



Artículo especial

Inteligencia artificial aplicada a los cuidados (II): algoritmos y aplicaciones

Artificial intelligence applied to care (II): algorithms and applications

Reyes Grangel^{a,*}, María Victoria Ibáñez Gual^b, Amelia Simó Vidal^b,
Juan Carlos Amengual Argudo^a y Óscar Belmonte Fernández^a

^a Grupo de Investigación en Aprendizaje Automático para Entornos Inteligentes, Departamento de Lenguajes y Sistemas Informáticos, Universitat Jaume I, Castellón de la Plana, España

^b Grupo de investigación Análisis de formas 2D y 3D, Aprendizaje Estadístico en Inteligencia Artificial, Estereología. Departamento de Matemáticas, IMAC, Universitat Jaume I, Castellón de la Plana, España



INFORMACIÓN DEL ARTÍCULO

Palabras clave:

Enfermería
Inteligencia artificial
Toma de decisiones
Algoritmos

Keywords:

Nursing
Artificial intelligence
Decision making
Algorithms

RESUMEN

En este artículo, como continuación de la primera parte, se presentan casos de aplicación de algoritmos y técnicas de aprendizaje automático y de minería de procesos aplicados a los cuidados. Se han seleccionado trabajos representativos de las técnicas presentadas en el primer artículo de este binomio, haciendo hincapié en los resultados obtenidos. Estos trabajos son aplicables al contexto español de cuidados.

ABSTRACT

As a continuation of the first part, this article presents case studies of application to healthcare of some machine learning and process mining methods and algorithms. We have selected some representative works of the techniques presented in the first article of this pair with a particular focus on the achieved results. These works are also relevant to the Spanish healthcare context.

Introducción

Este artículo muestra casos de aplicación de algunos de los diversos tipos de algoritmos de inteligencia artificial presentados por los mismos autores en el artículo anterior. A continuación se detallan los ejemplos que se presentan en cada sección.

En las secciones «Aprendizaje automático aplicado a la predicción de lesiones por presión» y «Aprendizaje automático aplicado a la estimación del coste sanitario por paciente» se presentan dos ejemplos de aplicación de técnicas de aprendizaje automático para, respectivamente, predecir la aparición de lesiones por presión en pacientes ingresados en una unidad de cuidados intensivos (UCI) y analizar la variabilidad en la estimación del coste de atención por paciente. En el primer caso se utilizan tres modelos de aprendizaje estadístico: regresión logística, árboles de decisión (*decision tree*) y bosques aleatorios (*random forest*). En el segundo, se emplean dos modelos: el primero es XGBoost, un modelo de aprendizaje estadístico que construye árboles de decisión de forma

secuencial, corrigiendo los errores de los anteriores; el segundo es una red neuronal estándar con cuatro capas ocultas.

La sección «Redes neuronales aplicadas al análisis de imágenes para el diagnóstico de Alzheimer» presenta un trabajo donde se utiliza una red neuronal convolucional para segmentar ciertas regiones de imágenes de resonancias magnéticas relacionadas con el diagnóstico de Alzheimer.

En la sección «*Deep learning* aplicado a la estimación de la probabilidad de reingreso» se presenta un ejemplo de aplicación de técnicas de *deep learning* o aprendizaje profundo: se emplea un gran modelo de lenguaje (LLM) basado en la arquitectura de una red neuronal profunda para hacer una estimación de la probabilidad del reingreso a 30 días de pacientes en un hospital a partir de la historia clínica electrónica.

La sección «Monitorización predictiva de procesos aplicada a la predicción de actividades y resultados en el proceso hospitalario» muestra un ejemplo de uso de técnicas de minería de procesos, concretamente en la monitorización predictiva de procesos, en primer lugar, para predecir posibles ingresos hospitalarios desde el servicio de urgencias como ejemplo de predicción del siguiente evento; y en segundo lugar, para predecir si un paciente puede ser tratado de manera segura en el

* Autor para correspondencia.

