

Modelo predictivo de la cantidad de pacientes que consultan al servicio de urgencia de un hospital universitario en Santiago de Chile

Luis Herrada Herrada^{1,*}, Francisco Espinoza Villegas¹, Raúl Vega Mondaca^{1,a}, Pedro Doren Carrasco^{2,b}.

Predictive Model for the Number of Patients Presenting to the Emergency Department of a University Hospital in Santiago, Chile

RESUMEN

La saturación de los servicios de urgencia es un desafío crítico a nivel global, afectando la calidad y oportunidad de la atención médica. Chile no es ajeno a este problema: Durante 2024 se registraron 18 millones de consultas en los dispositivos de urgencia del sistema público, lo que refleja una alta demanda que dificulta la planificación y distribución eficiente de los recursos. **Objetivo:** Desarrollar un modelo predictivo capaz de estimar con alta precisión el número de consultas semanales en el servicio de urgencia de un hospital universitario privado en Santiago de Chile. Se definió que el modelo tendría impacto en la gestión si lograba predecir con 14 días de anticipación y un margen de error inferior al 5%. **Metodología:** Se construyó un modelo de regresión utilizando aprendizaje supervisado con series temporales. La metodología se basó en el enfoque Knowledge Discovery in Databases (KDD), empleando datos históricos del año 2024. Se seleccionaron variables relevantes para entrenar y validar el modelo, enfocándose en la precisión para estimar el volumen semanal de consultas. **Resultados:** El modelo logró predecir el volumen semanal de consultas con 14 días de anticipación, alcanzando un error promedio del 3,3%. Esto representa una mejora significativa respecto a métodos tradicionales basados en promedios históricos, permitiendo una mejor anticipación de la demanda asistencial y un mayor impacto en la gestión de los recursos. **Conclusiones:** Es posible predecir la demanda semanal en servicios de urgencia con un margen de error inferior al 5% mediante modelos predictivos basados en aprendizaje supervisado. Esta herra-

¹Clínica Universidad de Los Andes, Santiago, Chile.

²Programa Especialidad Medicina de Urgencia, Universidad de Los Andes, Santiago, Chile.

^aIngeniero en Informática.

^bBecario Medicina de Urgencia.

*Correspondencia: Luis Herrada Herrada / lherrada@clinicauandes.cl
Av Plaza 2501, Las Condes, Región Metropolitana

Financiamiento: Este trabajo no contó con apoyo financiero de ningún tipo.

Conflicto de interés: Los autores declaran no tener conflictos de interés.

Recibido: 22 de julio de 2025.
Aceptado: 21 de marzo de 2026.

mienta puede contribuir significativamente a la mejora de la gestión interna y la planificación estratégica en hospitales universitarios y otros centros de atención de urgencia del país.

Palabra clave: Aprendizaje automático; Gestión en salud; Medicina de urgencias; Planificación en salud; Servicio de urgencia en hospital.

ABSTRACT

Emergency department (ED) overcrowding is a critical global challenge, affecting the quality and timeliness of medical care. Chile is no exception: In 2024, over 18 million ED visits were recorded in the public health system, reflecting high demand and complicating efficient resource planning and allocation. **Aim:** To develop a predictive model capable of accurately estimating the weekly number of consultations in the emergency department of a private university hospital in Santiago, Chile. The model was expected to generate a management impact if it could predict ED visits 14 days in advance with a margin of error below 5%. **Methods:** A regression model was developed using supervised machine learning based on time series data. The methodology followed the Knowledge Discovery in Databases (KDD) process, utilizing historical data from 2024. Relevant variables were selected to train and validate the model, with a focus on accurately forecasting weekly consultation volume. **Results:** The model successfully predicted the number of weekly ED consultations 14 days in advance, achieving an average error rate of 3.3%. This represents a significant improvement over traditional methods based on historical averages and enables better anticipation of patient demand and improved resource management. **Conclusions:** Weekly ED demand can be accurately predicted with a margin of error below 5% using supervised learning-based predictive models. This type of tool can contribute significantly to improving internal management and strategic planning in university hospitals and other emergency care centers across the country.

