

ORIGINAL

Predicción en tiempo real de los ingresos del servicio de urgencias mediante un modelo de inteligencia artificial y su integración en la planificación de las camas de hospitalización

Javier Millán Soria^{1,2}, Javier Medina Álvarez³, Laura Sánchez Suárez¹, Cesar Cano Cerviño³, Leticia Serrano Lázaro¹, M.^a Carmen García-Minguillán Castillo³, Vanesa Ginestar Miravet³

Objetivo. Diseñar, validar e implementar una herramienta basada en un modelo de aprendizaje automático capaz de predecir en tiempo real los ingresos de los pacientes urgentes y desarrollar una aplicación que incluya el modelo junto a indicadores clásicos sobre la presión asistencial.

Métodos. Se analizaron los datos anonimizados de 328.696 episodios de urgencias. Se identificaron 15 variables con mayor capacidad predictiva mediante análisis de correlación de Pearson. Se seleccionó el modelo RandomForest. Para el proceso de construcción se utilizó el lenguaje Python, y para el diseño y validación el software Jupyter Notebook. Para el entrenamiento se utilizaron 209.530 episodios (64%), 52.383 (16%) para la validación y 66.783 (20%) para test. El modelo se integró en un Panel de Control con la herramienta Microsoft Power BI.

Resultados. El modelo presenta una elevada capacidad predictiva para distinguir los pacientes que van a precisar ingreso, con un área bajo la curva (ABC) de la característica operativa del receptor (COR) de 0,97. Para cada métrica se observa como disminuye la puntuación del entrenamiento al tiempo que aumenta la puntuación de validación lo que descarta comportamientos de sobreajuste. El punto de saturación en las curvas de aprendizaje se alcanza a los 130.000 episodios. La calibración del modelo tiene una puntuación Brier de 0,0414.

Conclusiones. El modelo muestra un rendimiento excelente y un potencial significativo para predecir el ingreso de los pacientes atendidos en urgencias. La combinación de algoritmos de *machine learning* con sistemas de visualización interactiva representa un paso importante hacia una gestión y planificación más eficiente para evitar problemas de drenaje y sobreocupación.

Palabras clave: Inteligencia artificial. Sistemas de apoyo a la toma de decisiones clínicas. Hospitalización. Servicio de Urgencias hospitalario. Evaluación de riesgos.

Real-time prediction of emergency department admissions using an AI model and its integration into hospital bed-planning

Objective. To design, validate, and implement a tool based on a machine-learning model capable of predicting emergency patient admissions in real time, and to develop an application that integrates the model together with traditional indicators of health care pressure.

Method. We analyzed anonymized data from a total of 328,696 emergency episodes. Fifteen variables with the highest predictive capacity were identified through Pearson correlation analysis. The RandomForest model was selected. Python was used for model construction, and "Jupyter Notebook" for design and validation. A total of 209,530 episodes (64%) were used for training, 52,383 (16%) for validation, and 66,783 (20%) for testing. The model was integrated into a Control Panel using Microsoft Power BI.

Results. The model showed a high predictive ability to identify patients who would require admission, with a receiver operating characteristic (ROC) area under the curve (AUC) of 0.97. For each metric, a decrease in training score and a concurrent increase in validation score were observed, ruling out overfitting behaviors. The saturation point in the learning curves was reached at 130,000 episodes. Model calibration yielded a Brier score of 0.0414.

Conclusions. The model demonstrates excellent performance and significant potential for predicting hospital admissions among emergency department patients. Combining machine-learning algorithms with interactive visualization systems represents a major step toward more efficient management and planning, helping avoid bottlenecks and overcrowding.

Keywords: Artificial intelligence. Clinical decision support systems. Hospitalization. Hospital emergency service. Risk assessment.

DOI: 10.55633/s3me/009.2026

Filiación de los autores:

¹Servicio de Urgencias, Hospital Universitari i Politècnic La Fe, Valencia, España.

²Departamento de Medicina, Universitat de Valencia, España.

³Subdirección de Sistemas de Información, Hospital Universitari i Politècnic La Fe, Valencia, España.

Contribución de los autores:

Todos los autores han confirmado su autoría en el documento de responsabilidades del autor, acuerdo de publicación y cesión de derechos a EMERGENCIAS.

Autor para correspondencia:

Javier Millán Soria
Servicio de Urgencias
Edificio C. Planta Baja
Hospital Universitari i Politècnic La Fe
Avda. Fernando Abril Martorell, 106
46026 Valencia, España.

