente en conglomerados de puntos calientes y fríos determinados socialmente. Los efectos de los DSS sobre la dinámica temporal varían territorialmente y deben ser comprendidos geográficamente.

Palabras claves: Infecciones por coronavirus; Estudios ecológicos; Geografía; Determinantes sociales de la salud.

Abstract

Objective: The geospatial patterns of the temporal dynamics of the incidence of covid-19 cases in Costa Rica are analyzed, between March 2020 and May 2022, explained from the perspective of the social determinants of health (DSS) in the territorial context, particularizing in a comparative way, in two periods of time or epidemic peaks.

Materials and methods: An ecological study was carried out over counting weeks until the maximum case report was reached during the first and fourth peaks of the epidemic. Cartograms were designed to identify and analyze geospatial patterns, and explanatory Poisson regression and Geographically Weighted Regression (GWR) models were built.

Results: Hot geospatial clusters with high temporal dynamics of case incidence were identified, as well as cold clusters, which evidence the role of the territory. The regression models indicated explanatory factors in the first epidemic peak, such as population density, overcrowding of housing per bedroom, internet connection, and the percentage of the population over 65 years of age. In the fourth crest, the predictive importance of territorial social development in its economic dimension and the possible role of other factors, such as population mobility in coastal areas of the country, were identified.

Conclusions: The temporal dynamics of the covid-19 epidemic, until May 2022, was spatially configured in clusters of socially determined hot and cold spots. The effects of DSS on temporal dynamics vary territorially and must be understood geographically.

Keywords: Coronavirus infections; Ecological studies; Geography; Social determinants of health.

¹ Doctor en Gobierno y Políticas Públicas. Escuela de Tecnologías en Salud. Facultad de Medicina. Universidad de Costa Rica. San Pedro de Montes de Oca, San José, Costa Rica.

² Doctor en Epidemiología. Escuela de Medicina Veterinaria. Universidad Nacional de Costa Rica. San Pedro de Montes de Oca, San José, Costa Rica.

³ Doctora en Dirección de Empresas. Centro Internacional de Política Económica para el Desarrollo Sostenible, Universidad Nacional de Costa Rica. San Pedro de Montes de Oca, San José, Costa Rica.

⁴ Doctora en Geografía. Escuela de Ciencias Geográficas. Facultad de Ciencias de la Tierra y el Mar. Universidad Nacional de Costa Rica. San Pedro de Montes de Oca, San José, Costa Rica.



Introducción

La salud es un fenómeno complejo determinado socialmente por circunstancias ambientales, económicas, psicológicas y biológicas de la vida de las personas que trascienden de lo individual a lo colectivo, y se manifiestan geográficamente. Dentro del proceso de enfermar, la perspectiva ecológica adquiere una potencia explicativa dependiendo del evento epidemiológico concreto, pero también genera capacidad de influencia transformadora de la situación de salud¹. Los estudios ecológicos con fundamento geográfico se utilizaron habitualmente como herramienta fundamental para la toma de decisiones durante el curso de la pandemia de covid-19, sobre todo para orientar medidas de control epidemiológico diferenciadas espacialmente^{2,3,4,5,6}.

El análisis geográfico se empleó para identificar conglomerados espaciales^{7,8,9}, así como para monitorear las olas de casos nuevos respecto a la auto correlación espacial y a los cambios en los patrones geoespaciales en cada una de ellas^{8,10,11,12}, considerando que la velocidad de avance de la epidemia es determinante en el desempeño de los sistemas de salud, con consecuencias directas en la mortalidad y letalidad por covid-19¹³. La amplia extensión en el tiempo de la pandemia de covid-19 ha contribuido a mostrar una gran heterogeneidad espacial según períodos de tiempo (olas o crestas), por lo que se sugiere que los análisis geográficos deben ajustarse a subperíodos o momentos evolutivos de las epidemias en los países¹¹. La estratificación temporal podría aportar a la comprensión del comportamiento geográfico de este evento.

Se ha evidenciado el papel del contexto geográfico en el avance de la covid-19¹⁴. Una aplicación de interés, desde la perspectiva geográfica, se concreta a través de los modelos que analizan la intersección de la dinámica del tiempo y el lugar¹⁵, utilizando múltiples mapas de riesgo según cortes en el tiempo¹⁶ o intentando modelar la velocidad de avance de la epidemia y su explicación a partir de factores territoriales, como el realizado en el caso de la región metropolitana de Chile¹⁷. Un elemento común de gran interés estriba en explicar este comportamiento desde el punto de vista social.

Las condiciones vida de la población en el territorio se plantea como un factor explicativo de la incidencia de casos nuevos¹⁸, como sucede en las ciudades segregadas socioeconómicamente. Otros factores ambientales como la densidad poblacional a nivel comunal, y el hacinamiento en la vivienda, han sido incluidos en los modelos ecológicos explicativos¹⁹. Del mismo modo, se han incorporado la movilidad poblacional propia de las grandes ciudades en relación con sus barrios y asentamientos contiguos²⁰, y en otros con funciones turísticas¹². La concentración poblacional en asentamientos urbanos se relacionó con conglomerados geoespaciales de mayor riesgo también en Brasil³ y en Santiago de Cuba²¹. Asimismo, el

rol del territorio desde el punto de vista administrativo se ha utilizado como variables proxy de los desplazamientos poblacionales y el nivel de contacto interpersonal^{11,22}.

Factores demográficos como la estructura etaria, definida por variables como la proporción de personas de avanzada edad, y la proporción de personas masculinas, han sido considerada como predictores de la incidencia de casos nuevos^{23,24}. También, como parte de los Determinantes Sociales de la Salud (DSS), los aspectos socioculturales relacionados con el nivel de educación²⁵, la alfabetización²⁰, y el acceso a internet²⁶, pueden ser protectores de la salud en el caso de la epidemia de covid-19. La cobertura de las vacunas contra covid-19, por su parte, ha tenido impactos positivos²⁷, de manera particular en estudios evaluativos; sin embargo, esto se debe tomar con reserva ante la aparición de nuevas variantes del SARS-CoV-2²⁸.

