

*Artículo original*

# Cambios estructurales en la demanda de urgencias respiratorias en Chile (2017–2024): un análisis retrospectivo mediante modelamiento bayesiano de series temporales

## *Structural changes in respiratory emergency demand in Chile (2017–2024): a retrospective Bayesian time-series analysis*

Eric Comincini Cantillo<sup>1</sup> 

Jorge Homero Wilches Visbal<sup>2</sup> 

<sup>1</sup>Médico, Maestría en Epidemiología. Fundación Universitaria del Área Andina. Santiago, Chile.

<sup>2</sup>Doctor en Física. Facultad de Ciencias de la Salud. Universidad del Magdalena. Santa Marta, Colombia.

**Correo electrónico autor principal y de correspondencia:** Dr. Eric Comincini [comincinieric56@gmail.com](mailto:comincinieric56@gmail.com)

### RESUMEN

**Objetivo:** Identificar cambios estructurales en la demanda de urgencias respiratorias en Chile entre 2017 y 2024 mediante un enfoque bayesiano de series temporales que incorpora estacionalidad, efectos de día de la semana y puntos de cambio suaves.

**Materiales y métodos:** Se realizó un estudio ecológico de series temporales a partir de registros administrativos oficiales de 33.597.638 atenciones de urgencia respiratoria en Chile entre el 1 de enero de 2017 y el 31 de diciembre de 2024. Los conteos diarios fueron estratificados por nivel asistencial: atención primaria de urgencia (APS) y servicios de urgencia hospitalarios. Se ajustaron modelos bayesianos de regresión binomial negativa con estacionalidad anual mediante términos de Fourier, efectos de día de la semana y dos puntos de cambio estructural con transición suave definidos a priori según hitos epidemiológicos de la pandemia por COVID-19. Los efectos estructurales se resumieron mediante razones multiplicativas e intervalos creíbles del 90%, y se compararon con métodos clásicos: CUSUM, medias móviles con umbral Z y segmentación determinista.

**Resultados:** De las 33.597.638 atenciones registradas, 24.617.474 correspondieron a atención primaria y 8.980.164 a servicios hospitalarios. La serie presentó marcada estacionalidad anual y dos transiciones estructurales coherentes con las fases inicial y posterior de la pandemia. Ambos niveles asistenciales mostraron razones multiplicativas inferiores a la unidad en el primer punto de cambio y superiores en el segundo. En la comparación retrospectiva, el enfoque bayesiano presentó menor latencia de detección respecto a los métodos clásicos.

**Conclusiones:** La demanda de urgencias respiratorias en Chile entre 2017 y 2024 presentó cambios estructurales claramente distinguibles de la variación estacional, con patrones diferenciados entre niveles de atención. El modelamiento bayesiano de series temporales permitió una caracterización más precisa de las transiciones en la demanda asistencial, respaldando su utilidad como herramienta analítica para la vigilancia de sistemas de salud en contextos de alta variabilidad.

**Palabras clave:** Urgencias respiratorias; series temporales; modelamiento bayesiano; cambios estructurales; atención primaria; hospitales; Chile.

## ABSTRACT

**Objective:** to identify structural changes in respiratory emergency demand in Chile between 2017 and 2024 using a Bayesian time-series framework incorporating annual seasonality, day-of-week effects, and smooth change points, stratified by level of care.

**Materials and Methods:** An ecological time-series study was conducted using official administrative records of 33,597,638 respiratory emergency visits in Chile from January 1, 2017, to December 31, 2024. Daily counts were stratified by care level: primary care emergency services (APS) and hospital emergency departments. Bayesian negative binomial regression models were fitted incorporating Fourier-based annual seasonality, day-of-week effects, and two a priori structural change points with smooth transitions aligned to key COVID-19 epidemiological milestones. Structural effects were summarized using multiplicative ratios and 90% credible intervals, and compared with classical methods including CUSUM, moving averages with Z-score thresholds, and deterministic segmentation.

**Results:** Of the 33,597,638 visits recorded, 24,617,474 occurred in primary care and 8,980,164 in hospital emergency departments. The series exhibited marked annual seasonality and two structural transitions consistent with the early and later pandemic phases. Both care levels showed multiplicative ratios below unity at the first change point and above unity at the second. The Bayesian approach demonstrated shorter detection latency than classical methods in retrospective comparison.

**Conclusions:** Respiratory emergency demand in Chile between 2017 and 2024 displayed structural changes clearly distinguishable from seasonal variation, with distinct patterns across care levels. Bayesian time-series modeling enabled more precise

characterization of demand transitions, supporting its use as an analytical tool for health system surveillance in high-variability contexts.

**Keywords:** Respiratory emergencies; time-series analysis; Bayesian modeling; structural change; primary care; hospitals; Chile.

## INTRODUCCIÓN

La demanda de atención en servicios de urgencias respiratorias constituye un componente central de los sistemas de salud, particularmente en contextos de brotes epidémicos y pandemias, donde la carga asistencial puede variar abruptamente en el tiempo y exhibir patrones estacionales complejos. Diversos estudios han demostrado que las visitas a servicios de urgencia por causas respiratorias presentan oscilaciones significativas asociadas tanto a la circulación de virus respiratorios como a cambios en el comportamiento de búsqueda de atención y en la organización de los servicios de salud [1].

Durante la pandemia de COVID-19, múltiples investigaciones documentaron una reducción marcada de las visitas a los servicios de urgencia en distintos países, especialmente durante los primeros meses de 2020, seguida de fases de recuperación parcial y nuevas fluctuaciones posteriores [2,3]. Estos cambios han sido atribuidos a una combinación de factores, incluyendo la implementación de medidas de confinamiento, la reducción de la circulación de otros virus respiratorios y la percepción de riesgo asociada a la atención presencial en establecimientos de salud [3]. En este contexto, los registros de visitas a urgencias han sido ampliamente utilizados como herramientas de vigilancia sindrómica, dada su disponibilidad rutinaria y su capacidad para reflejar de manera temprana cambios en la dinámica epidemiológica respiratoria [4].