Keywords: Emergency medicine; Emergency service, hospital; Health management; Health planning; Machine learning.

Los servicios de urgencia poseen características inherentes al tipo de pacientes que atienden, que pueden influir de forma importante en el pronóstico de enfermedades tiempo dependientes, como son los largos tiempos de espera y la alta carga asistencial, que muchas veces no permite dedicar todo el tiempo necesario en la atención individual de cada paciente¹. Las atenciones de urgencia en Chile fueron aproximadamente 18 millones el año en el 2024².

El fenómeno de “urgencias llenas o atochadas o colapsadas” es denominado en la literatura médica como *overcrowding*. El Colegio Americano de Médicos de Urgencia (*American College of Emergency Physicians*) lo define como “un fenómeno que existe cuando los recursos institucionales disponibles son insuficientes para satisfacer las necesidades de servicios básicos de los pacientes de emergencia”³. esto se manifiesta en situaciones como, pacientes que están siendo tratados en los pasillos, la imposibilidad de recibir un paciente que ingresa en ambulancia, pacientes hospitalizados en los servicios de emergencia por falta de camas de hospitalización y atenciones a los pacientes que no cumplen con las normas de calidad básicas.

Es evidente que la problemática de *overcrowding* es multifactorial, por lo que el autor Asplin en el 2003 presentó un modelo conceptual del *overcrowding* en los servicios de urgencia, que inicia una corriente de análisis de la problemática a nivel mundial⁴ en este modelo el autor establece los conceptos input, troughput y output, que utilizamos hasta el día de hoy modelos conceptuales de gestión de urgencia, el input conceptualmente son aquellos hechos que motivan ingreso de pacientes al servicio de urgencia, por ejemplo ingreso de ambulancias, derivación desde centro de menor a mayor complejidad, derivación de consultas, pacientes que ingresan de manera espontánea entre otros.

Existen complejidades mayores para pronosticar la demanda de las consultas a los dispositivos de urgencia, en general por el tipo de serie de datos que se obtienen y su distribución de poisson.

Este estudio no pretende resolver o asociar causalmente el *overcrowding* con la predicción

arribo de pacientes a los servicios de urgencia, pero si busca colaborar con una medida más exacta para que los gestores puedan adecuar la oferta de servicios a los niveles de demanda, este desbalance se observa año a año en periodos de alta demanda de consulta como la época de invierno. Dado que los recursos en salud son limitados, es vital una planificación eficiente, una herramienta que podría contribuir a esta planificación es tener un modelo de predicción de la demanda por atenciones de urgencia a nivel nacional. En general, en Chile se utiliza el promedio histórico de consultas diarias al servicio de urgencia para asignar los recursos humanos (número de médicos, enfermeras, paramédicos y auxiliares) realizando esto en programaciones anuales y que son estáticas en el tiempo.

En este contexto, los modelos predictivos aparecen como herramientas prometedoras para mejorar la gestión de los SU. Específicamente, los modelos predictivos basados en IA se han utilizado para predecir las consultas al SU, utilizando variables como datos históricos de pacientes, información meteorológica, días festivos y datos de calendario. Estudios recientes han explorado el uso de datos no tradicionales, como el índice de búsqueda en internet, para mejorar la precisión de las predicciones, capturando información en tiempo real sobre el comportamiento de los pacientes, temas aun en estudio^{4,5}.

Nuestro objetivo fue pronosticar con la mayor precisión posible el número de pacientes que acudirían semanalmente al servicio de urgencia de un hospital universitario en Santiago de Chile durante el año 2024. Se consideró que el modelo generaría un impacto en la gestión del recurso humano y otros recursos del servicio de nuestra urgencia cuando el modelo permitiera establecer con 14 días de anticipación el número de pacientes semanales con un error menor al 5%.

Metodología

Para cumplir el objetivo propuesto, se desarrolló un modelo de regresión con aprendizaje supervisado, dado que la finalidad era predecir una variable en el tiempo se utilizaron series de pronóstico de tiempo (forecast), puesto que no

conocíamos ninguna de las variables en el futuro.

