

Modelos bayesianos espacio-temporales para analizar hospitalizaciones evitables por diabetes mellitus tipo 2 en Costa Rica, 2019-2024

Bayesian spatio-temporal models for analyzing preventable hospitalizations due to type 2 diabetes mellitus in Costa Rica, 2019–2024

Margarita Rojas Pérez¹;  <https://orcid.org/0009-0000-6419-3946>

1. Bachiller en estadística, Dirección Compra de Servicios de Salud, Caja Costarricense de Seguro Social; San José, Costa Rica; mrojaspe@ccss.sa.cr

Recibido 05 de diciembre de 2025 • Aceptado 04 de setiembre de 2026

RESUMEN

Objetivo: analizar el riesgo de hospitalizaciones evitables por diabetes mellitus tipo 2 (DM2) en la Caja Costarricense de Seguro Social durante el período 2019-2024, mediante modelos bayesianos jerárquicos espacio-temporales.

Métodos: estudio ecológico longitudinal usando resultados de la Evaluación de la Prestación de Servicios de Salud de las áreas de salud (AS) y registros de egresos hospitalarios por DM2 (CIE-10: E11). Se ajustaron modelos bayesianos espacio-temporales, con Integrated Nested Laplace Approximation (INLA), incorporando efectos espaciales estructurados y no estructurados, así como dependencia temporal. La selección del modelo se realizó con Deviance Information Criterion (DIC) y Watanabe-Akaike Information Criterion (WAIC). Se evaluó la asociación entre las hospitalizaciones evitables por DM2 y factores geográficos, temporales, clínicos y comunitarios.

Resultados: el mejor ajuste correspondió a una estructura espacial BYM2 e incluyó las variables no control óptimo, obesidad, población rural y cobertura del primer nivel de atención (PNA). Todas mostraron asociaciones positivas y estadísticamente significativas con el riesgo de hospitalización. La población rural presentó el mayor efecto relativo, seguida de la cobertura, el no control óptimo y la obesidad. El análisis espacio-temporal evidenció una disminución de las AS clasificadas con riesgo alto hacia 2024; aunque persistieron AS con riesgo elevado (Coto Brus, Golfito, Limón, Quepos y Turrialba-Jiménez).

Conclusiones: las hospitalizaciones evitables por DM2 presentan un comportamiento heterogéneo en el territorio, asociado a factores individuales, comunitarios y de los servicios de salud. Los modelos bayesianos espacio-temporales constituyen una herramienta útil para identificar áreas prioritarias y fortalecer la toma de decisiones dirigidas a mejorar la efectividad de la atención y el control en el PNA.

Palabras clave: Diabetes Mellitus Tipo 2, Atención Primaria de Salud, Teorema de Bayes, Hospitalización, Análisis Espacio-Temporal.

ABSTRACT

Objective: To analyze the risk of avoidable hospitalizations due to type 2 diabetes mellitus (DM2) within the Costa Rican Social Security Fund (CCSS) during the period 2019–2024 using Bayesian hierarchical spatio-temporal models.

Methods: A longitudinal ecological study was conducted using data from the Health Services Performance Evaluation of health areas and hospital discharge records for DM2 (ICD-10: E11). Bayesian spatio-temporal models were fitted using the Integrated Nested Laplace Approximation (INLA) approach, incorporating structured and unstructured spatial effects as well as temporal dependence. Model selection was based on the Deviance Information Criterion (DIC) and the Watanabe-Akaike Information Criterion (WAIC). The association between avoidable hospitalizations due to DM2 and geographic, temporal, clinical, and community-level factors was assessed.

Results: The best-fitting model corresponded to a BYM2 spatial structure and included suboptimal glycemic control, obesity, rural population, and primary health care (PHC) coverage as covariates. All variables showed positive and statistically significant associations with hospitalization risk. Rural population exhibited the largest relative effect, followed by PHC coverage, suboptimal glycemic control, and obesity. The spatio-temporal analysis revealed a reduction in the number of health areas classified as high risk by 2024; however, several areas remained at elevated risk, including Coto Brus, Golfito, Limón, Quepos, and Turrialba-Jiménez.

Conclusions: Avoidable hospitalizations due to DM2 showed heterogeneous spatial patterns and were associated with individual, community, and health service-related factors. Bayesian spatio-temporal models constitute a useful tool for identifying priority areas and supporting decision-making aimed at improving the effectiveness of primary health care and DM2 management.

Keywords: Diabetes Mellitus, Type 2, Primary Health Care, Bayes Theorem, Hospitalization, Spatio-Temporal Analysis.

INTRODUCCIÓN

En Costa Rica, el primer nivel de atención (PNA) forma parte de la estructura del sistema de salud pública, el cual se basa en un modelo solidario y universal administrado por la Caja Costarricense de Seguro Social (CCSS). Desde los años noventa, esta institución ha experimentado sucesivas reformas que han fortalecido el rol de los Equipos Básicos de Atención Integral en Salud (Ebáis) como eje del modelo de atención (1). En este nivel se desarrollan acciones de promoción de la salud y prevención de enfermedades, como la diabetes mellitus tipo 2 (DM2), con el fin de mantener su control y evitar mayores complicaciones en la persona atendida.