El análisis de series temporales ha sido una estrategia ampliamente empleada para modelar la demanda asistencial en servicios de urgencia. En particular, modelos basados en regresión de Poisson, binomial negativa y enfoques autorregresivos han sido utilizados para describir y predecir el número de atenciones diarias, incorporando tendencias temporales y estacionalidad [5]. Sin embargo, estos enfoques clásicos pueden presentar limitaciones cuando las series presentan sobredispersión, heterocedasticidad y cambios estructurales abruptos, características frecuentes en los datos de urgencias respiratorias durante crisis sanitarias [6].

En este escenario, los modelos bayesianos de series temporales han emergido como una alternativa metodológica robusta para la detección de cambios estructurales, al permitir la incorporación explícita de estacionalidad, efectos sistemáticos como el día de la semana y mecanismos probabilísticos de puntos de cambio con estimación directa de la incertidumbre [6,7]. Estos enfoques han sido aplicados con éxito en vigilancia epidemiológica y

sindrómica, mostrando ventajas frente a métodos determinísticos o basados en umbrales fijos, particularmente en contextos de alta variabilidad y transiciones graduales entre regímenes temporales [7].

En Chile y en otros países de América Latina, diversos estudios recientes han descrito modificaciones relevantes en el uso de servicios de urgencia y en la circulación de patógenos respiratorios durante la pandemia de COVID-19. Estas investigaciones han documentado cambios sustanciales en la demanda asistencial y en los patrones epidemiológicos respiratorios utilizando datos de vigilancia sanitaria y registros administrativos. Sin embargo, la mayoría de estos análisis se han basado en descripciones agregadas o evaluaciones epidemiológicas puntuales, con un uso aún limitado de modelos formales de series temporales orientados a la identificación de cambios estructurales en la dinámica de la demanda asistencial.[8–10].

A partir de la evidencia internacional disponible, se planteó como hipótesis que la pandemia por COVID-19 produjo un cambio estructural abrupto en la demanda de atenciones de urgencia respiratorias en Chile, seguido posteriormente de un régimen temporal distinto, caracterizado por una recuperación progresiva de la demanda asistencial. Asimismo, se planteó que la magnitud y dinámica de estos cambios estructurales podrían diferir entre los niveles asistenciales, entre la atención primaria de urgencia (APS) y los servicios de urgencia hospitalarios. El presente estudio tiene como objetivo identificar cambios estructurales en la demanda de urgencias respiratorias en Chile entre 2017 y 2024 mediante un enfoque bayesiano de series temporales que incorpora estacionalidad, efectos de día de la semana y puntos de cambio suaves. Asimismo, se comparan retrospectivamente los resultados obtenidos con métodos clásicos de detección de cambios y se evalúan las diferencias en los patrones temporales entre la atención primaria de urgencia y los servicios de urgencia hospitalarios.

## **MATERIALES Y MÉTODOS**

El presente estudio correspondió a un análisis ecológico de series temporales utilizando datos secundarios públicos del Departamento de Estadísticas e Información de Salud (DEIS) del Ministerio de Salud de Chile. Se analizaron registros diarios de atenciones de urgencia por causas respiratorias a nivel nacional entre el 1 de enero de 2017 y el 31 de diciembre de 2024, considerando exclusivamente establecimientos del sistema público. Las atenciones se clasificaron según el nivel asistencial en la atención primaria de urgencia (APS) y en los servicios de urgencia hospitalarios. La unidad de análisis fue el número diario de atenciones agregadas a nivel nacional, por nivel asistencial.

Se incluyeron las causas respiratorias no traumáticas definidas por el DEIS según los códigos registrados en los sistemas administrativos. Los datos fueron sometidos a procesos de limpieza y estandarización que incluyeron la verificación de la continuidad temporal de

la serie diaria, la detección y eliminación de registros duplicados y la correcta agregación de los eventos a nivel diario. Se comprobó la completitud de los registros mediante la verificación de la continuidad temporal de la serie diaria entre el 1 de enero de 2017 y el 31 de diciembre de 2024, lo que confirma la presencia de observaciones para todas las fechas del período analizado. Adicionalmente, se contrastaron los totales anuales agregados de la base de datos con los reportes estadísticos publicados por el DEIS correspondientes a los mismos años, observándose concordancia en los volúmenes anuales de atenciones. Los valores iguales a cero se mantuvieron como observaciones válidas, ya que correspondieron a días sin atenciones registradas y no a registros faltantes, lo cual se verificó mediante la continuidad de la secuencia temporal y la ausencia de patrones sistemáticos de interrupción en el reporte. Dado que los datos provienen de registros administrativos agregados del sistema público, no fue posible identificar directamente eventuales episodios de subregistro; sin embargo, se evaluó la estabilidad temporal de la serie y no se observaron discontinuidades abruptas compatibles con fallas sistemáticas de reporte. Los días festivos y los fines de semana se mantuvieron en la serie, y su posible efecto sobre la demanda fue modelado explícitamente mediante variables indicadoras del día de la semana en el modelo estadístico. Posteriormente, se construyeron series temporales independientes para la atención primaria (APS) y la atención hospitalaria, con periodicidad diaria.

Como análisis descriptivo inicial, se calcularon estadísticas resumen para cada nivel asistencial (total acumulado, media diaria, mediana diaria y razón cruda de tasas [IRR] usando Hospital como referencia). Estas medidas se utilizaron únicamente con fines descriptivos.