En Costa Rica, no se conocen antecedentes de otra investigación enfocada en medir la velocidad de la incidencia en el país, tema relevante por la gran cantidad de casos presentada en el período entre marzo del 2020 a mayo del 2022 (904,934 caos reportados). El presente estudio se plantea como objetivo explorar los patrones geoespaciales de la velocidad o dinámica temporal de la epidemia de covid-19 en Costa Rica, durante dos crestas y explicarlos desde el punto de vista de los determinantes sociales de la salud (DSS). Para cumplir este propósito, se diseñó una investigación epidemiológica tipo ecológica, fundamentada en distritos, utilizando procedimientos de análisis geoespacial.

Materiales y Métodos

Se diseñó un estudio observacional cuantitativo, ecológico, geográfico, con los distritos de Costa Rica como unidades de análisis. Se llevó a cabo inicialmente la cartografía exploratoria; posteriormente, se identificaron y analizaron sus patrones geoespaciales y, finalmente, se explicaron desde la perspectiva de los DSS utilizando modelos de regresión global y geográfica.

El número de casos diagnosticados por distritos con su fecha de reporte se obtuvo a partir del Ministerio de Salud (autoridad rectora en vigilancia epidemiológica). Se adquirieron datos a partir de bases de datos del Instituto Nacional de Estadísticas y Censos (INEC) producidos por el Censo Nacional de Población y Viviendas (año 2011), y también del Ministerio de Planificación (MIDEPLAN) correspondiente al Índice de Desarrollo Social (año 2017)²⁹ (IDS). Se contó con reportes de personas vacunadas contra covid-19 de diciembre del 2020 hasta el 30 de mayo del 2022 a partir información provista por la Caja Costarricense de Seguro Social (CCSS). También se obtuvieron mapas digitales básicos de polígonos en el sitio del Sistema de Información Territorial (SNIT) del Instituto Geográfico Nacional (IGN) de Costa Rica.

La unidad temporal básica es la semana epidemiológica, de acuerdo con las particularidades de diagnóstico y reporte de casos en el país, tal y como se ha considerado en otros estudios⁸. La unidad territorial considerada fue el distrito, que es la más detallada para Costa Rica.

Las siguientes variables fueron las utilizadas en el estudio:

Tabla 1. Lista de variables dependientes e independientes

Variable	Definición operativa
Dinámica de la Cresta 1 (DC1)	Número de semanas para alcanzar el reporte máximo de casos nuevos de covid-19 desde la semana epidemiológica 10 del 2020 (fecha de inicio de la epidemia en el país) hasta la semana 13 del 2021 (primera cresta de la epidemia)
Dinámica de la Cresta 4 (DC2)	Número de semanas para alcanzar el reporte máximo de casos nuevos de covid-19 desde la semana epidemiológica 49 del 2021 hasta la semana 15 del 2022 (la cresta que aportó el mayor número de casos hasta el 30 de mayo del 2022)
Dimensión Económica del IDS	Promedio de razón de consumo de electricidad residencial Porcentaje de viviendas con acceso a internet residencial
Dimensión educativa del IDS	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 Cobertura de la educación pública secundaria
Dimensión salud del IDS	Peso corporal inadecuado (bajo peso, obesidad, desnutrición), Mortalidad en menores de cinco años, Nacimientos en madres solteras en menores de diecinueve años Cobertura residencial de agua potable.
Cobertura de vacunación contra covid-19	Promedio de vacunas contra covid-19 por habitante
Dinámica de la epidemia	Cantidad de semanas para alcanzar el máximo reporte de casos
Densidad poblacional	Cantidad de habitantes por kilómetro cuadrado
Porcentaje de viviendas hacinadas	Porcentaje de viviendas clasificadas como hacinadas a partir de la cantidad de habitantes por viviendas
Porcentaje de viviendas hacinadas por dormitorio	Porcentaje de viviendas clasificadas como hacinadas a partir de la cantidad de habitantes por dormitorios en la vivienda
Porcentaje de personas mayores de 65 años	Cantidad de personas mayores de 65 años por cada cien habitantes
Porcentaje de personas nacidas fuera del país	Cantidad de personas nacidas fuera del país por cada 100 personas

Fuente: elaboración propia

La dinámica de avance de la epidemia en cada distrito, estimada por la cantidad de semanas para alcanzar el máximo reporte de casos durante las crestas 1 y 4 en Costa Rica (variables dependientes: DC1 y DC2, respectivamente), se estudió contando el número de semanas que transcurrieron entre la semana en la que se alcanza el menor número de casos y la semana en el que se alcanza el máximo reporte en dos períodos de la epidemia en Costa Rica: desde la semana epidemiológica 10 del año 2020 (fecha de inicio de la epidemia en el país) hasta la semana 13 del año 2021 (primera cresta de la epidemia); igualmente en el período desde la semana epidemiológica 49 del 2021 hasta la semana 15 del 2022. Se redactaron mapas temáticos que representan el conteo de semanas, considerando los colores más oscuros para los avances más rápidos en el reporte de casos y que reflejan una situación epidemiológica más dinámica.

La identificación de patrones espaciales de la dinámica de la epidemia en dos períodos consideró dos indicadores globales de autocorrelación en el espacio: la I de Moran y el estadístico G (Getis-Ord). Para la I de Moran se calculó el estadístico Z y su probabilidad p, para definir el nivel de certeza global sobre la autocorrelación. Los resultados positivos de Z definen la existencia de conglomerados espaciales, los negativos indican que el patrón es disperso. En el caso de Getis-Ord, resultados elevados de Z y una p baja, indican conglomerados espaciales calientes o de riesgos altos, en tanto un valor de Z bajo y una probabilidad elevada, indican la presencia de puntos fríos o de bajo riesgo³⁰.