Correo electrónico: grangel@uji.es (R. Grangel).

<https://doi.org/10.1016/j.enfcli.2026.502485>

Recibido el 28 de noviembre de 2025; Aceptado el 9 de febrero de 2026

Disponible en Internet el 14 de marzo de 2026

1130-8621/© 2026 Los Autores. Publicado por Elsevier España, S.L.U. Este es un artículo Open Access bajo la licencia CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Árbol de decisión simulado para predicción de UP

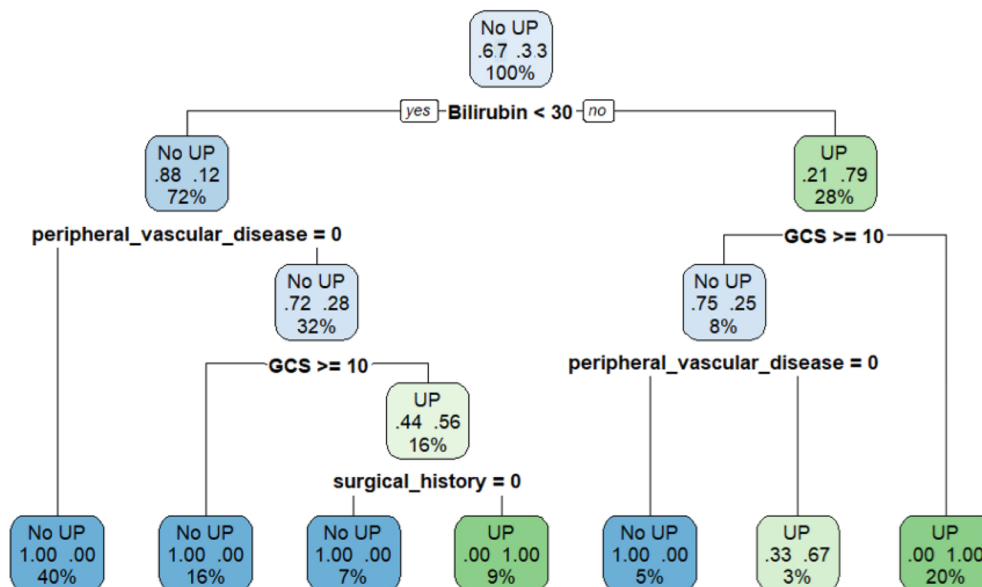


Figura 1. Ejemplo de árbol de decisión.

servicio de hospitalización a domicilio como ejemplo de predicción del resultado de la ejecución.

Finalmente, la sección «Conclusión» reflexiona acerca del potencial que tiene la aplicación de algoritmos, técnicas de aprendizaje automático y minería de procesos en el contexto de los cuidados y la atención sanitaria.

Aprendizaje automático aplicado a la predicción de lesiones por presión

Los métodos de aprendizaje automático más usados en el ámbito de la enfermería son la regresión logística^{1,2} (por su interpretabilidad y eficacia clínica), los bosques aleatorios y los árboles de decisión³ (por su robustez y capacidad explicativa). Como ejemplo, en Xu et al.⁴ puede consultarse un estudio de cohorte retrospectivo y observacional realizado con 618 pacientes ingresados en una UCI, en el que se utilizan y comparan estos tres métodos de aprendizaje automático con un objetivo común: desarrollar modelos para predecir la aparición de lesiones por presión en pacientes ingresados en la UCI:

- La regresión logística (LR) construye un modelo interpretable para calcular la probabilidad de aparición de una lesión por presión, que asigna un peso (coeficiente) a cada variable (factor de riesgo).
- Los árboles de decisión (DT) permiten crear un árbol con preguntas sucesivas sobre las variables clínicas (por ejemplo: «¿bilirrubina < 30? = riesgo alto de lesión por presión»), dividiendo a los pacientes en ramas según su riesgo. Es muy visual e interpretable, útil para entender patrones.
- Los bosques aleatorios (RF) se basan en construir muchos árboles de decisión (normalmente cientos) y promediar sus resultados para hacer una predicción más robusta y estable, identificando qué variables son más importantes para la predicción.