Utilizamos la metodología KDD (Knowledge Discovery in Databases), para generar un resultado pronostico del número de atenciones en el servicio de urgencia. Este diseño contempló cinco etapas:

Recopilación y Preparación de Datos

Como hipótesis, y al tomar como referencia algunos estudios realizados en otros países^{6,7,8,9,10} y la opinión de expertos, se tomaron las siguientes variables en consideración (Tabla 1).

Selección de características

Para definir las variables a usar en el modelo se optó por medir la correlación entre las distintas variables independientes versus la demanda de atenciones del servicio de urgencia de Clínica Universidad de Los Andes (CUANDES).

Al realizar este ejercicio se dejaron fuera 2 variables por baja correlación (Humedad relativa del aire y Calidad del aire, el corte para considerar las variables como correlacionadas con la cantidad de consultas al SU fue de { -1 a -0,5 } y de { 0,5 a 1 }.

Diseño del modelo

El problema fue abordado utilizando modelos univariados y algoritmos de machine learning.

En el caso de los modelos univariados se definieron los modelos ARiMa y Prophet y para el caso de los algoritmos de machine learning se definieron los modelos Linear Regression, Random Forest, Support Vector Regression y Neural Network.

Las variables finalmente utilizadas están indicadas en la figura 1.

A partir de estas 3 variables principales se crean 270 variables con distintos rezagos de las variables anteriores más la variable dependiente, esto con la finalidad de traspasar información relacionada a la tendencia y estacionalidad al modelo, este conjunto de datos fue utilizado para el entrenamiento y testeo de los modelos.

Entrenamiento y testeo del modelo

Se entrenaron 6 modelos en total; 2 univariados y 4 algoritmos de machine learning los cuales fueron mencionados en el punto 3. Para el entrenamiento se usaron los datos correspon-

Tabla 1. Variables propuestas para ser utilizadas y el origen de los datos.

Variable	Origen de dato
Temperatura máxima	Dirección meteorológica de Chile
Humedad relativa del aire	Dirección meteorológica de Chile
Calidad del aire (MP 10)	Ministerio del Medio Ambiente
Atenciones respiratorias SSMO	Ministerio de Salud (DEIS)
%Positividad Influenza (EEUU) (21 semanas desfase +correlación)	Centros para el Control y Prevención de Enfermedades (CDC)
Demanda de atenciones urgencia CUANDES	BBDD propia
%Atenciones respiratorias de urgencia CUANDES	BBDD propia
Cantidad de atenciones urgencia CUANDES (año anterior)	BBDD propia

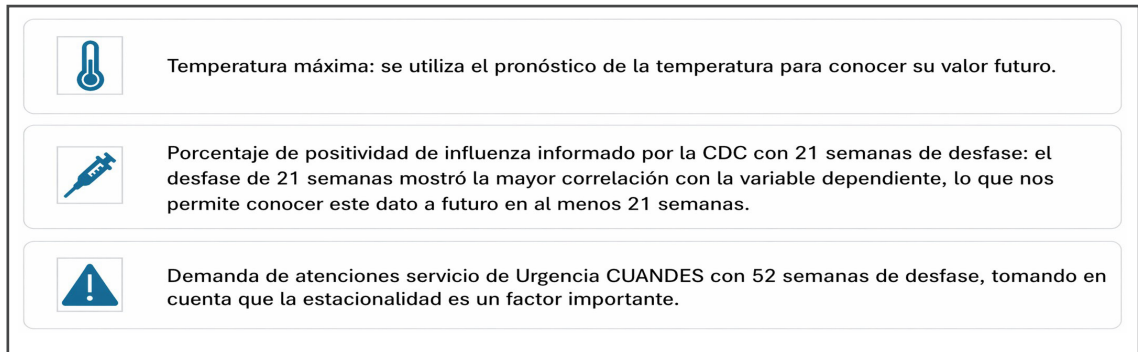


Figura 1: Variables utilizadas y sus definiciones.

dientes al periodo del 01-01-2022 al 30-06-2023 y para el testeo se consideró el periodo entre el 01-07-2023 y el 31-12-2023. El modelo que obtuvo la mejor performance en base al RMSE (raíz del error cuadrático medio) fue el SVR (support vector regression).