Correo electrónico:

millan_jav@gva.es

Información del artículo:

Recibido: 10-6-2025

Aceptado: 11-11-2025

Online: 9-12-2025

Editor responsable:

Agustín Julián-Jiménez

DOI:

10.55633/s3me/009.2026

Introducción

Los servicios de urgencias (SU) desempeñan un papel fundamental dentro del sistema sanitario y su actividad repercute, inevitablemente, en el resto de la organización. Los SU generan entre el 58% y el 71% del total de ingresos hospitalarios, por lo que influyen en la disponibilidad de camas para el desarrollo de la actividad programada, en las listas de espera para consultas y en la sobrecarga de los servicios de apoyo diagnóstico. La creciente presión asistencial en los SU representa uno de los principales desafíos del sistema sanitario actual¹.

Según cifras del Registro de Actividad Sanitaria Especializada del Ministerio de Sanidad², las atenciones en los SU de los hospitales del Sistema Nacional de Salud (SNS) han pasado de aproximadamente 22 millones en 2018 a más de 24,9 millones en 2023 con un incremento medio anual desde 2021 entre el 5-10%, según Comunidades Autónomas. Los pacientes usan cada vez más los SU de los hospitales como modo de acceso al sistema sanitario, con una tasa de frecuentación media de 516 urgencias/1.000 habitantes, superior a la de muchos países del entorno. Las causas son múltiples, relacionadas con las propias características del sistema sanitario español como la universalidad, la accesibilidad o el incremento de la población protegida, pero también con cambios en el perfil clínico de los pacientes, el envejecimiento de la población, cambios sociales y culturales como la facilidad de acceso a la información en redes que condiciona una percepción subjetiva de gravedad, la falta de educación sanitaria, la cultura de la inmediatez sin conciencia del coste y con un alto grado de exigencia, o las propias deficiencias y demoras en el resto de niveles asistenciales.

La combinación de esta elevada presión asistencial, la limitación estructural y de recursos, la variabilidad clínica de los pacientes en urgencias y la necesidad de mantener en el sistema la actividad programada, genera problemas de saturación y drenaje, que complican la toma de decisiones clínicas y organizativas en tiempo real³. En este contexto, contar con herramientas que permitan anticipar con precisión la necesidad de ingreso hospitalario se ha convertido en una prioridad estratégica para optimizar la gestión de camas en los hospitales, reducir los tiempos de espera en urgencias y, por tanto, mejorar la calidad de la atención a los pacientes^{4,5}.

El objetivo principal de este trabajo ha sido diseñar, validar e implementar una herramienta basada en un modelo de aprendizaje automático capaz de predecir en tiempo real si un paciente que está siendo atendido en el SU requerirá ingreso hospitalario.

Como objetivo secundario se planteó desarrollar una aplicación informática que incluyera el modelo junto a indicadores clave de presión asistencial como el índice de ocupación hospitalaria, número de pacientes pendientes de cama y el tiempo medio de estancia en urgencias, que pudiese contribuir a facilitar la planificación operativa a corto/medio plazo mediante una

visualización focalizada de la carga asistencial y de las necesidades que va a generar.

Con esta iniciativa se pretende avanzar hacia un modelo de urgencias más inteligente, capaz de anticiparse a los escenarios de colapso y problemas de drenaje de los pacientes pendientes de una cama de hospitalización⁶, y apostar por unos SU hospitalarios modernos y adaptados a todos estos cambios^{7,8}.

Método

Ámbito de actuación

El Departamento de Salud Valencia La Fe cuenta con una población directa asignada de 306.051 habitantes, de los cuales 264.917 son mayores de 15 años. El Hospital Universitari i Politècnic La Fe es un centro de alta tecnología y referencia de la Comunidad Valenciana, que atiende a más de 5 millones de personas. En 2024, el SU registró 228.206 episodios, con 25.561 ingresos urgentes (11,07%). El área de hospitalización dispone de 995 camas funcionales, que realizó un total de 21.353 ingresos programados (47,81%).

Diseño del estudio

Se diseñó y desarrolló un estudio siguiendo las directrices TRIPOD+AI⁹. El problema se definió como una clasificación binaria (ingreso frente a no ingreso). La variable objetivo "ingreso" se estableció como la necesidad de hospitalización y ocupación formal de una cama dentro del mismo centro tras la atención en el SU. Para el entrenamiento del modelo se incluyeron todos los episodios de pacientes adultos (con 15 o más años) atendidos en el SU entre el 1 de enero de 2022 y el 15 de marzo de 2024, excluyendo los casos con datos incompletos, duplicados y registros de quemados o urgencias obstétrico/ginecológicas. La cohorte final, representativa de la población objetivo de pacientes adultos atendidos en urgencias, incluyó un total de 328.696 episodios, de los cuales 209.530 (64%) se utilizaron para el entrenamiento, 52.383 (16%), para la validación y 66.783 (20%) para test. Los datos fueron extraídos de la plataforma de datos pseudonimizada del Departamento de Salud Valencia-La Fe, lo que facilita la validación de cumplimiento con el Reglamento General de Protección de Datos (RGPD) y la garantía de los derechos de privacidad de las personas. El protocolo fue aprobado por el Comité Ético de Investigación Clínica (CEIC) del Departamento.