En este contexto, la efectividad del PNA puede evaluarse a través de indicadores como las hospitalizaciones evitables, entendidas como aquellas asociadas a enfermedades que deberían ser atendidas oportunamente en este nivel y que, en principio, no tendrían que culminar en hospitalización. Este indicador parte del supuesto de que una atención primaria efectiva y oportuna puede prevenir, tratar o controlar enfermedades, reduciendo así el riesgo de hospitalización (2).

El análisis de las hospitalizaciones evitables constituye un indicador indirecto tanto de los problemas de accesibilidad a la atención, en especial a los cuidados efectivos en la atención primaria de salud (3), como de la capacidad resolutoria del PNA. Asimismo, permite identificar desigualdades territoriales en el acceso o en la calidad de los servicios de salud (4).

A pesar de los esfuerzos de la CCSS por mantener una atención homogénea en el territorio nacional, se han presentado variaciones regionales en las tasas de hospitalización por causas que se podrían considerar prevenibles. Para analizar estas variaciones se requieren herramientas analíticas robustas, que integren la dimensión espacial y temporal.

En este sentido, los modelos bayesianos espacio-temporales se han consolidado como una estrategia metodológica idónea para analizar la distribución geográfica del riesgo y su evolución temporal, ofreciendo estimaciones suavizadas y cuantificando la incertidumbre de manera explícita (5).

Por tanto, el objetivo del presente trabajo es aplicar un modelo bayesiano jerárquico espacio-temporal para analizar el riesgo de hospitalizaciones evitables por DM2, con el fin de identificar patrones espaciales y tendencias temporales en el comportamiento de la patología.

MARCO TEÓRICO

La Atención Primaria de Salud (APS), desde la Declaración de Alma-Ata (OMS/UNICEF, 1978), se concibe como la estrategia fundamental para alcanzar la cobertura universal, articulando promoción, prevención y atención curativa (1).

La Organización Panamericana de la Salud (OPS) la define como “un enfoque de la salud que incluye a toda la sociedad y que tiene por objeto garantizar el mayor nivel posible de salud y bienestar y su distribución equitativa mediante la atención centrada en las necesidades de las personas tan pronto como sea posible a lo largo del proceso continuo que va desde la promoción de la salud y la prevención de enfermedades hasta el tratamiento, la rehabilitación y los cuidados paliativos, y tan próximo como sea posible del entorno cotidiano de las personas” (6).

En el contexto costarricense, la APS se materializa principalmente a través de los Ebáis. Estos se encuentran organizados administrativamente dentro de las áreas de salud (AS) y articulan la atención médica, la educación sanitaria, la prevención de enfermedades y la participación comunitaria.

Una forma de evaluar el desempeño de la APS es mediante el análisis de las hospitalizaciones evitables, cuyo estudio permite observar su comportamiento en las distintas AS. Desde esa perspectiva, las altas tasas de hospitalizaciones evitables podrían reflejar deficiencias en la prevención, la detección temprana o la continuidad de la atención (4).

Para un análisis de esta índole, el uso de estadística bayesiana resulta de gran utilidad. Este enfoque de la estadística combina información previa del parámetro de interés con los datos observados, con el fin de actualizar el conocimiento sobre el fenómeno en estudio, generando así una distribución de probabilidad *a posteriori* (7). Además, permite incorporar al modelo información conocida proveniente de estudios

anteriores o de la experiencia de personas expertas sobre el parámetro de interés a estimar.

El cálculo de la distribución *a posteriori* es posible por medio del Teorema de Bayes.

Teorema de Bayes: sea $y = (y_1, y_2, \dots, y_n)$ una muestra con densidad $f(y|\theta)$ dependiente de un parámetro θ . Entonces, si suponemos que θ tiene densidad $\pi(\theta)$, se tiene que su densidad *a posteriori* es (8):

$$\pi(\theta|y) = \frac{f(y|\theta)\pi(\theta)}{\int f(y|\theta)\pi(\theta)d\theta}$$

Donde la densidad *a posteriori* se expresa como: $\pi(\theta|y) \propto f(y|\theta) \pi(\theta)$, ya que el término del denominador es una constante. Por lo tanto, la *a posteriori* es el cálculo del producto de la verosimilitud de los datos dado el parámetro de interés $f(y|\theta)$ por la información previa conocida del parámetro, representada por la distribución $\pi(\theta)$.

Esta combinación permite actualizar el conocimiento sobre el parámetro θ a partir de la evidencia empírica, lo que constituye el principio más importante de la inferencia bayesiana.

La estadística bayesiana contempla modelos jerárquicos bayesianos o multinivel, que permiten estructurar el modelo en varios niveles, incluyendo efectos fijos y aleatorios. Dentro de este tipo de modelos se encuentran los modelos bayesianos jerárquicos espacio-temporales, los cuales incorporan efectos espaciales y temporales, es decir, capturan la dependencia entre áreas o puntos geográficos y en el tiempo o periodos, así como el efecto de la interacción entre ambos (8,9).

Los modelos bayesianos espaciales se basan en la autocorrelación espacial, que es el grado en que un valor observado en un lugar está correlacionado con valores observados en lugares cercanos. Este concepto se fundamenta en la primera Ley de la Geografía de Tobler: "Todo está relacionado con todo lo demás, pero las cosas cercanas están más relacionadas que las lejanas" (10). Dichos modelos incluyen explícitamente esta estructura con el fin de captar esa dependencia.