Generación de pronósticos

La generación de pronósticos se realizó entrenando el modelo con todos los datos disponibles hasta el día i (siendo i = el día actual), luego se genera el pronóstico para el día $i + 1$, para luego volver a entrenar el modelo incluyendo el pronóstico para el día $i + 1$ con la finalidad de crear el pronóstico para $i + 2$. Esta operación continua en bucle hasta el pronóstico $i + n$, siendo n la cantidad deseada de días a pronosticar. Posteriormente se agrupan los datos por semana epidemiológica y son publicados en el reporte de pronóstico de atenciones de urgencia. El modelo se actualiza semanalmente, donde se agregan los datos reales de los últimos 7 días y se vuelve a ejecutar el proceso en bucle descrito en el párrafo anterior.

Resultados

El modelo SVR (support vector regression) entrenado con las variables propuestas logró pronosticar con 14 días de anticipación la cantidad de pacientes semanales que consultarían al servicio de urgencia de un hospital privado en Santiago de Chile con una diferencia promedio de 3,3% semanal, donde la mejor predicción la realizó para la semana epidemiológica número 20 con

una diferencia entre la predicción y la realidad de 1 paciente (0,1%) y la peor predicción la realizó para la semana epidemiológica número 16 con una diferencia de 91 pacientes (11,8%). También se puede observar que el modelo nunca predijo menos pacientes que el mismo periodo de año anterior y que de las 52 semanas epidemiológicas del año 2024 solamente en 8 el modelo predijo por sobre un 5% de pacientes (Tabla 2).

En relación con la estacionalidad de las consultas de urgencia durante el año 2024, desarrollamos una gráfica de actualización semanal (Figura 2) que nos permite establecer momentos de inicio y final de periodos de alta demanda, establecimos un umbral de 800 pacientes semanales, ya que, cuando las consultas superan ese número, el indicador de tiempo puerta medico sobrepasa los 25 minutos promedio, valor fijado como meta de atención en nuestro centro. En la figura 1 se puede observar un importante incremento en las consultas la semana epidemiológica número 7 (última semana de febrero) que asciende hasta un *peak* la semana epidemiológica número 12 que marca el inicio del primer periodo de alta demanda del año, que llega a su nivel máximo la semana epidemiológica número 20, que corresponde al *peak* de la campaña de invierno, luego se observa un marcado descenso que llega al nivel más bajo la semana epidemiológica número 27, que asciende hasta la semana 32, que marca el inicio del segundo periodo de alta demanda por atenciones de urgencia que dura hasta la semana 51.

Tabla 2. Resultados del modelo para el año 2024, por semana epidemiológica, con 1, 2, 3 y 4 semanas.