Análisis estadístico

De la totalidad de variables clínico-administrativas disponibles en los episodios de atención en urgencias, se seleccionaron 15 mediante un análisis de correlación de Pearson y eliminación recursiva de características, y se priorizó su capacidad predictiva y baja multicolinealidad. En la matriz de correlación de Pearson (Figura 1)

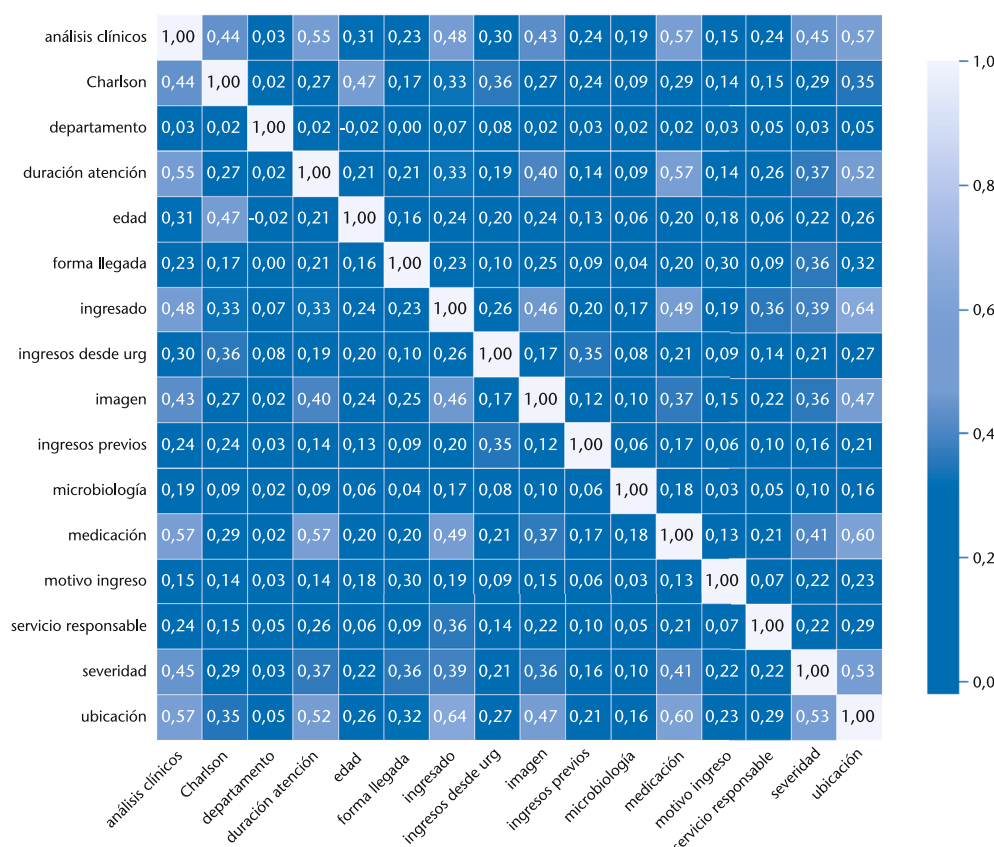


Figura 1. Matriz de correlación de Pearson que muestra la relación de cada variable predictora con la variable objetivo “ingresado”.

se puede observar la relación de cada una de las variables predictoras con la variable objetivo “ingresado”. Por muy baja relevancia en el modelo, se excluyeron sexo, reingresos e hiperfrecuentadores, permanencia en triaje y observación y atenciones en el último año.

Las variables predictoras se clasificaron en numéricas o categóricas y su rango de valores posibles. Además, se agruparon en tres niveles: PRE-EPISODIO (conocidas antes de la llegada a urgencias), INICIO-EPISODIO (disponibles al inicio de la atención) e INTRA-EPISODIO (recogidas durante el episodio) (Tabla 1).