Se presenta cartografía que localiza patrones geoespaciales a nivel local o distrital. En estos mapas se señala con el color blanco a aquellos distritos en los que el conteo de semanas (dinámica temporal) no es distinta a la de sus vecinos (con significancia estadística o certezas que alcanzan 99%, 95% o 90%), y con los colores rojos o los azules se representa a los distritos con dinámicas de incidencia de casos altas (puntos calientes) y bajas (puntos fríos) similares a sus vecinos con distintos niveles de certeza, respectivamente.

Fueron planteados dos tipos de modelos explicativos del comportamiento geoespacial para la explicación de la dinámica de la epidemia en ambos períodos: el modelo global de regresión (*GLR, global linear regression*) en el que se utiliza la regresión de Poisson y el modelo local de regresión (*GWR, Geographically Weighted Regression*). Las variables dependientes fueron el conteo de semanas en cada subperíodo o cresta (dinámica temporal, *DC1* y *DC2*). Las variables independientes fueron los DSS presentados en Tabla 1.

El análisis explicativo partió del modelo de regresión de Poisson³¹:

$$y=e^{ax+axd+b}$$



Donde la variable “y” es la variable a explicar (número de casos positivos o defunciones) y las variables “x” son las variables independientes introducidas en la ecuación (determinantes sociales); “b” es el intercepto, y “a” representa la razón de riesgos. La x_d representa la n -ésima variable en la ecuación.

Para cada modelo se verifica la sobre dispersión, la multicolinealidad, y la prueba de bondad de ajuste mediante el criterio de información de Akaike (AIC) como criterio de calidad explicativa. Se reporta la mejor ecuación significativa estadísticamente³¹.

La GWR no gaussiana para variables de conteo está explicada por la siguiente ecuación³⁰:

$$\ln O_i = B_0 (u_i v_i) + \sum_{B=1}^{B_n} K (B_1 (u_i v_i)) + e$$

Se genera una ecuación por distrito, donde u y v , son sus coordenadas geográficas y K , es el peso asignado al vecino. Para cada ecuación GWR se reportan los coeficientes y se hace cartografía para cada variable en la ecuación, con el propósito de presentar y discutir el comportamiento de cada una, controlando el efecto del resto de las variables. Los AIC del modelo GLR vs. GWR fueron comparados como evidencia del papel de la vecindad geográfica. Se comunica el porcentaje de la varianza explicado por GLR vs. GWR, como criterio de bondad de ajuste³⁰.

La GWR, como parte del análisis espacial, se ha utilizado en estudios ecológicos de la covid-19: estos modelos permiten estimar n cantidad de coeficientes de acuerdo al número de individuos o unidades geográficas involucradas, por lo que hacen posible visualizar como el papel de un mismo predictor cambia en el espacio geográfico influyendo de manera diferenciada en el riesgo⁵.

Resultados

La primera cresta de la epidemia en Costa Rica desde la semana 10 del 2020 hasta la 13 del 2021 acumuló 217,970 casos nuevos durante 56 semanas, en tanto la cuarta cresta desde la semana 49 del 2021 hasta la 15 del 2022 acumuló 278,845 para un total de 19 semanas. La cresta 4 corresponde al período más dinámico desde el inicio de la epidemia en Costa Rica, en marzo del año 2020, hasta el 30 de mayo del 2022 y alcanza un número de casos acumulados muy superior en un menor tiempo.


En el caso de la primera ola, el valor de p del Índice de Moran ($p < 0.001$) evidencia que existe menos del 1% de probabilidad de que el patrón observado se deba al azar; por tanto, el comportamiento de la cantidad de semanas para alcanzar el

máximo reporte casos de covid-19 no es aleatorio. El valor del estadístico Z ($Z=8.10$), permite rechazar la hipótesis de una distribución dispersa; es decir, se confirma la presencia de conglomerados espaciales de territorios con una cantidad de tiempo similar para alcanzar el máximo reporte de casos, formando conglomerados espaciales.

Por su parte, al revisar las puntuaciones de Z en la prueba de Getis-Ord ($Z=-5.60$), se evidencia que los conglomerados tienden a configurarse por bajos valores, poca cantidad de semanas, o poco tiempo para alcanzar el máximo reporte de casos (alta dinámica epidémica). La probabilidad es muy baja para que no ocurra esto ($p < 0.001$), así que se trata de conglomerados muy fuertes de bajo conteo de semanas o de mayor rapidez para alcanzar el máximo reporte de casos. Se puede interpretar como que los territorios en donde se alcanza muy rápidamente el máximo reporte de casos tienden a agruparse.

En el mapa de la Figura 1 se puede identificar como puntos calientes a los territorios con la mayor dinámica temporal de casos nuevos, o sea, que se produce de manera más aceleradamente y se logra el punto máximo en una menor cantidad de semanas. En tanto, los puntos fríos se reconocen como aquellos distritos que tardan más tiempo o en alcanzar el máximo reporte.

Figura 1. Puntos calientes y fríos de la cantidad de semanas para alcanzar el máximo reporte de casos de covid-19 en Costa Rica en la cresta 1, entre las semanas epidemiológicas 10 del 2020 a la 13 del 2021.




Tal como lo indica el estadístico Getis Ord a nivel global de todo el modelo espacial, existen agrupaciones de territorios con pocas semanas para alcanzar la cima de la ola epidemiológica. Estos se han señalado en el mapa como puntos calientes y se han representado con la gama de colores cálidos. Se ubican dos conglomerados de puntos calientes, uno coincidiendo con la GAM y su entorno con gran cantidad de territorios en el que predomina una certeza

muy alta del 99% para pertenecer a esta agrupación; y un segundo, integrado por menos distritos y un menor nivel de certeza (95% y 90%). Se identifican puntos fríos (territorios que han necesitado mayor cantidad de semanas para alcanzar su reporte más alto, con curvas epidémicas menos fuertes) fuera de la GAM, sobre todo hacia su sudeste y con niveles de certeza varados.