Semana Epidemiológica	N Consultas Reales	Valor predicho 2w	Intervalo de predicción	1w Dif%	2w Dif%	3w Dif%	4w Dif%
1	507	512	[482, 532]	0,99%	0,99%	0,99%	0,99%
2	593	572	[563, 623]	6,58%	3,54%	3,54%	3,54%
3	624	577	[593, 655]	8,33%	7,53%	17,15%	17,15%
4	555	560	[527, 583]	5,77%	0,90%	0,36%	7,03%
5	541	573	[514, 568]	6,65%	5,91%	5,91%	4,99%
6	490	574	[466, 515]	4,29%	17,14%	20,20%	20,20%
7	449	481	[427, 471]	3,79%	7,13%	7,35%	7,35%
8	481	553	[457, 505]	4,99%	14,97%	14,97%	28,69%
9	622	611	[591, 653]	2,41%	1,77%	1,93%	2,89%
10	663	680	[630, 696]	0,75%	2,56%	3,32%	3,32%
11	743	738	[706, 780]	0,13%	0,67%	0,67%	0,67%
12	800	779	[760, 840]	1,63%	2,63%	0,75%	0,63%
13	737	742	[700, 774]	1,22%	0,68%	1,22%	0,81%
14	785	811	[746, 824]	4,20%	3,31%	3,31%	3,31%
15	871	837	[827, 915]	4,25%	3,90%	5,05%	5,05%
16	774	858	[735, 813]	5,30%	10,85%	11,11%	12,14%
17	804	837	[764, 844]	1,49%	4,10%	4,10%	4,48%
18	799	872	[759, 839]	0,63%	9,14%	12,52%	12,52%
19	943	895	[896, 990]	6,57%	5,09%	4,56%	4,56%
20	972	895	[923, 1021]	3,50%	7,92%	7,92%	6,28%
21	940	947	[893, 987]	1,49%	0,74%	3,51%	3,94%
22	932	901	[885, 979]	1,72%	3,33%	3,11%	3,11%
23	968	983	[920, 1016]	1,45%	1,55%	1,55%	1,55%
24	864	814	[821, 907]	0,81%	5,79%	8,22%	8,68%
25	727	778	[691, 763]	6,60%	7,02%	5,50%	5,50%
26	657	692	[624, 690]	0,00%	5,33%	5,33%	5,33%
27	604	595	[574, 634]	0,83%	1,49%	1,32%	1,32%
28	675	590	[641, 709]	4,30%	12,59%	8,59%	3,56%
29	755	735	[717, 793]	2,78%	2,65%	2,65%	0,66%
30	754	766	[716, 792]	2,25%	1,59%	1,06%	1,06%
31	798	791	[758, 838]	0,50%	0,88%	0,38%	0,38%
32	775	825	[736, 814]	5,68%	6,45%	6,45%	4,77%
33	822	836	[781, 863]	1,95%	1,70%	2,55%	1,95%
34	869	834	[826, 912]	5,06%	4,03%	4,26%	4,26%
35	800	812	[760, 840]	1,50%	1,50%	1,50%	1,50%
36	885	873	[841, 929]	0,79%	1,36%	1,24%	0,11%
37	915	900	[869, 961]	1,86%	1,64%	1,64%	1,75%
38	840	937	[798, 882]	4,88%	11,55%	11,55%	11,55%
39	970	986	[922, 1019]	1,24%	1,65%	4,85%	4,85%
40	894	937	[849, 939]	3,58%	4,81%	4,36%	5,37%
41	945	927	[898, 992]	4,87%	1,90%	1,90%	1,80%
42	903	898	[858, 948]	1,22%	0,55%	4,43%	4,43%
43	935	903	[888, 982]	3,53%	3,42%	4,06%	4,06%
44	889	829	[845, 933]	0,56%	6,75%	3,04%	7,31%
45	951	900	[903, 999]	3,36%	5,36%	1,58%	4,21%
46	865	841	[822, 908]	0,00%	2,77%	3,93%	3,93%
47	814	826	[773, 855]	1,84%	1,47%	1,47%	1,47%
48	821	808	[780, 862]	1,34%	1,58%	0,73%	2,56%
49	786	804	[747, 825]	2,93%	2,29%	2,67%	2,29%
50	831	809	[789, 873]	5,90%	2,65%	2,65%	2,65%
51	766	815	[728, 804]	6,14%	6,40%	7,96%	7,96%
52	721	745	[685, 757]	0,83%	3,33%	3,05%	6,66%
MAPE				2,99%	4,36%	4,69%	5,14%
N Semanas > 5%				11	18	16	17

(Error de Porcentaje Medio Absoluto (MAPE por sus siglas en inglés).