Las variables categóricas se transformaron mediante la técnica *target encoding* (codificación basada en objetivo) para mejorar el rendimiento y eficiencia del modelo, y para reducir al mismo tiempo la dimensionalidad. De esta manera, cada categoría se convirtió en un número calculado y se sustituyó por la proporción de ingresos observados en cada una de ellas respecto al total de atenciones. Este procedimiento se utilizó con las variables gravedad, servicio responsable, forma de llegada, motivo de ingreso, medicación, determinaciones fuera de rango de los laboratorios de análisis clínicos y

Tabla 1. Tipología de variables predictoras y valores posibles. Clasificación de la variable predictora en función del momento en el que se tiene disponibilidad de los valores

Variable	Tipo	Valores posibles	Disponibilidad
Edad	Númérica	en meses > 179 (paciente adulto)	Pre-episodio
Índice de Comorbilidad Charlson	Númérica	[0-5]	Pre-episodio
Hospitalizaciones previas	Númérica	[0..n]	Pre-episodio
Ingresos/Atenciones en urgencias	Númérica	[0..n]	Pre-episodio
Gravedad asignada en triaje	Categórica	Poco urgente, urgente, muy urgente, atención inmediata	Inicio-episodio
Servicio responsable	Categórica	Servicios del hospital	Inicio-episodio
Forma de llegada	Categórica	SAMU, TNA, SVB, Propios medios	Inicio-episodio
Motivo de Ingreso	Categórica	Propio, traslado desde otro hospital, atención primaria	Inicio-episodio
Medicación administrada	Categórica	Fármacos administrables	Intra-episodio
Determinaciones de análisis clínicos fuera de rango	Categórica	Determinaciones de análisis clínicos	Intra-episodio
Determinaciones de microbiología fuera de rango	Categórica	Determinaciones de microbiología	Intra-episodio
Solicitud de pruebas de imagen	Categórica	Estudios de imagen	Intra-episodio
Tiempo permanencia total en urgencias	Númérico	[0..n]	Intra-episodio

SAMU: Servicio medicalizado urgente; TNA: transporte no asistido; SVB: soporte vital básico.

Tabla 2. Métricas principales de rendimiento de los modelos evaluados

Modelo	Precisión	Sensibilidad	Puntuación F1	ABC COR (IC 95%)	Muestra (nº de episodios)
Regresión logística	0,77	0,83	0,80	0,939	39.032
Random forest	0,86	0,79	0,82	0,958	39.032
Red neuronal	0,80	0,87	0,83	0,957	39.032
Gradient boosting (XGBoost)	0,86	0,78	0,81	0,953	39.032

ABC: área bajo la curva; COR: característica operativa del receptor; IC: intervalo de confianza.

Tabla 3. Relación de hiperparámetros de entrenamiento del modelo *random forest*

Criterio	gini
max_dep	16
max_features	sqrt
max_leaf_nodes	Ninguno
max_samples	Ninguno
min_impurity_decrease	0.0
min_samples_leaf	1
min_impurity_decrease	0.0
min_weight_fraction_leaf	0.0
min_samples_split	32
n_estimators	1024

Tabla 4. Métricas obtenidas para modelo *random forest*


Clase	Precisión	Sensibilidad	Puntuación F1	Muestra (nº de episodios)
0	0,97	0,97	0,97	59.166
1	0,78	0,74	0,76	7.617
Exactitud global			0,95	66.783
Promedio no ponderado	0,87	0,86	0,87	66.783
Promedio ponderado	0,95	0,95	0,95	66.783

ABC: área bajo la curva (Test): 0,975.

microbiología y pruebas de imagen. Disponer de datos de atenciones previas en urgencias “etiquetadas”, es decir, con la información final de si el paciente ingresó o no ingresó, permite entrenar modelos de aprendizaje automático “supervisados”.

Selección y entrenamiento de los modelos de aprendizaje automático

Inicialmente se seleccionaron 4 algoritmos de clasificación con buenos resultados previos¹⁰: regresión logística, redes neuronales, XGBoost (extreme gradient boosting) y *random forest* (bosque aleatorio). Los modelos fueron entrenados y evaluados con múltiples ejecuciones iterativas, variando distintas combinaciones de características de entrada y parámetros. Para la construcción del modelo se utilizó el lenguaje de programación Python y librerías especializadas en análisis de datos, en particular la librería “*sklearn*”. Para el diseño y validación se utilizó el software Jupyter Notebook, herramienta especialmente útil para el desarrollo de modelos predictivos al integrar de forma intuitiva documentación, código y visualización gráfica de resultados.

**Figura 2.** Curva de la característica operativa del receptor (COR).

Las métricas de rendimiento¹¹ incluyeron el área bajo la curva (ABC) de la característica operativa del receptor (COR), precisión, sensibilidad, puntuación F1 (promedio armónico entre precisión y sensibilidad) y calibración. Asimismo, se analizaron curvas de aprendizaje y calibración.

Finalmente, en base al modelo entrenado, se desarrolló un panel de control avanzado, que hace uso de este sistema, para la evaluación continua de la predicción individualizada y global de los pacientes en urgencias y la evolución de los indicadores de actividad y predictivos del servicio¹². El panel se ha desarrollado con la herramienta Microsoft Power BI.