Sin embargo, por su complejidad estructural y número de parámetros, la estimación directa de los modelos espacio-temporales puede resultar computacionalmente difícil si no se dispone de equipos y software adecuados. Para abordar esta dificultad, una de las alternativas más recomendadas es el Integrated Nested Laplace Approximation (INLA), una técnica de inferencia bayesiana que combina aproximaciones analíticas e integración numérica para obtener distribuciones posteriores de manera eficiente (11), y que destaca por su rapidez y por la precisión de las estimaciones obtenidas. A diferencia de los métodos tradicionales basados en Monte Carlo con Cadenas de Markov (MCMC), INLA reduce de manera significativa el costo computacional y el tiempo de procesamiento, lo que lo convierte en una herramienta óptima para el análisis de este tipo de modelos.

JUSTIFICACIÓN METODOLÓGICA

En el análisis de hospitalizaciones evitables por DM2, el componente geográfico resulta fundamental. Al respecto, cabe mencionar que las AS se distribuyen a lo largo del territorio nacional y, al pertenecer a diferentes regiones, presentan diferencias estructurales en factores socioeconómicos como la pobreza, la desigualdad, la educación y el desarrollo regional, entre otros indicadores (12). Estas variaciones pueden incidir en los procesos de salud y en la accesibilidad a los servicios sanitarios. En este sentido, capturar la heterogeneidad territorial permite explorar de manera más precisa cómo el entorno geográfico influye en el riesgo de hospitalizaciones evitables.

Por otra parte, la dimensión temporal también resulta esencial en este tipo de análisis, ya que posibilita observar tendencias y cambios a lo largo del tiempo, los cuales reflejan la evolución de las condiciones de salud. De tal forma, identificar variaciones temporales permite valorar el comportamiento de las diferentes AS en distintos periodos, lo cual es particularmente útil para monitorear los efectos de programas y estrategias de fortalecimiento de la APS. Este componente también contribuye a evaluar la continuidad y la sostenibilidad de la atención, tanto a nivel nacional como regional.

Otro aspecto fundamental es la baja frecuencia de casos en algunas AS y en años específicos, e incluso la existencia de conteos en cero cuando no se registran hospitalizaciones durante un periodo determinado. Ignorar esta característica podría conducir a la subestimación del riesgo en dichas zonas. En estos casos, los modelos bayesianos espacio-temporales resultan de gran utilidad, ya que permiten suavizar las estimaciones y estabilizar los valores en regiones con pocos datos, aprovechando la información de áreas y periodos vecinos (13). De esta forma, se evita interpretar que la ausencia de casos implica necesariamente un riesgo bajo o nulo.

Considerando estos elementos, los modelos jerárquicos bayesianos espacio-temporales constituyen una herramienta metodológica idónea para el monitoreo, el mapeo y la evaluación de enfermedades en salud pública. Estos modelos integran simultáneamente las dependencias espaciales y temporales, aportando robustez estadística y mayor precisión en la estimación de los riesgos. Además, los avances recientes en herramientas estadísticas, como el método Integrated Nested Laplace Approximation (INLA), facilitan el ajuste rápido y eficiente de modelos complejos, reduciendo la carga computacional.

En específico, con este enfoque metodológico es posible abordar de manera integral las variaciones espaciales, temporales y estructurales (características económicas, sociales y de salud) que caracterizan a las hospitalizaciones evitables por DM2, fortaleciendo el análisis y la toma de decisiones orientadas a mejorar la efectividad de la APS en Costa Rica.

MATERIALES Y MÉTODOS

Fuente de datos

Los datos para el PNA se obtuvieron de los registros, listados y resultados de la Evaluación de la Prestación de Servicios de Salud (EPSS) anual realizada por la Dirección Compra de Servicios de Salud (DCSS) en el período 2019-2024. Los datos del segundo y tercer nivel, por su parte, se tomaron de los archivos anuales del egreso hospitalario reportados por el Área de Estadísticas de Salud (AES) para ese período.

Los datos de la variable “egreso” corresponden a la patología DM2 (CIE-10: E11), cuando esta fue reportada como diagnóstico principal en el registro del egreso hospitalario.

Variables de estudio

Se tomaron en cuenta 12 variables independientes (tanto clínicas como sociodemográficas) y una variable dependiente. Para efectos del modelo, todas las variables independientes corresponden a valores promedios quinquenales, con excepción de la cobertura, la cual se incluyó de forma anual. Las variables se definen a continuación:

- **Acceso:** indicador quinquenal definido como el porcentaje de la población que recibió atención en el AS durante el período de estudio. Se calculó a partir del promedio quinquenal de personas atendidas y del promedio quinquenal de la población reportada por el INEC.
- **Área de salud:** unidad administrativa y operativa de la CCSS responsable de gestionar los servicios de salud de primer nivel en un territorio geográfico definido.
- **Ampliación de horario:** cantidad de horas de extensión en la jornada de atención de los Ebáis de las AS, destinadas a incrementar el acceso y la capacidad de atención.
- **Cobertura:** porcentaje anual de la población estimada de 20 años y más con DM2 que fue atendida en las AS.
- **Equipo Básico de Atención Integral en Salud (Ebáis):** unidad funcional básica de atención primaria encargada de brindar atención integral a un sector de la población específico, conformada mínimamente por un médico general, un auxiliar de enfermería y un asistente técnico de atención primaria (ATAP).
- **Hipertensión:** porcentaje de personas con DM2 que presentan diagnóstico de hipertensión arterial (HTA).
- **Índice de Desarrollo Social:** indicador sintético que resume las condiciones sociales y económicas de la población adscrita a las AS, calculado a nivel de estas unidades a partir de los datos distritales publicados por el

Ministerio de Planificación Nacional y Política Económica (MIDEPLAN).