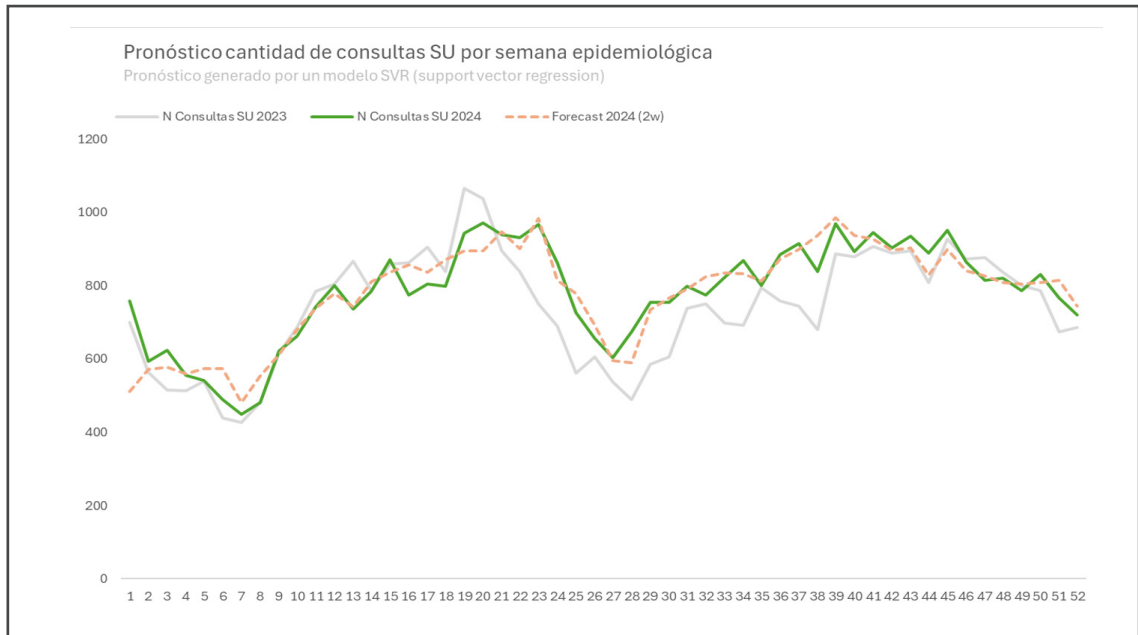


Figura 2: Estacionalidad de las atenciones de urgencia 2024, utilizada para toma de decisiones.

Discusión

Con una metodología simple y ampliamente disponible pronosticamos la demanda de atenciones a nuestro servicio de urgencia durante el año 2024, con una diferencia de pacientes promedio de 3,3% semanal, esto nos permitió ajustar la oferta y desarrollar estrategias innovadoras para manejar los momentos *peak* de consultas del año con anticipación, al igual que estudios internacionales logramos pronosticar la cantidad de atenciones semanales, por la simpleza de la herramienta creemos que esta metodología es aplicable a otros centros públicos y privados del país.

Por otro lado, el análisis de la estacionalidad nos permitió establecer que existen dos periodos de alta demanda por atenciones durante el año en este servicio de urgencia, no solamente uno “campana de invierno”, por lo tanto, la planificación anual debería ser en dos *peak*, lo que

abre varias interrogantes del punto de vista de la gestión hospitalaria, pensando en la eficiencia, satisfacción usuaria, calidad y seguridad de la atención de los pacientes de urgencia.

No fue posible por el alcance del estudio medir el impacto real en la gestión del servicio de urgencia, sin embargo, es importante mencionar que, al contar con los datos de números de pacientes semanales y semanas del año con alta y baja demanda, tomamos decisiones en equipo del punto de vista del manejo de las personas que cuentan con un sustento basado en datos, lo que nos permitió tener mejores conversaciones y poder establecer objetivos con mayor facilidad.

Limitaciones

Existen distintas limitaciones en el estudio, en relación con la metodología utilizada los

modelos univariados no permiten incluir otras variables que podrían resultar útiles para explicar y predecir de mejor manera el comportamiento del número de consultas.