Para la detección exploratoria de cambios estructurales en la serie nacional agregada se aplicaron tres métodos clásicos utilizados en vigilancia epidemiológica: (1) medias móviles de 14 días con detección mediante puntajes Z (umbral  $Z > 3$ ); (2) CUSUM con  $k = 0,5$  y  $h = 5$ ; y (3) segmentación mediante el algoritmo PELT implementado en la librería ruptures de Python, utilizando una función de costo cuadrática y penalización BIC.

El análisis principal se realizó mediante un modelo bayesiano de regresión para conteos con distribución binomial negativa y enlace logarítmico para modelar la sobredispersión de las atenciones diarias. El predictor incluyó un intercepto, estacionalidad anual modelada mediante una expansión de Fourier con tres armónicos (seis términos seno-coseno) y efectos fijos del día de la semana.

Formalmente:

$$Y_t \sim \text{NegBin}(\mu_t, \alpha)$$

$$\log(\mu_t) = \beta_0 + \sum_{k=1}^3 [\beta_{2k-1} \sin(2\pi kt/365) + \beta_{2k} \cos(2\pi kt/365)] + \gamma_{\text{dow}} + \delta_1 S(t, \tau_1, \kappa_1) + \delta_2 S(t, \tau_2, \kappa_2)$$

donde representa el número de atenciones respiratorias observadas en el día , corresponde a la media esperada del proceso generador de datos y representa el parámetro de dispersión de la distribución binomial negativa. El número de armónicos ( $k = 3$ ) se seleccionó mediante una comparación exploratoria de modelos, utilizando criterios de información (WAIC y LOO) y la evaluación de residuos estacionales, observándose que esta especificación capturaba adecuadamente la estacionalidad anual sin sobreparametrización. Los cambios estructurales se modelaron mediante funciones logísticas suaves:

$$S(t, \tau, \kappa) = \frac{1}{1 + \exp[-\kappa(t - \tau)]}$$

donde:

$t$ : tiempo (día en la serie temporal);  $\tau$ : punto de transición o cambio estructural;  $\kappa$ : parámetro de suavidad de la transición.

Se incorporaron dos puntos de cambio estructural definidos *a priori* a partir del contexto epidemiológico y de las medidas sanitarias implementadas en Chile durante la pandemia de COVID-19. El primer punto de cambio se fijó el 28 de marzo de 2020, correspondiente al período inicial de implementación de restricciones sanitarias y reorganización de los servicios de salud a nivel nacional. El segundo se fijó el 31 de octubre de 2021, fecha que coincide con la transición hacia una fase de mayor apertura y reorganización progresiva del sistema sanitario.

Estos puntos se utilizaron como anclas temporales comunes para los modelos estratificados por nivel asistencial, estimándose únicamente la magnitud del cambio asociado a cada transición. Con el fin de evaluar la robustez de las estimaciones del modelo frente a la localización temporal de los puntos de cambio estructural, se realizó un análisis de sensibilidad desplazando temporalmente cada punto de transición  $\pm 7$  días respecto a las fechas originalmente definidas.

Los cambios estructurales se modelaron mediante los parámetros  $\delta_1$  y  $\delta_2$  en escala logarítmica, interpretados como razones relativas de cambio tras su exponenciación. La suavidad de cada transición se controló mediante parámetros  $\kappa$ .

Se especificaron distribuciones previas débilmente informativas: intercepto Normal centrado en el logaritmo de la media observada, coeficientes de Fourier Normal (Normal (0,0.5)), efectos de día de semana Normal (Normal (0,0.3)), parámetros de cambio estructural Normal (Normal (0,1)) y los parámetros de dispersión del modelo binomial negativo se modelaron mediante una distribución Half-Normal con escala 2, mientras que los parámetros de suavidad de las transiciones logísticas se especificaron como Half-Normal (1).

La inferencia posterior se realizó mediante MCMC utilizando el algoritmo No-U-Turn Sampler (NUTS), con cuatro cadenas, 1.500 iteraciones de calentamiento y 1.500 iteraciones

de muestreo por cadena (target acceptance = 0,9). La convergencia de las cadenas se evaluó mediante el estadístico potencial de reducción de escala (), considerándose adecuada cuando , junto con el tamaño efectivo de muestra (ESS), el cual fue superior a 3000 para los principales parámetros del modelo. El análisis de autocorrelación residual mediante ACF/PACF y la prueba de Ljung–Box no evidenciaron autocorrelación significativa ( $p > 0,05$ ). La adecuación del modelo se evaluó mediante posterior predictive checks, generando 1.000 series replicadas desde la distribución predictiva posterior y comparándolas con la serie observada. Las simulaciones reprodujeron adecuadamente la media, la dispersión y la estacionalidad de los datos


Los resultados se resumieron mediante medianas posteriores e intervalos creíbles del 90% para las razones relativas de cambio asociadas a cada punto de transición. Intervalos creíbles del 90% (ICr 90%) se adoptaron para facilitar la interpretación de cambios relativos en el contexto de vigilancia epidemiológica, donde la detección de señales estructurales suele priorizar la sensibilidad analítica en lugar de la inferencia confirmatoria estricta. Todos los análisis se realizaron en Python 3.10, utilizando las librerías PyMC, NumPy, Pandas y ArviZ, en Google Colab.

### ***Consideraciones éticas***

El estudio utilizó datos administrativos agregados de acceso público provenientes del Departamento de Estadísticas e Información de Salud (DEIS) del Ministerio de Salud de Chile. Debido a que los datos están anonimizados y no contienen información identificable de los pacientes, el estudio se consideró exento de evaluación por un comité de ética.