- **No control:** porcentaje de personas con DM2 que no alcanzan un control metabólico óptimo, definido este como un nivel de hemoglobina glicosilada $\geq 7\%$ en población general y $\geq 8\%$ en personas mayores de 80 años.
- **Número de Ebáis:** cantidad total de Ebáis habilitados en cada AS.
- **Obesidad:** porcentaje de personas con DM2 con un índice de masa corporal (IMC) $\geq 30 \text{ kg/m}^2$.
- **Personas adultas mayores:** proporción de la población de 65 años o más respecto a la población total del AS, expresada como porcentaje.
- **Población rural:** proporción de la población residente en zonas rurales del área de adscripción de cada AS, expresada como porcentaje.
- **Primer nivel de atención (PNA):** corresponde a la atención primaria y constituye el punto de contacto inicial entre los individuos, la familia y la comunidad con los establecimientos de salud de la CCSS. Está conformado por los Ebáis.
- **Razón de masculinidad:** cociente entre el número de hombres y el número de mujeres con DM2 en cada AS.
- **Sobrepeso:** porcentaje de personas con DM2 con un IMC ≥ 25 y $< 30 \text{ kg/m}^2$.

Por último, la variable dependiente, egresos totales, se definió como la cantidad absoluta de egresos hospitalarios registrados por cada AS y año del período de estudio. Su estimación requirió la aplicación de los porcentajes de adscripción distrital a los registros de egresos, con el fin de asignar el total correspondiente a cada AS. Este procedimiento fue necesario debido a que los registros institucionales de egresos hospitalarios no incluyen una variable que identifique el AS de adscripción de las personas usuarias al momento del egreso.

Ajuste del modelo

Como primer paso, se realizó un análisis exploratorio de los datos, con el objetivo de identificar patrones espaciales y temporales en las hospitalizaciones evitables por DM2.

Se calcularon las tasas observadas de hospitalización por AS y año. Para evaluar la autocorrelación espacial global se utilizó el Índice de Moran con 999 permutaciones de Monte Carlo, mientras que para explorar los patrones espaciales por AS se utilizó Local Indicators of Spatial Association (LISA).

Este análisis permitió identificar la presencia de dependencia espacial entre las AS, justificando el uso de modelos espaciales jerárquicos.

El cálculo de los valores esperados, por el método de estandarización indirecta, se realizó por medio del paquete INLA, con la función *expected*.

Se analizaron las correlaciones entre las covariables y su asociación con la variable dependiente (ver anexo 2 y 3), con el fin de detectar problemas de multicolinealidad y seleccionar las variables más relevantes para el modelo. Además, se estandarizaron las covariables para facilitar la comparación de los efectos estimados.

Se ajustó un modelo mixto bayesiano espacio-temporal con O_{it} el número observado de egresos hospitalarios por diabetes mellitus tipo 2, en el área de salud $i = 1, \dots, n$ y año $t = 1, \dots, T$.

Se asume que:

$$O_{it} \sim \text{Poisson}(E_{it} * \lambda_{it})$$

Donde E_{it} se consideran los casos esperados de egresos, y λ_{it} el riesgo relativo de hospitalización en el área i y año t .

Donde el riesgo relativo (RR) se define como la razón entre los valores observados de hospitalizaciones y los valores esperados. De esta manera, un valor de RR = 1 indica que el área de salud presenta un riesgo equivalente al promedio nacional; valores menores a 1 reflejan un riesgo bajo (menor ocurrencia de hospitalizaciones que la esperada); y valores mayores a 1 representan un riesgo alto.

El modelo calcula el riesgo relativo suavizado como:

$$\log(\lambda_{it}) = \alpha + \beta_k X + u_{it} + v_{it} + \gamma_t$$

- α es el intercepto global.
- β_k son los coeficientes de la k -énima covariable ($k=1, \dots, 12$)
- X Matrix de covariables
- u_{it} es el efecto espacial estructurado.
- v_{it} es el efecto espacial no estructurado.
- γ_t representa el efecto temporal, modelado como un proceso autorregresivo de primer orden AR(1), el cual asume que la tasa en un año determinado depende linealmente de la tasa del año anterior.

Se eligieron las variables más adecuadas con base en el análisis de correlación entre las covariables, y se evaluaron

distintas combinaciones modelos con dichas variables, para elegir el modelo que tuviera un mejor ajuste a los datos; además, se tomó en cuenta la pertinencia teórica de cada variable para el estudio.

Adicionalmente, se probaron cuatro estructuras espaciales alternativas: Modelo independiente (sin correlación espacial), Modelo Besag (efecto condicional autorregresivo CAR), Modelo BYM (Besag–York–Mollié), que combina un efecto estructurado y otro no estructurado y, por último, el Modelo BYM2, que es una reparametrización reescalada del BYM que mejora la interpretación de la varianza espacial y la estabilidad numérica.