También es importante mencionar que los algoritmos de *machine learning* aún no se encuentran muy extendidos para el uso en problemas de series tiempo, la principal dificultad de estos algoritmos es que dada su naturaleza no son capaces de identificar tendencias o estacionalidades en un conjunto de datos. Sin embargo, es posible entregar dicha información a través de la creación de variables con rezagos, medias móviles, cambios en un intervalo de tiempo que fue lo que utilizamos en este estudio, esto hace que el modelo pierda robustez ya que básicamente trabaja en base a predicciones lo cual conlleva a una disminución de la exactitud deseada.

En la gestión de servicios de urgencia no solamente la estacionalidad anual, es decir verano e invierno marcan hitos importantes, sino que también la temporalidad según días de la semana o las horas del día, es decir no es lo mismo, un lunes a las 18 horas que un miércoles a las 4 de la madrugada, el indicador de tasa de arribo promedio de los pacientes al servicio de urgencia por día, hora y mes, es un indicador fundamental a la hora de realizar los *staffing* médicos, en este estudio no abordamos el desafío de pronosticar datos más específicos con mayor tiempo de anticipación, para esto se requieren modelos de pronóstico más robustos, para manejo de gran cantidad de bases de datos.

Conclusiones

Es posible predecir con un error menor al 5% el número de consultas semanales a un servicio de urgencia de un hospital universitario en Santiago de Chile, creemos que es importante difundir este estudio, ya que, este modelo podría replicarse en los distintos dispositivos de la red de urgencia.

Es importante generar modelos más robustos que permitan realizar predicciones más exactas

utilizando más herramientas relacionadas al manejo de datos, esto podría permitir una mejor gestión de los recursos de salud en los distintos servicios de urgencia, contribuyendo a disminuir el overcrowding o atochamiento que se puede observar en la red de urgencia en Chile y en el mundo año a año.

Referencias

1. Belzunegui MA, García C. Tiempos de espera en un servicio de urgencias como indicador de calidad asistencial. *Emergencias*. 1993; 5(3): 84-89.
2. Departamento de Estadísticas e Información de Salud (DEIS), Ministerio de Salud de Chile. *Indicadores básicos de salud Chile 2011*. Santiago: Ministerio de Salud de Chile; 2011 [citado el 22 de diciembre de 2025]. Disponible en: <https://deis.minsal.cl/>
3. Emergency Medicine Practice Committee, American College of Emergency Physicians. *Emergency Department Crowding: High Impact Solutions*. Irving (TX): American College of Emergency Physicians; 2016 [citado el 22 de diciembre de 2025]. 24 p. Disponible en: https://www.acep.org/siteassets/sites/acep/media/crowding/empc_crowding-ip_092016.pdf
4. Asplin BR, Magid DJ, Rhodes KV, Solberg LI, Lurie N, Camargo CA Jr. A conceptual model of emergency department crowding. *Ann Emerg Med*. 2003; 42(2): 173-180.
5. Box GEP, Jenkins GM, Reinsel GC. *Time series analysis: forecasting and control*. 3rd ed. Englewood Cliffs (NJ): Prentice Hall; 1994. 598 p.
6. Adya M, Collopy F. How effective are neural nets at forecasting and prediction? A review and evaluation. *J Forecast*. 1998; 17(5-6): 481-495.
7. Peláez-Rodríguez C, Torres-López R, Pérez-Aracil J, López-Laguna N, Sánchez-Rodríguez S, Salcedo-Sanz S. An explainable machine learning approach for hospital emergency department visits forecasting using continuous training and multi-model regression. *Comput Methods Programs Biomed*. 2024; 245:108033.
8. Álvarez-Chaves H, Muñoz P, R-Moreno MD. Machine learning methods for predicting the admissions and hospitalizations in the emergency department of a civil and military hospital. *J Intell Inf Syst*. 2023; 61: 881-900.
9. Murtas R, Tunesi S, Andreano A, et al. Time-series cohort study to forecast emergency department visits in the city of Milan and predict high demand: A 2-day warning system. *BMJ Open*. 2022; 12(4): e056017.
10. Gafni-Pappas G, Khan M. Predicting daily emergency department visits using machine learning could increase accuracy. *Am J Emerg Med*. 2023; 65: 5-11.