Con respecto a la ola que se extiende entre las semanas epidemiológicas de la 49 del 2021 a la 15 del 2022, el valor de p del Índice de Moran ($p < 0.001$) evidencia que existe menos del 1% de probabilidad de que el patrón observado sea debido al azar, el comportamiento de la cantidad de semanas para alcanzar el máximo reporte casos de covid-19 no es aleatorio. El valor del estadístico Z, de $Z=10.00$, permite rechazar la hipótesis de una distribución dispersa, es decir, se confirma la presencia de conglomerados espaciales. De forma complementaria el valor de p del estadístico Getis-Ord ($p = 0.10$), indica que se trata de conglomerados débiles, y no se logra establecer estadísticamente que se trate de conglomerados de alta velocidad en el reporte de casos.

En el mapa de la Figura 2 se revisa el comportamiento geoespacial de los puntos fríos y calientes a nivel local. Se identifican solo conglomerados de puntos fríos, integrados relativamente por pocos puntos fríos o territorios en los que se tarda más en el tiempo el máximo reporte de casos nuevos, es decir, la pendiente de la curva epidémica es menos fuerte. Este conglomerado está ubicado al norte del país en la zona fronteriza y posee una alta certeza estadística. Un segundo conglomerado de puntos fríos se localiza más hacia el sureste, cercano también a la zona fronteriza, pero con un nivel de certeza más bajo (95% o 90%).

Figura 2. Puntos calientes y fríos de la cantidad de semanas para alcanzar el máximo reporte de casos de covid-19 entre las semanas epidemiológicas desde la semana 49 del 2021 a la 15 del 2022.



En la Tabla 2 se reportan los resultados de la regresión GLR, en este caso la regresión de Poisson, para la explicación de las variables dinámica de la cresta 1 (DC1) y dinámica de la cresta 4 (DC2). Se reportan los coeficientes de regresión como razón de riesgos (IRR) para las variables incluidas en las dos ecuaciones. En cada caso se reportan los modelos mejor ajustados (menor AIC), excluyendo variables no significativas estadísticamente.

Tabla 2. Resultados del GLR, explicación de variables *DIC* y *D2C* a partir de variables de DSS incluidas en la ecuación final, razones de riesgo, intervalos de confianza de la razón de riesgos y su significancia al 95%

Variables dependientes	Variables independientes	IRR	IC de IRR	p
DC1	Densidad de población	0.99	0.99-0.99	0.00
	% de viviendas hacinadas (por dormitorio)	0.99	0.99-0.99	0.00
	% de personas sin internet	1.01	1.01-1.02	0.04
	% personas 65 años	0.98	0.97-0.99	0.04
DC2	Dimensión Económica	0.97	0.96-0.98	0.02

DC1: $p(\chi^2)=0.00$, DC2 $p(\chi^2)=0.00$

Fuente: elaboración propia

Los resultados de IRR obtenidos, una vez controlados los efectos atribuidos a las variables incluidas en ambas ecuaciones, muestran efectos entre uno y tres por ciento, es decir, entre media y una semana para alcanzar el máximo reporte de casos. Respecto a la dinámica en la primera cresta, se observa que un incremento en la densidad de población y el porcentaje de viviendas hacinadas (por dormitorio), reduce en un 1% la cantidad de semanas para alcanzar el máximo reporte de casos, es decir, genera un incremento de la dinámica de la epidemia. El aumento de una unidad porcentual de personas mayores de 65 años disminuyó el número de semanas, generando también mayor dinámica de la epidemia. Por otra parte, el aumento de una unidad porcentual de personas sin internet incrementó la cantidad de semanas para alcanzar el máximo reporte de casos, disminuyendo la dinámica de la epidemia.

En el caso de la cuarta cresta, solo fue incluida la variable dimensión económica del IDS. El incremento de una unidad estándar del IDS en su dimensión económica genera una disminución en el número de semanas para alcanzar el máximo reporte de casos, es decir, una mayor dinámica de la epidemia.

Según los resultados del modelo de GWR para la cantidad de semanas para alcanzar el máximo reporte de casos durante la cresta 1 (DC1), se reporta que la desviación de la variable dependiente explicada por el modelo global de Poisson es 43%, en tanto el modelo global explica el 68%. Se verificó



que los resultados de la prueba VIF para cada variable independiente son aceptables y el modelo GWR presenta un menor valor de AIC. Los residuos del modelo GWR fueron analizados (mediante la *I* de Moran), comprobando que no existe tendencia significativa a la autocorrelación global, es así como las dependencias entre territorios vecinos se encuentran controladas en notable medida (Figura 3). Se observa que la capacidad explicativa de cada variable independiente es diferenciada territorialmente.

En la figura 3A se evidencia que a mayor densidad poblacional se incrementa la dinámica de la epidemia, de modo que se disminuyen las semanas para alcanzar el máximo reporte de casos nuevos en la GAM y toda un área notable al centro del país, extendida hacia ambas costas, sobre todo en el Pacífico Central y el Caribe Sur. Los coeficientes se tornan positivos hacia el norte y sur del país.

Asimismo, se observa que un incremento del hacinamiento en los dormitorios de la vivienda se asoció con una mayor dinámica en el reporte de casos nuevos, es decir, menor cantidad de semanas para alcanzar el mayor reporte en el centro del país, incluyendo la GAM, formando un conglomerado extendido hacia la frontera norte y el Pacífico Central (Figura 3B). Por su parte, en la Figura 3C se observa que el incremento de la proporción de personas mayores de 65 años se asoció con una mayor dinámica de nuevos casos en la GAM y su entorno, formando un conglomerado de coeficientes negativos hacia el Pacífico Central.

En la Figura 3D, por otro lado, se observa que el incremento del porcentaje de personas sin internet hacia el sur del país, particularmente en el sector del Caribe Sur y en la GAM se asoció con una mayor dinámica en el reporte de casos nuevos. En tanto, en el sector del Caribe Norte y una parte del Pacífico Norte se advierte lo contrario, un aumento de la proporción de personas sin internet incrementó el conteo de semanas generando una dinámica menor de la epidemia en esas zonas.