## **RESULTADOS**

Durante el período comprendido entre el 1 de enero de 2017 y el 31 de diciembre de 2024 se registraron 33.597.638 atenciones de urgencia por causas respiratorias a nivel nacional. De estas, 24.617.474 correspondieron a la atención primaria de urgencia (APS) y 8.980.164 a los servicios de urgencia hospitalarios, lo que equivale a una media diaria aproximada de 8.424 consultas en APS y 3.073 en servicios hospitalarios, calculada a partir del total acumulado de atenciones dividido por el número total de días observados en la serie ( $n = 2.922$ ) (Figura 1).



**Figura 1.**

*Serie temporal diaria de atenciones de urgencia respiratorias en APS y Hospital, con puntos de cambio estructural definidos a nivel nacional ( $\tau_1$ ,  $\tau_2$ ).*

El análisis anual de la serie nacional evidenció una marcada variabilidad temporal en el número de consultas respiratorias (Tabla 1). Durante el período previo a la pandemia (2017–2019), el volumen anual de atenciones se mantuvo relativamente estable. En contraste, durante 2020 y 2021 se observó una reducción pronunciada en la utilización de los servicios de urgencia por causas respiratorias. Posteriormente, a partir de 2022, se evidenció una recuperación progresiva de la demanda asistencial, con niveles anuales cercanos o superiores a los observados en el período prepandémico.

**Tabla 1.**

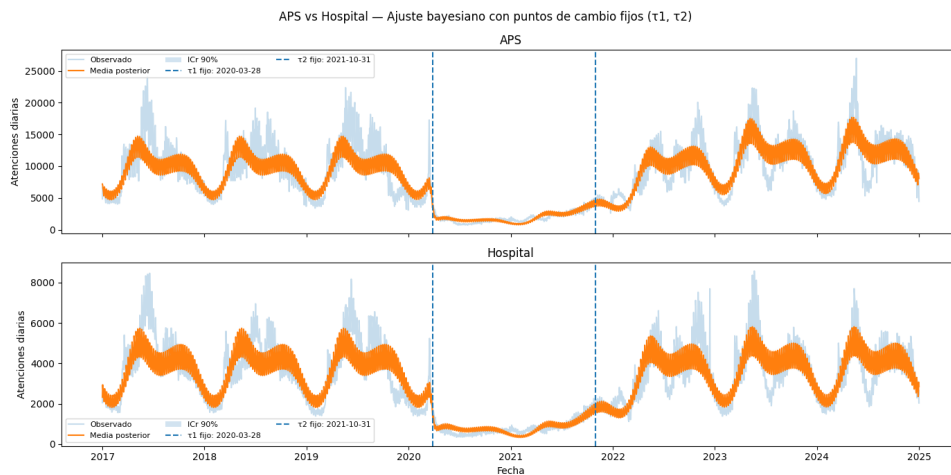
*Estadísticos descriptivos anuales de las atenciones de urgencia respiratorias a nivel nacional, incluyendo medidas de tendencia central, dispersión y rangos extremos (2017–2024).*

Año	Días	Total atenciones	Media diaria	Mediana diaria	p25	p75	Mín.	Máx.
2017	365	5.133.880	14.065,4	3.810	1.458	6.915	382	21.555
2018	365	4.939.422	13.532,7	3.683	1.958	6.180	673	15.770
2019	365	5.007.981	13.720,5	3.532	2.102	5.813,5	682	18.380
2020	366	1.223.447	3.342,8	418,5	100,8	827	0	12.520
2021	365	1.381.568	3.785,1	656	144	1.193	3	3.160
2022	365	4.812.171	13.184,0	2.285	550	4.100	1	12.862
2023	365	5.557.541	15.226,1	2.599	812	4.618	0	13.364
2024	366	5.541.628	15.141,1	3.323,5	1.467	4.777,25	0	16.138

En el análisis global del período completo, la atención primaria de urgencia concentró la mayor proporción del volumen total de consultas respiratorias, con una media diaria superior a la observada en los servicios hospitalarios.

El modelo bayesiano aplicado a la serie nacional agregada se especificó incorporando dos puntos de cambio estructural definidos a priori a partir de hitos epidemiológicos relevantes del período pandémico en Chile. El primero se fijó el 28 de marzo de 2020, correspondiente al período inicial de implementación de restricciones sanitarias y reorganización del sistema de salud, mientras que el segundo se fijó el 31 de octubre de 2021, asociado a la fase de reapertura progresiva y reorganización de la atención sanitaria. Estas fechas fueron utilizadas como referencias temporales comunes para los modelos estratificados por nivel asistencial.

En el modelo correspondiente a APS, el primer punto de cambio se asoció con una reducción marcada en el nivel esperado de consultas, equivalente a una disminución aproximada del 87% respecto al régimen previo del modelo. La razón multiplicativa estimada fue inferior a la unidad y su intervalo creíble del 90% se mantuvo por completo por debajo de dicho valor. Para el segundo punto de cambio, la razón multiplicativa estimada fue superior a la unidad, lo que indica un incremento relativo en el nivel esperado de consultas en el régimen posterior del modelo (Figura 2). Un patrón similar se observó en el modelo hospitalario, con estimaciones consistentes en ambos puntos de transición (Tabla 2).