Selección del modelo y herramientas de software utilizadas

Los modelos se compararon mediante el Criterio de Información de Deviance (DIC), el Criterio de Información Watana-be–Akaike (WAIC) y el Conditional Predictive Ordinates (CPO).

El procesamiento y análisis de los datos se realizó en el software R versión 4.5.1 (14), mediante el entorno RStudio (15). Para la manipulación y depuración de datos se emplearon los paquetes dplyr y tidyr del ecosistema tidyverse (16,17), mientras que la visualización de resultados se efectuó con ggplot2 (18). Los resultados tabulares fueron elaborados con el paquete flextable (19). En cuanto al componente espacial, la construcción de las estructuras de vecindad y la estimación de los indicadores de autocorrelación se realizaron con el paquete spdep (20), y el manejo de información geográfica con sf (21) siguiendo las metodologías para datos de salud geo-espacial propuestas por Moraga (10,11). Finalmente, el ajuste de los modelos espacio-temporales se efectuó mediante el paquete INLA (22).

RESULTADOS

El modelo que mejor se ajustó a los datos fue el modelo con una estructura espacial BYM2 y las covariables: no control, obesidad, población rural y cobertura.

Análisis de las covariables

Los coeficientes de la Tabla 1 corresponden a covariables estandarizadas, por lo que representan el cambio esperado en el logaritmo de la tasa de hospitalización ante un aumento de una desviación estándar en cada variable.

Tabla 1
CCSS: Estimación de los efectos fijos, media a posteriori, media exponencial, desviación estándar y límites del intervalo de credibilidad. Estudio de hospitalizaciones evitables por DM2, 2019-2024.

Variable	Media	Media exponencial	sd	2,5 %	97,5 %
Población rural	0,16	17	0,03	0,11	0,21
No control	0,13	14	0,03	0,08	0,18
Obesidad	0,08	8	0,02	0,03	0,12
Cobertura	0,15	16	0,03	0,10	0,20



En el caso de los porcentajes reportados, estos se obtuvieron a partir de la exponenciación de los coeficientes estimados del modelo bayesiano para covariables estandarizadas y representan el cambio porcentual en el riesgo de hospitalización asociado a un incremento de una desviación estándar en cada variable explicativa.

En general, todas las covariables contempladas mostraron efectos positivos y no incluyen el cero en sus intervalos de credibilidad, lo cual es evidencia de que son estadísticamente significativas en relación con la tasa de hospitalizaciones evitables por DM2.

La variable Población rural tiene un efecto positivo, tal como se muestra en la Tabla 1, por lo que un aumento en una desviación estándar en esta variable se asocia a un incremento del 17 % en el riesgo de hospitalización. Esto indica que las AS con un mayor porcentaje de población rural en el quinquenio tienden a registrar más hospitalizaciones evitables, lo cual podría reflejar desigualdades en el acceso o en la continuidad de la APS.

Por otra parte, la variable No control, que refleja la proporción de personas con diabetes sin un control glucémico óptimo durante el quinquenio analizado, también mostró un efecto positivo, lo que implica que un aumento en una desviación estándar en la variable incrementa el riesgo de hospitalización en un 14 %. De tal forma, un menor control se asocia con un incremento en el riesgo de hospitalización.

La variable Obesidad también se asocia positivamente a las hospitalizaciones evitables, por lo que un aumento de una desviación estándar en esta variable se relaciona

con un incremento del 8 % en el riesgo de hospitalización. Esto sugiere que las AS con una mayor prevalencia de obesidad tienen un riesgo levemente superior de registrar hospitalizaciones evitables.

Por último, la Cobertura del primer nivel de atención mostró una asociación positiva con las hospitalizaciones evitables, observándose un aumento del 16 % en el riesgo por cada incremento de una desviación estándar en esta variable. Dado que esta variable corresponde al porcentaje estimado de personas de 20 años y más con DM2 que fueron atendidas en las AS, este resultado no necesariamente implica que una mayor cobertura incremente el riesgo de hospitalización. Una posible explicación es que las AS con mayor cobertura logran captar y dar seguimiento a una mayor proporción de personas con DM2, lo que favorece una identificación y un registro más completos de los casos y sus eventos asociados. En contraste, las AS con menor cobertura podrían tener una menor captación de pacientes o subregistro, influyendo en la asociación observada.

Riesgo relativo

Para el análisis espacial y temporal del riesgo relativo (RR) de hospitalización por DM2, se obtuvieron los valores ajustados del modelo, con el fin de determinar el RR por AS y año del periodo analizado. Los valores de RR obtenidos se clasificaron en tres categorías: bajo si RR es menor que 0,9; medio si RR está entre 0,9 y 1,5; y alto si RR es mayor o igual que 1,5.

En la Figura 1 se muestra la distribución espacial y temporal del RR a lo largo del periodo 2019–2024, según la




Figura 1. Distribución geográfica y evolución del riesgo relativo de hospitalizaciones evitables por DM2 por AS y año, 2019-2024.
Fuente: DCSS. Evaluación de la prestación de Servicios de Salud, 2019-2024.