Finalmente, se presentan los resultados del modelo de GWR para el caso de la dinámica de la cuarta cresta (Figura 4). Se reporta que la desviación de la variable dependiente explicada por el modelo global de Poisson es 41%, en tanto el modelo global explica el 47%. Se verificó que los resultados de modelo GWR presenta un menor valor de AIC. Los residuos del modelo GWR fueron analizados (mediante la *I* de Moran), comprobando que no existe tendencia significativa a la autocorrelación global.

Respecto a la ecuación GWR explicativa de la cantidad de semanas para alcanzar el máximo reporte de casos durante la cresta 4 (DC2), el incremento en el IDS en su dimensión económica se asocia al aumento de la dinámica

de la epidemia en los territorios, es decir, sobre todo en la GAM y las regiones Pacífico Central y Caribe Norte. En la zona de la frontera sur, por el contrario, el mayor desarrollo socioeconómico se asocia como tendencia con una menor dinámica de la epidemia (Figura 4).

Figura 3. Distribución espacial de los coeficientes de regresión de la densidad poblacional (A), el porcentaje de viviendas hacinadas por dormitorio (B), porcentajes de personas mayores de 65 años (C) y porcentaje de personas sin acceso a internet (D), según el modelo GWR explicativo de la cantidad de semanas para alcanzar el máximo reporte de casos durante la cresta 1 (DC1).


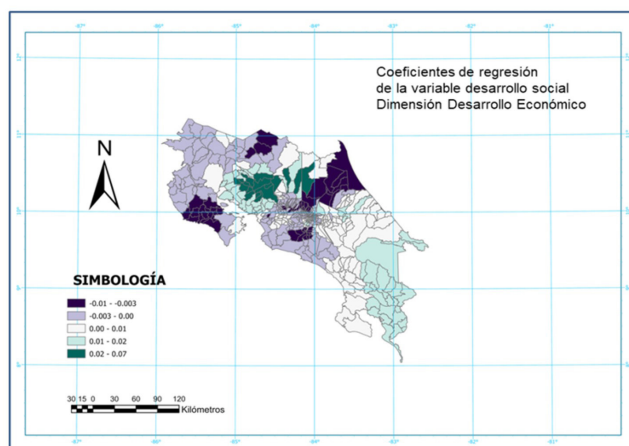


Figura 4. Distribución espacial de los coeficientes de regresión de la variable dimensión económica del IDS según el modelo GWR, explicativo de la cantidad de semanas para alcanzar el máximo reporte de casos durante la cresta 4 (DC2)



Discusión

En la presente investigación, la dinámica de la incidencia, medida por el número de semanas para alcanzar el mayor reporte de casos nuevos, evidencia un comportamiento geoespacial variable al comparar los dos períodos de tiempo. En ambos se identifican conglomerados, sobre todo en la primera cresta donde aparecen conglomerados calientes y fríos de mayor y menor dinámica, respectivamente, en tanto que, en la segunda cresta, los conglomerados son más escasos y solo son fríos.

En cuanto a la velocidad alcanzada, la primera cresta se caracteriza por una dinámica más baja en términos generales, y se aprecian contrastes mayores entre territorios integrados a conglomerados (son los primeros momentos de la epidemia en Costa Rica y la pandemia en el mundo). Así, se identifica un conglomerado sobresaliente por la cantidad de distritos que lo integran, de alta velocidad relativa en el centro del país que coincide con el entorno de la Gran Área Metropolitana, y limita por el sureste a muy corta distancia por un conglomerado de puntos fríos de más baja velocidad. Algo similar se encontró en el estudio sobre la velocidad de la incidencia de casos nuevos en la Región Metropolitana de Chile¹⁷. Se destacan los distritos de la zona Pacífico Central y Norte que corresponde a sectores con gran desarrollo turístico, como se hace notar en un estudio ecológico sobre mortalidad por covid-19³².

Los efectos atribuidos a cada DSS, una vez controlado el papel de cada variable incluida en las ecuaciones, oscilan entre uno y tres por ciento, es decir, alrededor de una semana de incremento o reducción, del tiempo para alcanzar el máximo reporte de casos. Conocido el volumen de casos reportados, estos cambios en la dinámica de la epidemia pudieron afectar la satisfacción en la demanda de servicios y el riesgo de morir. Se pudo determinar, además, que, en la primera cresta, la dinámica de la incidencia de nuevos casos se asoció con factores ambientales como es la densidad poblacional y el hacinamiento en la vivienda. En otras investigaciones se ha evidenciado que el papel de la densidad poblacional, como variable explicativa, varió de una cresta a otra³³. La propagación de la covid-19 se relacionó positivamente con la movilidad, utilizando la variable transporte público per cápita en el norte de Italia, así como con la densidad poblacional³⁴. La aglomeración poblacional en las ciudades se asoció con patrones espaciales concentrados de mayor riesgo también en Brasil³ y en Santiago de Cuba²¹. También, las condiciones de vida hacinadas en la vivienda fue un determinante durante la primera cresta observada en la primavera del año 2020 en Nueva York (2) o en Carolina del Norte¹⁹.

Por otra parte, la velocidad de propagación (aumento relativo de casos entre dos puntos en el tiempo) en Italia, se

correlacionó negativamente con el índice de envejecimiento (número de ancianos por cada 100 personas jóvenes)³⁴. Adicionalmente, la avanzada edad y el sexo masculino han sido identificados 3 estudio, la existencia de población mayor de 65 años en el país se asoció con un incremento en la dinámica de reporte de nuevos casos, efecto más marcado particularmente en zonas de la GAM y el Pacífico Central.