**Figura 2.**

*Modelo bayesiano binomial negativa con estacionalidad anual, efectos de día de la semana y puntos de cambio estructurales fijos ( $\tau_1$ ,  $\tau_2$ ), ajustado separadamente para APS y Hospital.*

*Fuente: elaboración propia.*

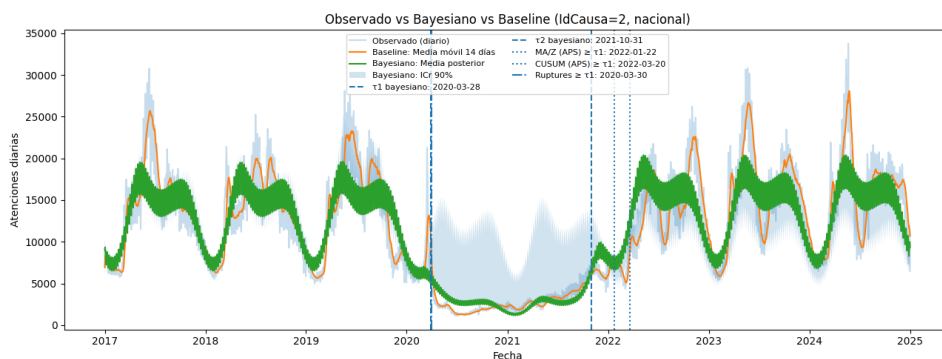
**Tabla 2.**

*Estimaciones posteriores de los efectos multiplicativos asociados a los puntos de cambio estructural fijos ( $\exp(\delta_1)$ ,  $\exp(\delta_2)$ ) y sus intervalos creíbles al 90%, estratificadas por nivel asistencial.*

Grupo	$\exp(\delta_1)$	ICr 90%	$\exp(\delta_2)$	ICr 90%
APS	0.138	0.134-0.142	8.683	8.373-9.001
Hospital	0.176	0.171-0.18	5.758	5.593-5.925

El análisis de sensibilidad mostró estimaciones prácticamente invariantes de los efectos multiplicativos asociados a los puntos de cambio estructural. En el modelo correspondiente a APS, el parámetro  $\exp(\delta_1)$  se mantuvo entre 0.134 y 0.142, y el parámetro  $\exp(\delta_2)$  entre 8.52 y 8.81, al desplazar las fechas  $\pm 7$  días. En el modelo hospitalario, las estimaciones correspondientes oscilaron entre 0.172 y 0.180 para  $\exp(\delta_1)$  y entre 5.63 y 5.89 para  $\exp(\delta_2)$ . Estos resultados sugieren una adecuada robustez del modelo frente a pequeñas variaciones en la localización temporal de las transiciones estructurales.

En la comparación de métodos de detección de cambios estructurales aplicados a la serie nacional agregada, el punto de cambio de referencia se fijó el 28 de marzo de 2020, a partir de hitos epidemiológicos relevantes del inicio de la pandemia en Chile y de acuerdo con la especificación del modelo bayesiano. El método de segmentación determinista implementado mediante *ruptures* detectó un cambio el 30 de marzo de 2020, con un retraso de dos días respecto al punto de referencia. En contraste, los métodos basados en media móvil con umbral  $Z > 3$  y CUSUM identificaron cambios considerablemente más tardíos, el 22 de enero de 2022 y el 20 de marzo de 2022, respectivamente, con retrasos de 665 y 722 días (Figura 3; Tabla 3).

**Figura 3.**

*Comparación entre el modelamiento bayesiano y métodos baseline (media móvil, CUSUM y segmentación determinista) para la detección de cambios estructurales en la serie nacional de atenciones de urgencia respiratorias.*

**Tabla 3.**

*Comparación de la latencia en la detección del primer cambio estructural ( $\tau_1$ ) entre el modelo bayesiano y métodos baseline, expresada como días de retraso respecto al punto de cambio de referencia.*

<b>Método</b>	<b>Fecha detección</b>	<b>Días de retraso vs <math>\tau_1</math></b>
Media móvil ( $Z>3$ )	2022-01-22	665
CUSUM	2022-03-20	722
Ruptures	2020-03-30	2
Bayesiano ( $\tau_1$ )	2020-03-28	0

Las representaciones gráficas ilustraron la evolución temporal diaria de las atenciones respiratorias por tipo de establecimiento, la distribución de consultas entre APS y Hospital, así como el ajuste del modelo bayesiano con puntos de cambio estructurales fijos. Estas figuras muestran las medias posteriores estimadas y sus intervalos creíbles al 90 %, junto con la localización temporal de los puntos de transición definidos para ambos niveles asistenciales.

## DISCUSIÓN

El presente análisis documenta una reconfiguración marcada en la demanda de atenciones de urgencia respiratorias en Chile entre 2017 y 2024, caracterizada por dos cambios estructurales claramente diferenciados en la dinámica temporal de la serie, correspondientes al inicio del período pandémico y a la fase posterior de reorganización del sistema sanitario. Desde una perspectiva temporal, la identificación de estos puntos de transición mediante un enfoque bayesiano permitió delimitar regímenes diferenciados de uso de servicios, separando patrones estacionales recurrentes de alteraciones estructurales persistentes en la demanda. Este comportamiento es consistente con observaciones realizadas en distintos sistemas de salud durante crisis sanitarias previas, en las que se ha descrito que eventos epidémicos pueden inducir quiebres abruptos en la utilización de los servicios de urgencia, más allá de la variabilidad estacional esperable [7,11].

La reducción abrupta de las consultas de urgencia durante la fase inicial de la pandemia de COVID-19 ha sido ampliamente documentada en diversos contextos internacionales. En Estados Unidos, análisis multicéntricos mostraron disminuciones sustanciales en las visitas a servicios de urgencia durante marzo y abril de 2020, seguidas de recuperaciones parciales en períodos posteriores [1,12]. Hallazgos concordantes han sido reportados en Europa, donde se observaron descensos pronunciados en las atenciones de urgencia, tanto