Resultados

Las métricas obtenidas para cada uno de los modelos entrenados (red neuronal, *random forest* y *gradient boosting*) fueron similares (Tabla 2). Se eligió *random forest*, además de por obtener unas métricas globales (ABC COR) ligeramente superiores, por arrojar unas métricas más equilibradas entre clases, presentar menor riesgo de sobreajuste y tratarse de un modelo más sencillo con menores tiempos de entrenamiento y predicción de nuevas instancias¹³. En concreto, se utilizó la clase RandomForestClassifier de la librería *skikit-learn* de Python, entrenada con los hiperparámetros mostrados en la Tabla 3. La red neuronal obtuvo la mejor sensibilidad para detectar los casos reales positivos (0,87), aunque con menor precisión global (0,80), es decir, con una mayor tasa de falsos positivos.

En la Tabla 4 se pueden observar las métricas obtenidas para el modelo *random forest* que alcanzó un rendimiento global elevado, con una exactitud (*accuracy*) del 95% (proporción total de predicciones correctas) y un ABC-COR de 0,975. El promedio ponderado alcanzó valores de 0,95 en precisión, 0,95 en sensibilidad y 0,95 en puntuación F1, lo que indica un desempeño robusto del modelo. A nivel de clases mostró una excelente capacidad para identificar los casos negativos (precisión y sensibilidad del 97%), mientras que para la clase ingreso (cla-




Figura 3. Curvas de aprendizaje de las métricas exactitud, precisión, sensibilidad y puntuación F1 del modelo *random forest*.

se 1) la precisión, sensibilidad y puntuación F1, fue de 0,78, 0,74 y 0,76, respectivamente. Este comportamiento es debido al desequilibrio normal en la distribución de clases con una menor representación de la clase ingreso. El promedio macro fue de 0,87 en precisión, 0,86 en sensibilidad y 0,87 en puntuación F1.

Un ABC-COR del 0,97 (Figura 2) es un indicador de la fuerte capacidad del modelo para distinguir entre pacientes que requieren ingreso hospitalario (clase 1) de aquellos que no lo requieren (clase 0). En la matriz de confusión se objetiva, para un total de 52.383 episodios testeados, 1.094 falsos positivos y 1.872 falsos negativos, con un valor predictivo positivo de 80,9 y una especificidad de 97,6%.

Asimismo, se han obtenido las curvas de aprendizaje del modelo (Figura 3). Para cada una de las métricas se observa como disminuye la puntuación del entrenamiento al tiempo que aumenta el de validación de la métrica, lo que sugiere un buen comportamiento del entrenamiento y descarta comportamientos de sobreajuste. También podemos observar en las curvas de aprendizaje que el punto de saturación se alcanza en torno a los 130.000 episodios, a partir del cual, estas tienden ya a

estabilizarse, lo cual indica que el tamaño de la muestra es suficiente para el correcto entrenamiento del modelo.

La calibración del modelo¹⁴ tiene una puntuación Brier de 0,0414, valor muy bajo que refleja una buena calibración y por tanto que las probabilidades predichas por el modelo reflejan fielmente las probabilidades reales observadas (Figura 4). En la Figura 5 se puede observar la importancia de cada una de las variables utilizadas en el modelo.

Actualmente se está llevando a cabo una monitorización diaria del comportamiento del modelo y se observa que se mantienen los resultados de las métricas descritas para las pruebas de test, con una exactitud mantenida por encima del 95%.

Implementación y funcionalidad en un panel de control avanzado

Se desarrolló una aplicación basada en el modelo predictivo que complementa las herramientas clásicas de asistencia y gestión en urgencias, lo cual facilita decisiones basadas en datos y anticipación de problemas¹⁵. El panel de control avanzado dispone de dos vistas:

Característica	Importancia
14 Ubicación	0,315390
10 Medicación	0,134568
7 Imagen	0,128347
0 Análisis clínicos	0,107529
12 Servicio responsable	0,093346
3 Duración atención	0,064520
13 Gravedad	0,035298
1 Charlson	0,027972
4 Edad	0,025734
6 Ingresos desde urgencias	0,021536
9 Microbiología	0,017614
2 Departamento	0,009394
5 Forma llegada	0,008381
11 Motivo ingreso	0,006038
8 Ingresos previos	0,004330

Figura 4. Calibración del modelo *random forest* obtenido.

– Vista asistencial: muestra en tiempo real la predicción global e individualizada de ingreso. Los pacientes se ordenan por probabilidad de ingreso, representada en un gradiente cromático, y al seleccionar un caso se visualizan las variables predictoras que sustentan la estimación.