Figura 2. Evolución temporal del riesgo relativo de hospitalizaciones evitables por DM2 en las áreas de salud que iniciaron con riesgo medio y alto y culminaron con riesgo bajo en el periodo 2019-2024. Fuente: DCSS. Evaluación de la prestación de Servicios de Salud, 2019-2024.

categoría creada. En esta se observa que aunque el patrón de riesgo varía entre los años, existe una reducción visible de las zonas con riesgo alto hacia 2024, lo que podría sugerir una mejora general en la atención o en el control de la enfermedad en diversas AS.

La Figura 2, por otro lado, presenta la evolución temporal de las categorías de RR de hospitalizaciones evitables por DM2 en AS que iniciaron el período con categorías de riesgo medio o alto y finalizaron con riesgo bajo, independientemente de las variaciones observadas en los años intermedios. En general, estas AS tuvieron diferentes variaciones en el periodo, pero finalizaron con un riesgo bajo. La evolución completa de las 105 AS se muestra en el Anexo 5.

El ordenamiento desde el año inicial (2019) hasta el año final (2024) permite visualizar de forma complementaria la trayectoria de las AS que mostraron una reducción global del riesgo a lo largo del período de estudio, lo que facilita la identificación de trayectorias de mejora y patrones de transición temporal del riesgo relativo entre AS.

Los resultados obtenidos permitieron caracterizar las AS según el comportamiento del RR a lo largo del período de estudio. Con base en ello, se identificaron las AS que presentaron de forma constante categorías de riesgo alto y aquellas que se mantuvieron en riesgo bajo. Esta diferenciación permite analizar posibles factores asociados a estas trayectorias




Figura 3. AS con riesgo relativo alto de hospitalizaciones evitables por DM2, 2019-2024. Fuente: DCSS. Evaluación de la prestación de Servicios de Salud, 2019-2024.

y aportar evidencia útil para orientar la toma de decisiones en salud pública.

En total, cinco áreas de salud se han mantenido con un RR alto: Coto Brus, Golfito, Limón, Quepos y Turrialba-Jiménez (Figura 3). En contraste, 21 áreas de salud se han mantenido

con un RR bajo: Bagaces, Carmen-Montes de Oca, Cartago, Concepción-San Diego-San Juan (UNIBE), Coronado, Corralillo-La Sierra, Curridabat, Desamparados 3, El Guarco, Escazú, Goicochea 1, Goicochea 2, Los Santos, Moravia, Oreamuno-Pacayas-Tierra Blanca, Puriscal-Turubares, San Francisco-San Antonio (COOPESANA), San Sebastián-Paso Ancho (ASEMECO), Santa Ana, Tilarán y Zapote-Catedral (Figura 4).

Esta información resulta de utilidad, ya que el cálculo del RR mediante modelos bayesianos espacio-temporales permite obtener estimaciones más precisas y estables, incluso en AS con pocos casos o con valores cero, lo que contribuye a una mejor identificación de territorios prioritarios para la toma de decisiones en salud pública.




Figura 4. AS con riesgo relativo bajo de hospitalizaciones evitables por DM2, 2019-2024. Fuente: DCSS. Evaluación de la prestación de Servicios de Salud, 2019-2024.

DISCUSIÓN

El monitoreo del comportamiento de las enfermedades crónicas no transmisibles es de suma importancia en epidemiología, ya que proporciona información clave para el diseño y la implementación de políticas y programas de salud pública adaptadas a la realidad local. En este escenario, es cada vez más frecuente el uso de herramientas analíticas avanzadas basadas en evidencia, que facilitan la toma de decisiones a partir del análisis de datos y contribuyen al fortalecimiento de los procesos mediante enfoques más precisos y fundamentados.

En el presente estudio se analizó el riesgo de hospitalizaciones evitables por DM2, por medio del uso de modelos mixtos bayesianos espacio-temporales, tomando en cuenta la variación geográfica y temporal, así como factores individuales (covariables no control y obesidad), comunitarios (población rural) y de servicios de salud (cobertura).

Los hallazgos confirman que las variables de salud de nivel individual actúan como determinantes directos y

positivos del riesgo. Un incremento en la proporción de personas con DM2 sin control glucémico óptimo y con obesidad eleva de manera estadísticamente significativa el riesgo de egresos hospitalarios por complicaciones agudas o crónicas de la enfermedad.

Respecto a la dimensión comunitaria, la población rural también mostró una relación positiva con el riesgo de hospitalización. Esto sugiere que los cantones con mayor proporción de población rural tienden a registrar mayor cantidad de casos de hospitalizaciones evitables. En el contexto de Costa Rica, este fenómeno se encuentra estrechamente vinculado con las asimetrías socioeconómicas y del desarrollo territorial que persisten entre la Región Central y las regiones periféricas del país, tal como lo describen Benavides y Artavia (12). Asimismo, este comportamiento refleja las barreras de acceso geográfico, la dispersión poblacional y los desafíos históricos en la continuidad del seguimiento clínico que enfrentan las áreas de salud rurales para garantizar una cobertura efectiva (1,3).