A su vez, en la presente investigación, se encontró explicación para la dinámica de la epidemia a partir del acceso a internet, variable con influencia diferenciada según zonas geográficas. El incremento del porcentaje de personas sin internet hacia el sur del país, particularmente en el sector del Caribe Sur y en la GAM, se asoció con una mayor dinámica en el reporte de casos nuevos, pero esto no ocurre en otras zonas como es en el sector norte del país donde el incremento de personas sin acceso a internet propició una epidemia más distendida en el tiempo, probablemente encontraron conocimiento efectivo a partir de otros medios más de comunicación tradicionales. El acceso a la información y la educación de las personas es un factor relevante, el factor comunicación y la pertenencia a redes sociales resultó muy importante en el avance de la epidemia en Nueva York²⁶. La falta de acceso a internet de banda ancha, se ha señalado como un determinante social de la covid-19 porque afecta directamente la educación, la comunicación social, el acceso a la información e indirectamente, a la estabilidad socioeconómica y el acceso a ingresos³⁵.

Un hallazgo relevante de esta investigación es que, durante la cuarta cresta, ocurrida entre las semanas 49 del 2021 y la 15 del 2022, la más fuerte por su volumen de casos, con velocidades mucho mayores (menor número de semanas para alcanzar el máximo reporte de casos) aunque cuenta igualmente con patrones geospaciales significativos, no alcanza a formar conglomerados tan notables, salvo dos casos de puntos fríos, integrado por relativamente pocos distritos localizados hacia las fronteras norte y sur. A nivel local, se aprecian significativos contrastes en la dinámica de la incidencia de casos entre distritos vecinos por lo que no tienden a formar conglomerados, probablemente asociado al esfuerzo desconcentrado por ajustar las medidas locales a la realidad epidemiológica específica en cada distrito, en este momento de la epidemia en el país.

La constitución de conglomerados está asociada a avances muy rápidos en el espacio geográfico donde no existen diferencias territoriales en la implementación de medidas preventivas, tal y como se reporta a través de una investigación en Nigeria¹⁰. En el presente estudio, la única variable con capacidad explicativa de las desigualdades espaciales en la dinámica de la epidemia durante la cuarta cresta fue el IDS en su dimensión económica. En la medida que mejora el IDS y los territorios presentan mejor condición

económica la dinámica de la epidemia aumenta, sobre todo en la GAM, el Caribe Norte, Pacífico Norte y frontera norte.

En otros estudios a pesar de que no se encontró un patrón de distribución espacial, sino que fue aleatorio, la velocidad de avance de la epidemia se atribuyó a las facilidades de acceso y por lo tanto la movilidad de la población, lo que fue determinante en Yogyakarta¹⁴, evidenciado también en un meta análisis que recomienda la restricción de movilidad como medida de control epidemiológico³⁶. Una situación divergente a la descrita en la GAM de Costa Rica se observa en otras zonas del sur del país, donde una mejor condición económica implicó un menor dinámica de la epidemia. Algunos estudios reportan que la ruralidad y la pobreza multidimensional correlacionaron de manera inversa y significativa con el número de días para alcanzar el pico en el número de casos reportados¹⁷.

Conclusiones

La velocidad o dinámica temporal de la epidemia ha tenido un comportamiento geográfico diferenciado, estableciendo puntos calientes donde rápidamente se alcanzó un máximo reporte de casos nuevos y puntos fríos donde la epidemia transcurrió más distendidamente en el tiempo. Estos patrones han sido explicados a partir de DSS. Los DSS constituyen importantes predictores de la dinámica temporal, sobre todo una vez que se controla el factor vecindad geográfica mediante el análisis de autocorrelación espacial. Los modelos globales de regresión contribuyeron a explicarla, sin embargo, los coeficientes promedio para todo el país no permiten constatar las importantes variaciones territoriales que la presente investigación revela. Los DSS predictores no se comportan en el espacio de manera homogénea, sus variaciones mostradas a través de modelos GWR, constituyen importantes elementos de juicio para comprender las particularidades geográficas en la toma de decisiones preventivas.

Se destaca la robustez del análisis geográfico, para localizar conglomerados geoespaciales y su explicación desde los DSS, lo que puede ser utilizado en la toma de decisiones políticas descentralizadas territorialmente. La presente investigación se encuentra limitada en su alcance explicativo por los escasos de datos más actualizados sobre DSS, se sugiere que en la medida que se localicen otros datos sincrónicos con las crestas de la epidemia, proceder a actualizar el análisis geográfico.

Conflicto de interés

Los autores declaran que no presentan conflicto de interés respecto a la investigación realizada y los hallazgos que se muestra en el presente documento.

Consideraciones éticas

Los datos procesados en la presente investigación son públicos y aparecen disponibles en bases de datos anonimizadas de acceso digital y libre, dispuestos por el organismo competente y autorizado para la vigilancia epidemiológica en Costa Rica (Ministerio de Salud). Las personas autoras se comprometen a presentar el conocimiento generado para su difusión científica y social, utilizando un lenguaje respetuoso para con las personas afectadas y la sociedad en general.

Contribución de autores

Conceptualización: H,J,S,L; Curación de datos: H; Análisis formal: H; Adquisición de Financiamiento: H; Investigación: H,J,S,L, Metodología: H,J,S,L; Administración del Proyecto: H; Recursos: H,J,S,L; Software: H; Supervisión: H,J,S,L; Validación: H,J,S,L; Redacción-Borrador Original: H,J,S,L; Redacción, revisión y edición: H,J,S,L

Uso de inteligencia artificial IA

Los autores declaran que no han utilizado ninguna aplicación, software, páginas web de inteligencia artificial generativa en la redacción del manuscrito, en el diseño de tablas y figuras, ni en el análisis e interpretación de los datos.