– Vista de gestión (Figuras 6-7). Combina evolución temporal de la actividad asistencial (ingresos, altas, ocupación, camas disponibles) con información predictiva. Incluye KPIs como número total de pacientes, presión asistencial, porcentaje de ingresos diarios y pacientes pendientes de cama. Tres gráficas ilustran la evolución de ingresos y ocupación, la concordancia entre ingresos esperados y observados, y la tendencia de atenciones e ingresos hospitalarios.





Figura 5. Importancia de cada una de las características en el modelo *random forest* obtenido.

Discusión

La demanda en el SU, aunque no es programada, sigue un comportamiento predefinido, previsible y reproducible. Hasta el momento se utilizan las series históricas y los indicadores clásicos⁴, que tienen en cuenta únicamente los patrones de afluencia, la diferente frecuentación en función del día de la semana, del mes o la evolución de la situación epidémica estacional, para intentar determinar cómo se va a comportar la presión en urgencias y de qué forma va a condicionar la ocupación del hospital. Sin embargo, modelos predictivos basados en inteligencia artificial (IA), y en particular aque-



llos contruidos mediante algoritmos de aprendizaje automático, han demostrado una notable capacidad para identificar patrones complejos en datos clínicos⁵. Aplicados a urgencias, estos modelos podrían permitir predecir de forma temprana y precisa la probabilidad de ingreso hospitalario, integrando toda la información sobre el flujo de pacientes con variables más complejas relacionadas con su perfil clínico, ámbito de actuación y funcionamiento del SU o las características específicas de su población de referencia⁶.

El presente estudio demuestra que un modelo de aprendizaje automático basado en *random forest* permite predecir con elevada precisión la necesidad de ingreso hospitalario en pacientes atendidos en urgencias. Con un ABC COR de 0,97 y una calibración óptima, el modelo supera ampliamente el rendimiento descrito en estudios previos, donde los ABC COR suelen situarse entre 0,75 y 0,90. Estos resultados sugieren que el uso de datos clínico-administrativos rutinarios, combinados


con técnicas de aprendizaje automático, puede aportar una herramienta robusta para la gestión de la sobrecarga en urgencias¹⁶.

La correcta calibración es especialmente relevante en el ámbito clínico, ya que asegura que las probabilidades de ingreso predichas reflejan de forma fiel el riesgo real, lo que facilita su interpretación por parte del personal sanitario y su integración en sistemas de apoyo a la decisión clínica y a la gestión.

En lo que respecta a la literatura previa, estos resultados consolidan la línea apuntada por Hong *et al.*¹⁷ y Feretzakis *et al.*¹⁸, sobre la eficacia de los modelos de aprendizaje automático para predecir ingresos. Sin embargo, a diferencia de esos trabajos y de la aproximación más clásica descrita por Elvira Martínez *et al.*¹⁹, aquí se incorpora un sistema más versátil y escalable, que plantea su uso en tiempo real para la gestión del SU.

Entre las fortalezas del estudio destaca el tamaño de la cohorte (más de 300.000 episodios), la representati-

Evolución ingresos, ingresos pendientes de cama y ocupación de camas en planta



Evolución de la predicción del porcentaje de ingresos e ingresos pendientes de cama



Evolución de las atenciones e ingresos respecto a la actividad esperada en base a la tendencia calculada




Figura 7. Gráficos de evolución temporal en función de la hora del día de la información clave para el servicio de urgencias en tiempo real.

ACU: acumulados; OCU: ocupación; ADU: adultos; PRED.: predicción; ING.: ingresos.

vidad poblacional, el uso de múltiples algoritmos comparativos, la validación en un conjunto de test independiente y la estabilidad del modelo en el tiempo a través de la monitorización continua de los resultados de sus métricas. Asimismo, la implementación en un panel de control avanzado introduce una herramienta innovadora para la gestión de los recursos hospitalarios y la toma de decisiones clínicas en los SU hospitalarios. En este caso, la predicción de posibles ingresos hospitalarios se integra de forma activa con el resto de los indicadores, y permite anticipar picos de demanda asistencial y optimizar la asignación de recursos^{9,20} y toma de decisiones de forma proactiva en la organización.

Este trabajo presenta algunas limitaciones. En primer lugar, se trata de un estudio unicéntrico, lo que puede limitar la generalización de los resultados a otros hospitales con distinta casuística o recursos^{21,22}. En segundo lugar, aunque se incluyeron variables clínicas y administrativas, no se dispuso de datos fisiológicos en tiempo real (por ejemplo los signos vitales monitorizados), que podrían mejorar la capacidad predictiva. Finalmente, el modelo requiere un análisis de impacto en la práctica clínica y gestión de recursos (previstos para una segunda fase) con el fin de confirmar su utilidad en la reducción de tiempos de espera de los pacientes urgentes ingresados y la optimización de camas.