Por otra parte, la cobertura del PNA presentó un efecto positivo sobre el riesgo de hospitalización por DM2. Aunque este resultado podría parecer contradictorio frente a la premisa teórica tradicional de que una mayor oferta de atención primaria reduce linealmente los ingresos hospitalarios (6), algunos estudios realizados en el contexto de la seguridad social costarricense han demostrado que aproximadamente una de cada diez hospitalizaciones clasifica como evitable (2,4). En este punto, es importante considerar que la consolidación de las redes de atención primaria mediante el modelo de Ebáis fortaleció la cobertura de servicios, la captación de usuarios y el seguimiento de pacientes en el PNA (1). En este contexto, es posible que los territorios con mayor cobertura presenten una mejor identificación y registro de personas con DM2 y sus complicaciones, visibilizando perfiles de morbilidad que en zonas con menor cobertura podrían permanecer subregistrados en los sistemas institucionales. Este hallazgo plantea la necesidad de evaluar no solo la cobertura de los servicios, sino también la efectividad de la atención brindada y la calidad de la organización asistencial en su conjunto, aspectos que han sido señalados como determinantes relevantes en la ocurrencia de hospitalizaciones evitables (3).

En general, los resultados obtenidos son consistentes con estudios previos que han aplicado modelos bayesianos espacio-temporales en salud pública. Por ejemplo, en Costa Rica Morera (4) utilizó este tipo de modelos para analizar hospitalizaciones por problemas de salud susceptibles de cuidados ambulatorios, evidenciando diferencias geográficas en el riesgo y demostrando la utilidad de incorporar la dependencia espacial para obtener estimaciones más estables. De forma similar, el presente estudio identificó una distribución heterogénea del riesgo de hospitalizaciones evitables por DM2 entre las AS y permitió reconocer territorios con riesgo persistentemente elevado a lo largo del período analizado.

Por otro lado, a nivel internacional, Asmarian *et al* (5) mostraron que los modelos espaciales bayesianos ajustados

mediante INLA constituyen una herramienta robusta para el mapeo de enfermedades, especialmente cuando se analizan eventos poco frecuentes o datos con una elevada proporción de ceros. Asimismo, Kim y Lim (13) mostraron que la incorporación conjunta de componentes espaciales y temporales permite caracterizar de manera más adecuada los patrones de mortalidad e incidencia de enfermedades crónicas al considerar simultáneamente la variabilidad espacial y temporal del riesgo. En concordancia con estos hallazgos, el presente estudio evidenció que la modelación espacio-temporal permitió caracterizar con mayor precisión la heterogeneidad territorial y temporal de las hospitalizaciones evitables por DM2, aportando información útil para la vigilancia epidemiológica y la planificación de intervenciones en el PNA.

CONCLUSIONES

Los resultados de este estudio aportan evidencia de que las hospitalizaciones evitables por DM2 pueden estar asociadas tanto con factores individuales como con determinantes comunitarios y características de los servicios salud. Esto se evidenció mediante las asociaciones identificadas entre las covariables incluidas en el modelo y el riesgo de hospitalización, lo que confirma el carácter multifactorial de este evento y la necesidad de abordajes integrales para su comprensión e intervención.

El análisis espacio-temporal permitió identificar variaciones geográficas y temporales en el riesgo de hospitalización entre las AS, mostrando la existencia de patrones diferenciales en el territorio. Estos hallazgos facilitan el reconocimiento de AS prioritarias, donde las intervenciones pueden adaptarse según las necesidades locales y las características específicas de la población, favoreciendo una planificación más focalizada y potencialmente más efectiva.

Respecto a la asociación positiva observada entre la cobertura del PNA y el riesgo de hospitalización, los resultados sugieren una relación compleja. Una mayor cobertura no necesariamente implica una reducción inmediata del riesgo, sino que favorece la capacidad institucional de captación, diagnóstico oportuno y registro de casos. Por otra parte, las hospitalizaciones pueden estar influenciadas por factores adicionales relacionados con la severidad clínica, la adherencia al tratamiento, los determinantes sociales o la capacidad resolutoria de los servicios. Esto resalta que, para futuras políticas, es indispensable trascender la cobertura cuantitativa y evaluar, además, la efectividad clínica, la capacidad resolutoria y la adherencia al tratamiento.

Debe considerarse que las hospitalizaciones evitables constituyen un indicador indirecto del desempeño del sistema de salud, debido a que los egresos hospitalarios pueden verse influenciados por múltiples factores clínicos, sociales y de acceso a los servicios. Sin embargo, pese a estas limitaciones, los modelos bayesianos espacio-temporales demostraron ser herramientas útiles para el monitoreo del comportamiento territorial del riesgo, permitiendo identificar

patrones espaciales y temporales relevantes para la vigilancia y la gestión en salud pública.

Desde la perspectiva de política pública, los hallazgos sugieren la necesidad de fortalecer estrategias diferenciadas según el contexto territorial, priorizando AS con mayor riesgo y considerando no solo la expansión de la cobertura de servicios, sino también la calidad, la continuidad y la oportunidad de la atención. El uso de herramientas analíticas espacio-temporales puede contribuir a orientar la asignación de recursos, apoyar la toma de decisiones y fortalecer estrategias de prevención y manejo oportuno de la DM2.

Finalmente, para futuros estudios se recomienda ampliar la serie temporal con un mayor número de años para mejorar la estimación de la correlación y las tendencias temporales. Asimismo, se sugiere utilizar covariables con variación anual en lugar de agregaciones por quinquenios, con el fin de capturar adecuadamente la dinámica temporal y evitar que parte importante de la variabilidad sea absorbida por componentes aleatorios del modelo. Estas consideraciones adquieren especial relevancia si se pretende emplear este tipo de modelos con fines predictivos.