Agradecimientos

Se agradece al Posgrado en Ciencias Veterinarias Tropicales de la Universidad Nacional de Costa Rica y a la Escuela de Tecnologías en Salud de la Universidad de Costa Rica

Referencias

1. Castellanos PL. Sobre el concepto de salud-enfermedad. Descripción y explicación de la situación de salud. Boletín Sanitario Panamericano. 1990.10(4). <https://buenosaires.gob.ar/areas/salud/dircap/mat/matbiblio/castellanos.pdf>
2. Maroko AR, Nash D, Pavidonis BT. COVID-19 and Inequity: a Comparative Spatial Analysis of New York City and Chicago Hot Spots. J Urban Health. agosto de 2020;97(4):461-70. <https://doi.org/10.1007/s11524-020-00468-0>
3. Almeida PD, Araújo TME de, Araújo Filho ACA de, Ferreira AF, Fronteira I, Melo Júnior EB de, et al. Análise espaço-temporal da covid-19 em um estado brasileiro. Rev baiana enferm [Internet]. 8 de junio de 2021 [citado 28 de abril de 2022];35. <https://periodicos.ufba.br/index.php/enfermagem/article/view/42740>

4. Ismail SNS, Abidin EZ, Rasdi I, Ezani NE, Che N, Shamsuddin AS. COVID-19: the Epidemiological Hotspot and the Disease Spread in Malaysia. *Malaysian Journal of Medicine and Health Sciences*. 2021;17:10. [https://medic.upm.edu.my/upload/dokumen/202111231849317\)_2021_0639.pdf](https://medic.upm.edu.my/upload/dokumen/202111231849317)_2021_0639.pdf)
5. Almendra R, Santana P, Costa C. Spatial inequalities of COVID-19 incidence and associated socioeconomic risk factors in Portugal. *BAGE* [Internet]. 9 de diciembre de 2021 [citado 2 de mayo de 2022];(91). Disponible en: <https://bage.age-geografia.es/ojs/index.php/bage/article/view/3160>
6. Kabir K, Taherinia A, Ashourloo D, Khosravi A, Karim H, Salehi Shahrabi H, et al. Epidemic size, trend and spatiotemporal mapping of SARS-CoV-2 using geographical information system in Alborz Province, Iran. *BMC Infect Dis*. diciembre de 2021;21(1):1185. <https://bmcinfectdis.biomedcentral.com/articles/10.1186/s12879-021-06870-6>
7. Bilal U, Tabb LP, Barber S, Diez Roux AV. Spatial Inequities in COVID-19 Testing, Positivity, Confirmed Cases, and Mortality in 3 U.S. Cities: An Ecological Study. *Ann Intern Med*. julio de 2021;174(7):936-44. <https://www.acpjournals.org/doi/10.7326/M20-3936>
8. Buffalo L, Rydzewski AL. Dinámica territorial de pandemia COVID-19 en la provincia de Córdoba Argentina. *BAGE* [Internet]. 4 de noviembre de 2021 [citado 4 de mayo de 2022];(91). Disponible en: <https://bage.age-geografia.es/ojs/index.php/bage/article/view/3149>
9. Jesri N, Saghafipour A, Koohpaei A, Farzinnia B, Jooshin MK, Abolkheirian S, et al. Mapping and Spatial Pattern Analysis of COVID-19 in Central Iran Using the Local Indicators of Spatial Association (LISA). *BMC Public Health*. diciembre de 2021;21(1):2227. <https://bmcpubhealth.biomedcentral.com/articles/10.1186/s12889-021-12267-6>
10. Obuekwe IS, Anka US, Ibrahim SO, Adam UA. Quantifying The Significance of Distance to Temporal Dynamics of Covid-19 Cases in Nigeria Using a Geographic Information System. *Geos Ind*. 25 de abril de 2021;6(1):40. <https://jurnal.unej.ac.id/index.php/GEOSI/article/view/21405>
11. Wang L, Xu C, Wang J, Qiao J, Yan M, Zhu Q. Spatiotemporal heterogeneity and its determinants of COVID-19 transmission in typical labor export provinces of China. *BMC Infect Dis*. diciembre de 2021;21(1):242. <https://bmcinfectdis.biomedcentral.com/articles/10.1186/s12879-021-05926-x>
12. Brugués Rodríguez A, Fuentes Flores NA, Ramírez Cervantes A. Análisis del patrón espacio-temporal de transmisión del COVID-19 por municipios de Baja California. *REF* [Internet]. 4 de junio de 2021 [citado 6 de mayo de 2022];22. Disponible en: <https://ref.uabc.mx/ojs/index.php/ref/article/view/919>
13. Departamento de Epidemiología. Informe Epidemiológico No 38. Enfermedad SARS-COV-2. COVID-19 [Internet]. Ministerio de Salud Gobierno de Chile; 2020. Disponible en: <https://www.minsal.cl/nuevo-coronavirus-2019-ncov/informe-epidemiologico-covid-19/>
14. Purwantara S, Ashari Ar, Putro STJ. The relationship between landscape and meteorological parameters on COVID-19 risk in a small-complex region of Yogyakarta, Indonesia. *Bulletin of Geography Physical Geography Series*. 1 de junio de 2021;21(1):27-43. <https://www.semanticscholar.org/paper/The-relationship-between-landscape-and-parameters-a-Purwantara-Ashari/9b26ab705fccc3fd051077cb5f2251d716d9c9d1>
15. Lan Y, Desjardins MR, Hohl A, Delmelle E. Geovisualization of COVID-19: State of the Art and Opportunities. *Cartographica*. marzo de 2021;56(1):2-13. <https://utpjournals.press/doi/10.3138/cart-2020-0027>
16. Azevedo L, Pereira MJ, Ribeiro MC, Soares A. Geostatistical COVID-19 infection risk maps for Portugal. *Int J Health Geogr*. diciembre de 2020;19(1):25. <https://ij-healthgeographics.biomedcentral.com/articles/10.1186/s12942-020-00221-5>
17. Villalobos Dintrans P, Castillo C, de la Fuente F, Maddaleno M. COVID-19 incidence and mortality in the Metropolitan Region, Chile: Time, space, and structural factors. *Morrissey K, editor. PLoS ONE*. 6 de mayo de 2021;16(5):e0250707. <https://dx.plos.org/10.1371/journal.pone.0250707>
18. Duan Y, Ma J, Huang Y, Chen X, Zheng ZJ. State fragility and the coronavirus disease 2019 (COVID-19) pandemic: an ecologic analysis of data from 146 countries. *Global Health Journal*. marzo de 2021;5(1):18-23. <https://linkinghub.elsevier.com/retrieve/pii/S2414644721000026>
19. Turner NA, Pan W, Martinez-Bianchi VS, Panayotti GMM, Planey AM, Woods CW, et al. Racial, Ethnic, and Geographic Disparities in Novel Coronavirus (Severe Acute Respiratory Syndrome Coronavirus 2) Test Positivity in North Carolina. *Open Forum Infectious Diseases*. 1 de enero de 2021;8(1):ofaa413. <https://academic.oup.com/ofid/article/doi/10.1093/ofid/ofaa413/5902825>