por causas infecciosas como no infecciosas, durante los períodos de confinamiento [13,14]. De manera similar, estudios en América Latina describieron reducciones abruptas en la utilización de servicios de urgencia durante la primera ola pandémica, con heterogeneidad según el contexto sanitario y la fase epidémica [15]. Este fenómeno también ha sido documentado en poblaciones pediátricas, particularmente en consultas respiratorias, y se atribuye a la disminución de la circulación viral y a cambios en el comportamiento de búsqueda de atención de los cuidadores [16,17]. Estos hallazgos refuerzan la noción de que la contracción inicial de la demanda por urgencias respiratorias constituyó un patrón transversal. La magnitud del cambio estructural estimado para APS en el presente estudio ( $\exp(\delta_1) = 0,138$ ), equivalente a una reducción aproximada del 87% en el nivel esperado de consultas, se sitúa en el extremo superior de las disminuciones reportadas internacionalmente durante los primeros meses de la pandemia. Por ejemplo, un análisis multicéntrico realizado en cinco estados de Estados Unidos reportó reducciones en las visitas a servicios de urgencia entre 41% y 63% durante marzo–abril de 2020, mientras que análisis nacionales del sistema de vigilancia estadounidense documentaron descensos cercanos al 42% en el volumen total de consultas en el mismo período [1,2]. Estas diferencias sugieren que la contracción observada en APS en Chile podría reflejar una combinación de restricciones sanitarias tempranas, cambios en el comportamiento de consulta de la población y una reducción transitoria en la circulación de virus respiratorios distintos a SARS-CoV-2 durante la fase inicial de la pandemia. En este contexto, los resultados del presente estudio permiten explorar cómo estas dinámicas se manifestaron dentro de los distintos niveles asistenciales del sistema sanitario chileno. En este estudio, la comparación entre APS y Hospital sugiere que los niveles asistenciales no operaron como réplicas de un mismo fenómeno, sino como componentes con dinámicas diferenciadas frente a un shock sistémico común. APS concentró la mayor proporción del volumen total de consultas respiratorias observadas en la serie, lo cual es consistente con su rol como puerta de entrada al sistema y primer nivel de resolución de síntomas respiratorios agudos. No obstante, la mayor variabilidad observada en la distribución diaria de consultas en APS sugiere una mayor sensibilidad a cambios abruptos en el comportamiento de consulta de la población y a reorientaciones de los flujos asistenciales, fenómeno descrito previamente en sistemas de salud con un fuerte componente de atención primaria [18,19]. En contraste, los servicios hospitalarios mostraron una distribución diaria relativamente más estable, compatible con la atención de cuadros clínicos de mayor severidad que mantienen una demanda basal incluso durante períodos de restricción o alta percepción de riesgo sanitario, patrón descrito previamente como “selección por severidad” durante emergencias sanitarias [20,21].

La caracterización del período posterior al primer quiebre pandémico, correspondiente al segundo punto de cambio identificado en el modelo, es coherente con reportes que describen fases de recuperación o de reacomodo en la utilización de los servicios de urgencia tras los períodos iniciales de restricciones. Estudios recientes han señalado que los años

posteriores al inicio de la pandemia se asociaron a un panorama respiratorio complejo, con reemergencia de virus respiratorios estacionales, temporadas intensas y cambios en la edad y severidad de los casos atendidos [22,23]. En este contexto, los cambios estructurales observados pueden interpretarse como transiciones entre regímenes de utilización de urgencias más que como simples fluctuaciones estacionales, lo que refuerza la necesidad de métodos analíticos capaces de distinguir entre variabilidad esperable y alteraciones persistentes del sistema [24,25].

Desde el punto de vista metodológico, uno de los hallazgos más relevantes es la divergencia observada entre los métodos clásicos de detección de cambios y el enfoque bayesiano al identificar transiciones estructurales en la serie. En series de conteo diario caracterizadas por alta estacionalidad, sobredispersión y heterocedasticidad, los métodos basados en medias móviles o umbrales  $Z$  tienden a comportarse como detectores de extremos locales más que como identificadores de cambios de régimen sostenidos [26]. De manera similar, los enfoques basados en CUSUM asumen implícitamente una referencia estable y varianza constante, supuestos que rara vez se cumplen en datos de demanda asistencial durante crisis sanitarias prolongadas [27]. Dado que los puntos de cambio utilizados en los modelos estratificados fueron definidos a priori con base en eventos epidemiológicos relevantes, la comparación entre métodos debe interpretarse como una evaluación retrospectiva del desempeño relativo de los distintos enfoques analíticos de detección de cambios en un mismo marco temporal.

En contraste, los modelos bayesianos de series temporales con puntos de cambio permiten integrar explícitamente la estacionalidad, los efectos sistemáticos y los mecanismos probabilísticos de transición, ofreciendo una representación más realista de la dinámica de la demanda asistencial. La literatura metodológica ha destacado de forma consistente la utilidad de estos enfoques para la vigilancia epidemiológica, particularmente en contextos donde los cambios son graduales, heterogéneos y acompañados de elevada incertidumbre [6,27–29]. Asimismo, la comparación con métodos de segmentación determinista sugiere que, si bien estos pueden aproximar retrospectivamente la localización de rupturas, su dependencia de información futura limita su aplicabilidad directa para sistemas de vigilancia con requerimientos de baja latencia [30].

En conjunto, los resultados de este estudio describen una reconfiguración estructural en la demanda de urgencias respiratorias en Chile durante el período pandémico y post-pandémico, con diferencias relevantes entre niveles asistenciales. La coherencia de estos patrones con la evidencia internacional respalda la plausibilidad externa de los hallazgos. Desde una perspectiva metodológica, el uso de modelos bayesianos de series temporales permitió integrar la estacionalidad, la sobredispersión y las transiciones estructurales en un marco probabilístico coherente, lo que posiciona este enfoque como una herramienta robusta para la vigilancia de la demanda asistencial en contextos caracterizados por alta variabilidad y cambios de régimen. La magnitud de los efectos multiplicativos asociados a

los puntos de cambio debe interpretarse como una transición entre regímenes temporales del modelo, más que como un incremento instantáneo en el volumen absoluto de consultas.