AGRADECIMIENTOS

La autora expresa su agradecimiento a la Dirección Compara de Servicios de Salud y, en particular, al equipo de Estadística e Información, por la oportunidad de desarrollar este estudio, así como por el apoyo brindado y por proporcionar la información necesaria para su desarrollo.

CONFLICTO DE INTERESES

La autora declara no presentar conflictos de interés.

ASPECTOS ÉTICOS

El estudio utilizó bases de datos institucionales agregadas sin identificación individual, por lo que no implicó intervención directa en personas.

Ver material suplementario
a01v5n1-Suppl 1

REFERENCIAS BIBLIOGRÁFICAS

1. Vargas W. *Atención primaria de salud en acción: su contexto histórico, naturaleza y organización en Costa Rica*. San José: EDNASSS-CCSS; 2006.
2. Morera M, Aparicio A. En Costa Rica una de cada diez hospitalizaciones es evitable. *Rev Costarric Salud Pública*. 2011;20(1):1-4.
3. Peritó S, Delgado E. Hospitalizaciones evitables. ¿Quién soporta la carga de la prueba? *Gac Sanit*. 2003;17(5):419-25.
4. Morera M. *Modelos bayesianos espacio-temporales aplicados a las hospitalizaciones por problemas de salud susceptibles de cuidados ambulatorios en Costa Rica* [Tesis doctoral]. Las Palmas de Gran Canaria: Universidad de Las Palmas de Gran Canaria; 2010.

5. Asmarián N, Ayatollahi SMT, Sharafi Z, Zare N. Bayesian spatial joint model for disease mapping of zero-inflated data with R-INLA: a simulation study and an application to male breast cancer in Iran. *Int J Environ Res Public Health* [Internet]. 2019;16(22):4460. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/31766251/>
6. Organización Panamericana de la Salud. *Atención primaria de salud* [Internet]. Washington, D.C.: OPS; s.f. Disponible en: <https://www.paho.org/es/temas/atencion-primaria-salud>
7. Correa JC, Barrera CJ. *Introducción a la estadística bayesiana*. Medellín: Instituto Tecnológico Metropolitano; 2018.
8. Alcalde M. *Modelos jerárquicos bayesianos* [Trabajo de fin de grado]. Zaragoza: Universidad de Zaragoza; 2022.
9. Mirás B. *Modelo espacial bayesiano para la estimación de la invalidez en España con la metodología INLA* [Trabajo fin de máster]. Madrid: Universidad Carlos III de Madrid; 2019.
10. Moraga P. *Datos de salud geoespacial: modelado y visualización con R-INLA y Shiny*. Boca Raton: Chapman & Hall/CRC; 2019.
11. Moraga P. *Spatial statistics for data science: theory and practice with R*. Boca Raton: Chapman & Hall/CRC; 2023.
12. Benavides S, Artavia ML. Asimetrías en el desarrollo de los territorios de Costa Rica. *Atl Rev Econ* [Internet]. 2018;1(1). Disponible en: <https://www.aroec.org/ojs/index.php/ARoEc/article/view/28>
13. Kim H, Lim H. Comparison of Bayesian spatio-temporal models for chronic diseases. *J Data Sci* [Internet]. 2010;8(2):189–211. Disponible en: <https://jds-online.org/journal/JDS/article/914/info>
14. R Core Team. *R: A language and environment for statistical computing* [Internet]. Vienna: R Foundation for Statistical Computing; 2024. Disponible en: <https://www.R-project.org>
15. Posit Software. *RStudio: Integrated development environment for R* [Internet]. Posit Software, PBC; 2024. Disponible en: <https://posit.co>
16. Wickham H, François R, Henry L, Müller K. *dplyr: A grammar of data manipulation* [Internet]. CRAN; 2024. Disponible en: <https://CRAN.R-project.org/package=dplyr>
17. Wickham H, Girlich M. *tidyr: Tidy messy data* [Internet]. CRAN; 2024. Disponible en: <https://CRAN.R-project.org/package=tidyr>
18. Wickham H. *ggplot2: Elegant graphics for data analysis* [Internet]. New York: Springer-Verlag; 2016. Disponible en: <https://ggplot2.tidyverse.org>
19. Gohel D, Skintzos P. *flextable: Functions for tabular reporting* [Internet]. CRAN; 2024. Disponible en: <https://CRAN.R-project.org/package=flextable>
20. Bivand R. *spdep: Spatial dependence: Weighting schemes, statistics and models* [Internet]. CRAN; 2024. Disponible en: <https://CRAN.R-project.org/package=spdep>
21. Pebesma E. Simple features for R: Standardized support for spatial vector data. *R J* [Internet] 2018;10(1):439–46. Disponible en: <https://journal.r-project.org/articles/RJ-2018-009/index.html>
22. Rue H, Martino S, Chopin N. Approximate Bayesian inference for latent Gaussian models by using Integrated Nested Laplace approximations. *J R Stat Soc Ser B Stat Methodol* [Internet] 2009;71(2):319–92. Disponible en: <https://doi.org/10.1111/j.1467-9868.2008.00700.x>