Una de las características diferenciales de este proyecto es la capacidad de recalcular la predicción de forma continua durante la evolución del episodio. El modelo combina información previa del estado de salud del paciente con la que se va generando a lo largo de su atención en urgencias, actualizando la estimación cada cinco minutos hasta el alta²³⁻²⁵. Esta reevaluación dinámica permite mejorar la precisión y ofrece al profesional una ayuda más ajustada y en tiempo real para la toma de decisiones.

Asimismo, se identifican varias líneas de mejora del modelo. La primera consiste en la incorporación de variables adicionales que aporten capacidad predictiva, tanto de datos estructurados procedentes de episodios previos (por ejemplo: intervenciones quirúrgicas, trasplantes, hospital de día, técnicas intervencionistas) como de datos no estructurados, mediante técnicas de procesamiento de lenguaje natural (PLN) aplicadas a informes de imagen o de procedimientos generados durante la estancia en urgencias^{26,27}. Una segunda vía de optimización sería la aplicación de factores de corrección a variables predictoras correlacionadas, con el objetivo de reducir redundancias y evitar distorsiones en la estimación del riesgo de ingreso. Finalmente, la exploración de modelos más avanzados de aprendizaje automático como técnicas de aprendizaje profundo (*deep learning*), de forma independiente o combinada con los algoritmos actuales, podría potenciar aún más la capacidad discriminativa del sistema.

En conjunto, aunque el modelo actual muestra resultados muy prometedores y supone un avance significativo en el uso de la IA para mejorar la atención y eficiencia en los SU, aún existen oportunidades de desarrollo que pueden fortalecer su aplicabilidad clínica

y su impacto en la gestión hospitalaria^{28,29}. En conclusión, el modelo desarrollado en el SU del Hospital Universitario y Politécnico La Fe de Valencia muestra un rendimiento excelente y un potencial significativo para apoyar la toma de decisiones en el SU hospitalario. La combinación de algoritmos de aprendizaje automático con sistemas de visualización interactiva representa un paso importante hacia una gestión más eficiente y personalizada de la demanda asistencial, pues anticipa información de las situaciones que se van a producir. Futuras investigaciones deberían centrarse en la validación multicéntrica, la integración con datos en tiempo real y la evaluación de su impacto en indicadores asistenciales y de resultados clínicos.

Conflicto de intereses: Los autores declaran no tener conflicto de interés en relación con el presente artículo.

Financiación: Los autores declaran la no existencia de financiación en relación con el presente artículo.

Responsabilidades éticas: Todos los autores han confirmado el mantenimiento de la confidencialidad y respeto de los derechos de los pacientes en el documento de responsabilidades del autor, acuerdo de publicación y cesión de derechos a EMERGENCIAS.

Artículo no encargado por el Comité Editorial y con revisión externa por pares.

Bibliografía

- Carballo Cardona C. Servicios de Urgencias en situación crítica: hacia un marco de identificación y actuación estructural. *Emergencias*. 2025;37:301-3.
- Urgencias atendidas en hospitales del Sistema Nacional de Salud (SNS), frecuentación por 1.000 habitantes y porcentaje de urgencias ingresadas sobre el total de urgencias atendidas según comunidad autónoma. Ministerio de Sanidad. (Consultado 2 Noviembre 2025). Disponible en: <https://www.sanidad.gob.es/estadEstudios/sanidadDatos/tablas/tabla27.htm>
- Salvador Suárez FJ, Millán Soria J, Téllez Castillo C, Pérez García C, Oliver Martínez C. Implantación de un plan de calidad en un servicio de urgencias y su impacto en la satisfacción del paciente. *Emergencias*. 2013;25:163-70.
- Tandberg D, Qualls C. Time series forecasts of emergency department patient volume. *Ann Emerg Med*. 1994;23:299-306.
- Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. *Nat Med*. 2022;28:31-8.
- Larrea N, García S, Miro O, Jacob J, Llorens P, Burillo-Putze G, et al. Predicting hospitalisation in older patients attended in the emergency department using classical and artificial intelligence mathematical strategies. *J Health Res*. 2025;39:262-73.
- Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25:44-56.
- 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.
- Collins GS, Moons KGM, Dhiman P, Riley RD, Beam AL, Van Calster B, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ*. 2024;385:e078378.
- Lyashevskaya O, Malone F, MacCarthy E, Fiehler J, Buhk J-H, Morris L. Class imbalance in gradient boosting classification algorithms: Application to experimental stroke data. *Stat Methods Med Res*. 2021;30:916-25.
- Gösgens M, Zhiyanov A, Tikhonov A, Prokhorenkova L. Good Classification Measures and How to Find Them. *Adv Neural Inf Process Syst*. 2021;34:29683-95.
- Sendak MP, D'Arcy J, Kashyap S, Gao M, Nichols M, Corey K, et al. A path for translation of machine learning products into healthcare delivery. *NPJ Digit Med*. 2020;4:9-15.
- Rodríguez-Pérez R, Bajorath J. Interpretation of machine learning models using shapley values: application to compound potency and multi-target activity predictions. *J Comput Aided Mol Des*. 2020;34:1013-26.