### ***Limitaciones***

Este estudio presenta algunas limitaciones. En primer lugar, el diseño ecológico del estudio implica un riesgo de falacia ecológica y no permite establecer relaciones causales directas entre los cambios observados y los factores específicos del contexto sanitario. Asimismo, la ausencia de información a nivel individual impide controlar posibles variables de confusión no observadas. En segundo lugar, los datos corresponden a registros administrativos agregados del sistema público, los cuales pueden estar sujetos a variaciones en los procesos de registro y no permiten capturar las heterogeneidades regionales. Finalmente, como en todo modelo bayesiano, los resultados pueden verse influidos por la especificación del modelo y por las distribuciones previas, aunque se utilizaron priors débilmente informativos y se realizaron diagnósticos de ajuste.

### ***Conflictos de intereses y financiación***

Los autores declaran que no tienen ningún conflicto de intereses relacionado con este estudio. Todos los datos y resultados presentados en esta investigación son originales y no han sido influenciados por intereses financieros, comerciales o personales. Este estudio ha sido llevado a cabo de manera independiente y con total integridad científica.

### ***Disponibilidad de datos***

El conjunto de datos utilizado en este estudio corresponde a registros administrativos de acceso público disponibles a través del Departamento de Estadísticas e Información de Salud (DEIS) del Ministerio de Salud de Chile.

El código analítico empleado para el procesamiento de los datos y el modelamiento bayesiano se encuentra disponible en un repositorio público en:

<https://github.com/comincinieric56-maker/respiratory-ed-demand-chile>

## **REFERENCIAS BIBLIOGRÁFICAS**

1. Hartnett KP, Kite-Powell A, DeVies J, Coletta MA, Boehmer TK, Adjemian J, et al. Impact of the COVID-19 Pandemic on Emergency Department Visits - United States, January 1, 2019-May 30, 2020. *MMWR Morb Mortal Wkly Rep.* 2020 Jun 12;69(23):699–704. doi:10.15585/mmwr.mm6923e1 PubMed PMID: 32525856.

2. Jeffery MM, D'Onofrio G, Paek H, Platts-Mills TF, Soares WE, Hoppe JA, et al. Trends in Emergency Department Visits and Hospital Admissions in Health Care Systems in 5 States in the First Months of the COVID-19 Pandemic in the US. *JAMA Intern Med.* 2020 Oct 1;180(10):1328–33. doi:10.1001/jamainternmed.2020.3288 PubMed PMID: 32744612.
3. Moon J, Choi YY, Min HS, Sung HK, Lee KS. Time-series evaluation of an ED-based syndromic alarm system before and during the COVID-19 pandemic. *J Infect Public Health.* 2026 Mar 1;19(3):103149. doi:10.1016/j.jiph.2026.103149
4. Schranz M. Syndromic surveillance using emergency department data for the monitoring of unspecific acute gastrointestinal infections. Dissertation. Berlin: Robert Koch Institute; 2019. doi:10.25646/9364
5. Jones SS, Thomas A, Evans RS, Welch SJ, Haug PJ, Snow GL. Forecasting daily patient volumes in the emergency department. *Acad Emerg Med.* 2008 Feb;15(2):159–70. doi:10.1111/j.1553-2712.2007.00032.x PubMed PMID: 18275446.
6. Adeoye M, Didelot X, Spencer SEF. Bayesian spatio-temporal modelling for infectious disease outbreak detection. *Epidemics.* 2026 Mar 1;54:100879. doi:10.1016/j.epidem.2025.100879 PubMed PMID: 41418592.
7. Brookmeyer R, Stroup DF. Monitoring the health of populations: statistical principles and methods for public health surveillance. New York: Oxford University Press; 2003. p. 1–32.
8. Cárdenas CM, Sovier CV, Pérez U, González S. Consultas de urgencia general y por causa respiratoria en la red de establecimientos del Sistema Nacional de Servicios de Salud (SNSS): un modelo predictivo en el Servicio de Salud de Chiloé. *Rev Chil Enferm Respir.* 2014;30:133-141.
9. Toro L, Parra A, Alvo M. COVID-19 epidemic in Chile: Impact on emergency services care and specific pathologies. *Rev Med Chil.* 2020 Apr 1;148(4):558–60. doi:10.4067/s0034-98872020000400558 PubMed PMID: 32730468.
10. Tinoco YO, Osman TS, Ampuero JS, Gazo M, Ocaña V, Chávez E, et al. Respiratory Disease Surveillance in the Middle East and Latin America during the COVID-19 Pandemic, 2020-2022. *Emerg Infect Dis.* 2024 Nov 1;30(14):S26–32. doi:10.3201/eid3014.240303 PubMed PMID: 39530856.
11. Viboud C, Børnstad ON, Smith DL, Simonsen L, Miller MA, Grenfell BT. Synchrony, waves, and spatial hierarchies in the spread of influenza. *Science.* 2006 Apr 21;312(5772):447–51. doi:10.1126/science.1125237 PubMed PMID: 16574822.
12. Daoud A, Ronen O. Decline in emergency department visits during the COVID-19 quarantine. *Am J Emerg Med.* 2023 Sep 1;71:74. doi:10.1016/j.ajem.2023.06.002 PubMed PMID: 37352578.