20. Khobragade A, Kadam D. Spatial mapping and socio-demographic determinants of COVID-19 mortality in India. *J Family Med Prim Care*. 2021;10(11):4200. https://journals.lww.com/jfmpc/Fulltext/2021/11000/Spatial_mapping_and_socio_demographic_determinants.41.aspx
21. Matamoros LZ. 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*. 2021;19(5):11. <http://medisur.sld.cu/index.php/medisur/article/view/5172>
22. Matsumoto PSS, Tenório Crepaldi M, Avanzi Júnior PS, Buttler de Oliveira M, De Sousa Regala RM, Vasco Rosseal T, et al. Mapeamento de covid-19 e isolamento social: ferramentas de monitoramento e vigilância em saúde pública. *Hygeia*. 20 de junio de 2020;298-311. <http://www.seer.ufu.br/index.php/hygeia/article/view/54553>
23. Niklitschek EM. Tendencia de mortalidad no relacionadas con covid-19 en la región del bio-bio, periodo 2016-2020. :8. <https://pesquisa.bvsalud.org/portal/resource/es/biblio-1282102>
24. Bashash D, Abolghasemi H, Naseri P, Cheraghali AM, Soltanpoor MJ, Imani Fooladi AA. 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. *IJAAI* [Internet]. 19 de abril de 2021 [citado 21 de julio de 2021]; Disponible en: <https://publish.kne-publishing.com/index.php/IJAAI/article/view/6046>
25. Viswanath K, Bekalu M, Dhawan D, Pinnamaneni R, Lang J, McLoud R. Individual and social determinants of COVID-19 vaccine uptake. *BMC Public Health*. diciembre de 2021;21(1):818. <https://bmcpublihealth.biomedcentral.com/articles/10.1186/s12889-021-10862-1>
26. Ataguba OA, Ataguba JE. Social determinants of health: the role of effective communication in the COVID-19 pandemic in developing countries. *Global Health Action*. 31 de diciembre de 2020;13(1):1788263. <https://www.tandfonline.com/doi/full/10.1080/16549716.2020.1788263>
27. Silva AP, Albuquerque Ribeiro M, Paiva Emídio M, Elena Guerrero Daboin B, Cristina Morais T, Inês Pelegrini De Oliveira Abreu C, et al. COVID-19 in the municipalities of Botucatu and Serrana, São Paulo, Brazil, the effects of lethality and mortality. *jhg*. 23 de junio de 2022;32(2):302-14. <https://revistas.marilia.unesp.br/index.php/jhg/article/view/13255>
28. Topf KG, Sheppard M, Marx GE, Wiegand RE, Link-Gelles R, Binder AM, et al. 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. *Okda FA*, editor. *PLoS ONE*. 9 de diciembre de 2022;17(12):e0276409. <https://dx.plos.org/10.1371/journal.pone.0276409>
29. Ministerio de Planificación de la República de Costa Rica. Índice de Desarrollo Social 2017. MIDEPLAM; 2017. <https://www.mideplan.go.cr//indice-desarrollo-social>
30. Environmetal Systems Research Institute. Autocorrelación espacial [Internet]. 2021. Disponible en: <https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-statistics/spatial-autocorrelation.htm>
31. Colton T. Estadística en Medicina. Masson-Little Brownp. Barcelona; 1979.
32. Bonilla-Carrión R, Evans-Meza R, Salvatierra-Durán R. Efecto de factores sociodemográficos en la mortalidad del COVID-19 en Costa Rica: un enfoque geográfico. *Rev Biol Trop*. 30 de marzo de 2023;71(1):e51679. <https://revistas.ucr.ac.cr/index.php/rbt/article/view/51679>
33. Leal Lima D, Cristina Morais T, Guerrero Daboin B, Paiva Emídio Cavalcanti M, Mesaroch A, Moraes Ramos Da Silva H, et al. Epidemiological perspective of the evolution of the COVID-19 pandemic in Amapá State, Northern Brazil. *jhg*. 1 de diciembre de 2021;31(3):414-24. <https://revistas.marilia.unesp.br/index.php/jhg/article/view/12610>
34. Buja A, Paganini M, Cocchio S, Scioni M, Rebba V, Baldo V. Demographic and socio-economic factors, and healthcare resource indicators associated with the rapid spread of COVID-19 in Northern Italy: An ecological study. *Joe W*, editor. *PLoS ONE*. 28 de diciembre de 2020;15(12):e0244535. <https://dx.plos.org/10.1371/journal.pone.0244535>
35. Benda NC, Veinot TC, Sieck CJ, Ancker JS. Broadband Internet Access Is a Social Determinant of Health! *Am J Public Health*. agosto de 2020;110(8):1123-5. <https://ajph.aphapublications.org/doi/full/10.2105/AJPH.2020.305784>
36. Paternina-Cacedo A, Alvis-Guzmán N, Dueñas C, Narvaez J, Smith AD, De La Hoz-Restrepo F. Impact of mobility restrictions on the dynamics of transmission of COVID-19 in Colombian cities. *International Health*. 2 de mayo de 2022;14(3):332-5. <https://academic.oup.com/inthealth/article/14/3/332/6383437>