- 14 Van Calster B, McLernon DJ, van Smeden M, Wynants L, Steyerberg EW; Topic Group 'Evaluating diagnostic tests and prediction models' of the STRATOS initiative. Calibration: the Achilles heel of predictive analytics. *BMC Med.* 2019;17:230.
- 15 González Armengol JJ. La atención en urgencias y los pacientes en espera de cama de hospitalización como síntomas visibles del funcionamiento global de los sistemas sanitarios. *Emergencias.* 2025;37:323-5.
- 16 Larburu N, Azkue L, Kerexeta J. Predicting hospital ward admission from the emergency department: a systematic review. *J Pers Med.* 2023;13:849.
- 17 Hong WS, Haimovich AD, Taylor RA. Predicting hospital admission at emergency department triage using machine learning. *PLoS One.* 2018;13:e0201016.
- 18 Feretzakis G, Karlis G, Loupelis E, Kalles D, Chatzikyriakou R, Trakas N, et al. Using Machine Learning Techniques to Predict Hospital Admission at the Emergency Department. *J Crit Care Med (Targu Mures).* 2022;8:107-16.
- 19 Elvira Martínez CM, Fernández C, González del Castillo J, González-Armengol JJ, Villarroel P, Martín-Sánchez FJ. Modelo predictor de ingreso hospitalario a la llegada al servicio de urgencias. *An Sist Sanit Navar.* 2012;35:207-17.
- 20 Sitthiprawiat P, Wittayachamnankul B, Sirikul W, Laohavisudhi K. Development and internal validation of an AI-based emergency triage model for predicting critical outcomes in emergency department. *Sci Rep.* 2025;15:31212.
- 21 Estella A, Armengol de la Hoz MA, González del Castillo J, Grupo de trabajo INFURG-SEMES. Datos abiertos e inteligencia artificial: una ventana de oportunidad para pacientes sépticos en los servicios de urgencias. *Emergencias.* 2025;37:373-81.
- 22 Lopez Alcaraz JM, Strodthoff N. MIMIC-IV-Ext-MDS-ED: Multimodal Decision Support in the Emergency Department - a Benchmark Dataset for Diagnoses and Deterioration Prediction in Emergency Medicine (version 1.0.0). *PhysioNet.* 2024. RRID:SCR_007345. (Consultado 2 Noviembre 2025). Disponible en: <https://doi.org/10.13026/p90d-vd84>
- 23 Zheng Z, Luo J, Zhu Y, Du L, Lan L, Zhou X, et al. Development and Validation of a Dynamic Real-Time Risk Prediction Model for Intensive Care Units Patients Based on Longitudinal Irregular Data: Multicenter Retrospective Study. *J Med Internet Res.* 2025;27:e69293.
- 24 Van der Burgt R, Collins GS, Snell KIE, Altman DG, Riley RD. Dynamic models to predict health outcomes: current status and methodological challenges. *Diagn Progn Res.* 2018;2:23.
- 25 Cooksley TA, Collins GS, Ogundele A, Callaway A, Royston P, Rawles J, et al. Continual updating and monitoring of clinical prediction models: time for dynamic prediction systems? *Diagn Progn Res.* 2020;4:15.
- 26 López I, Zhang Z, Dong Y, Song J, Zhuang W, Jonnagaddala J, et al. Clinical entity augmented retrieval for clinical information extraction. *NPJ Digit Med.* 2025;8:45.
- 27 Chen TL, Chen JC, Chang WH, Tsai W, Shih MC, Wildan Nabila A. Imbalanced prediction of emergency department admission using natural language processing and deep neural network. *J Biomed Inform.* 2022;133:104171.
- 28 Castro-Delgado R, Pardo Ríos M. La inteligencia artificial y los servicios de urgencias y emergencias: debemos dar un paso adelante. *Emergencias.* 2024;36:145-7.
- 29 Ip W, Xenochristou M, Sui E, Ruan E, Ribeira R, et al. Hospitalization prediction from the emergency department using computer vision AI with short patient video clips. *NPJ Digit Med.* 2024;7:371.