13. Thornton J. Covid-19: A&E visits in England fall by 25% in week after lockdown. *BMJ*. 2020 Apr 6;369:m1401. doi:10.1136/bmj.m1401 PubMed PMID: 32253175.
14. Fanourgiakis J, Papadakis E, Dimotikalis I, Papadakis E, Kanoupakis E. The effect of COVID-19 on emergency department visits: Real-world data from Greece, 2016-2024. *The European Journal of Public Health*. 2025 Nov 1;35(Suppl 5):ckaf165.125. doi:10.1093/eurpub/ckaf165.125
15. Knudsen SV, Jensen H, Mainz J, Baandrup L, Gögenur I, Jensen JW, et al. Indirect effects of the COVID-19 pandemic on healthcare contacts, quality of care, and social disparities across essential healthcare domains. *Int J Qual Health Care*. 2025;37(1). doi:10.1093/intqhc/mzaf013 PubMed PMID: 39936327.
16. Isba R, Edge R, Jenner R, Broughton E, Francis N, Butler J. Where have all the children gone? Decreases in paediatric emergency department attendances at the start of the COVID-19 pandemic of 2020. *Arch Dis Child*. 2020 Jul 1;105(7):704. doi:10.1136/archdischild-2020-319385 PubMed PMID: 32376695.
17. de Jorna C, Liber M, Khalifi S El, Neggia G, Martinot A, Dubos F. Changes in pediatric emergency department visits during a COVID-19 lockdown period: An exhaustive single-center analysis: Impact of the 2020 lockdown on admissions to a pediatric emergency department. *Archives de Pediatrie*. 2022 Nov 1;29(8):604–9. doi:10.1016/j.arcped.2022.08.003 PubMed PMID: 36167618.
18. Starfield B. Primary Care: Balancing Health Needs, Services, and Technology [Internet]. 1998 Oct 29. doi:10.1093/oso/9780195125429.001.0001
19. Kringos D, Boerma W, Bourgueil Y, Cartier T, Dedeu T, Hasvold T, et al. The strength of primary care in Europe: an international comparative study. *Br J Gen Pract*. 2013 Nov;63(616). doi:10.3399/bjgp13x674422 PubMed PMID: 24267857.
20. Mantica G, Riccardi N, Terrone C, Gratarola A. Non-COVID-19 visits to emergency departments during the pandemic: the impact of fear. *Public Health*. 2020 Jun 1;183:40. doi:10.1016/j.puhe.2020.04.046 PubMed PMID: 32417567.
21. Sartini M, Carbone A, Demartini A, Giribone L, Oliva M, Spagnolo AM, et al. Overcrowding in Emergency Department: Causes, Consequences, and Solutions—A Narrative Review. *Healthcare*. 2022 Sep 1;10(9):1625. doi:10.3390/healthcare10091625 PubMed PMID: 36141237.
22. Liu P, Xu M, Cao L, Su L, Lu L, Dong N, et al. Impact of COVID-19 pandemic on the prevalence of respiratory viruses in children with lower respiratory tract infections in China. *Viol J*. 2021 Dec 1;18(1):159. doi:10.1186/s12985-021-01627-8 PubMed PMID: 34344406.
23. Olsen SJ, Azziz-Baumgartner E, Budd AP, Brammer L, Sullivan S, Pineda RF, et al. Decreased influenza activity during the COVID-19 pandemic—United States,

- Australia, Chile, and South Africa, 2020. *American Journal of Transplantation*. 2022 Dec 1;20(12):3681. doi:10.1111/ajt.16381 PubMed PMID: 33264506.
24. Hyndman RJ, Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd ed. Melbourne: OTexts; 2021. <https://otexts.com/fpp3/>
  25. West M, Harrison J. *Bayesian Forecasting and Dynamic Models*. 2nd ed. New York: Springer; 1997.
  26. Montgomery DC. *Introduction to statistical quality control*. 8th ed. Hoboken (NJ): John Wiley & Sons; 2020. p. 5.
  27. Hawkins DM, Olwell DH. *Cumulative Sum Charts and Charting for Quality Improvement*. Cumulative Sum Charts and Charting for Quality Improvement. 1998. doi:10.1007/978-1-4612-1686-5
  28. MacNab YC. Bayesian disease mapping: Past, present, and future. *Spat Stat*. 2022 Aug 1;50:100593. doi:10.1016/j.spasta.2022.100593 PubMed PMID: 35075407.
  29. Van de Schoot R, Kaplan D, Denissen J, Asendorpf JB, Neyer FJ, van Aken MAG. A Gentle Introduction to Bayesian Analysis: Applications to Developmental Research. *Child Dev*. 2014;85(3):842–60. doi:10.1111/cdev.12169 PubMed PMID: 24116396.
  30. Horváth L, Rice G. *Change Point Analysis for Time Series* [Internet]. 2024;Springer Series in Statistics. doi:10.1007/978-3-031-51609-2

Recibido: 28/01/2026

Aceptado: 12/03/2026

### ***Contribuciones de autoría***

Por la presente sometemos a consideración el manuscrito titulado “Detección temprana de cambios estructurales en la demanda de urgencias respiratorias mediante modelamiento bayesiano: evidencia nacional de Chile (2017–2024)” como artículo de investigación original en su revista.

**Eric Comincini Cantillo:** contribuyó a la conceptualización del estudio, curación de los datos, análisis formal, investigación, metodología, desarrollo de software, validación, visualización, administración del proyecto y redacción del borrador original del manuscrito.

**Jorge Homero Wilches Visbal:** contribuyó a la supervisión del estudio y a la revisión crítica y edición del manuscrito.

Todos los autores revisaron y aprobaron la versión final del manuscrito y aceptan asumir responsabilidad por todos los aspectos del trabajo.

### ***Declaración de conflictos de intereses***

Los autores declaran que no existen conflictos de intereses financieros, personales, profesionales o institucionales que puedan haber influido de manera inapropiada en la realización, análisis o interpretación de los resultados presentados en este estudio. Asimismo, los autores confirman que la investigación se llevó a cabo con independencia científica y que ninguna entidad externa tuvo participación en el diseño del estudio, la recopilación de datos, el análisis de la información, la interpretación de los resultados ni en la decisión de someter el manuscrito para su publicación.