Antes de empezar a modelizar se identificaron 31 posibles factores de riesgo con una revisión de la literatura, incluyendo datos demográficos, causa de ingreso, parámetros de laboratorio, antecedentes médicos y escalas de valoración como Braden y Glasgow. Se recuperó la información de los pacientes en la historia clínica electrónica, creando en una base de datos, que se dividió en un conjunto de entrenamiento (*training*) y un

conjunto de prueba (*test*). En función de la naturaleza de las variables, se realizó un análisis descriptivo de la muestra y un análisis bivariante entre casos (pacientes que desarrollaron una lesión por presión) y controles (pacientes que no desarrollaron una lesión por presión). Aquellas variables que no devolvieron diferencias significativas entre ambos grupos se excluyeron de los modelos predictivos (por ejemplo, creatinina y hemoglobina).

Método 1. Regresión logística

Se realizaron tres análisis de regresión logística. El primero modelizó la probabilidad de sufrir lesión por presión. El segundo modelizó la probabilidad de sufrir una lesión con desarrollo temprano (en las 24 primeras horas de ingreso en la UCI, n = 53), y la tercera regresión modelizó la probabilidad de sufrir una lesión con desarrollo tardío (pasadas las 24 primeras horas de ingreso en la UCI, n = 153). Las variables significativas en todos los modelos (p < 0,05) formaron parte del modelo predictivo.

Se trata de modelos fácilmente interpretables. Por ejemplo, los valores obtenidos para los *odds ratios* (OR) indicaron que el riesgo de sufrir lesión por presión aumenta un 44% por cada año más de edad del paciente, un 42% para pacientes diabéticos vs no diabéticos o un 48% para pacientes con ictus vs sin ictus.

Métodos 2 y 3. Árboles de decisión y bosques aleatorios

El artículo no comenta con detalle los árboles de decisión ni los árboles aleatorios, aunque indica qué variables son significativas (factores de riesgo) en cada modelo. No obstante, la figura 1 presenta un ejemplo simulado de árbol de decisión que clasifica a los pacientes en dos categorías: «No lesión por presión» (no desarrollará úlcera por presión) y «Lesión por presión» (sí desarrollará úlcera por presión). Cada nodo del árbol presenta la etiqueta correspondiente a la clase más probable, junto con dos proporciones: el porcentaje de pacientes con esas características que no desarrolló lesión por presión, y el porcentaje que sí la desarrolló (por ejemplo, 0,67 y 0,33 indican que el 67% de los pacientes con esas características son No lesión por presión, y el 33% son Lesión por presión). El nodo raíz divide a los pacientes según si cumplen o no la condición Bilirubina < 30. A lo largo del árbol, si se cumple la condición, se avanza por la rama izquierda; si no se cumple, por la derecha.




Figura 2. Ejemplo de nomograma.

El árbol nos permite plantear preguntas sucesivas, y llegar a conclusiones como «En pacientes con bilirrubina alta, un Glasgow bajo (menor de 10) prácticamente garantiza el desarrollo de lesión por presión» o «Si la bilirrubina es baja (30) y no hay enfermedad vascular, lo más probable es que el paciente no desarrolle lesión por presión».

Una vez obtenidos los tres modelos, se comparó su poder predictivo en los pacientes del conjunto test, frente al poder predictivo de la escala de Braden sobre estos mismos pacientes y se obtuvieron mejores resultados con la regresión logística. Por último, recalcularon la regresión logística, añadiendo al modelo un nuevo factor de riesgo: el test de Braden y comprobaron que el modelo aumentó un poco más su poder predictivo.

El nomograma

Un nomograma es una representación gráfica del resultado del modelo de regresión logística, que permite estimar de forma visual la probabilidad de un suceso (en este caso, de desarrollar úlceras de presión). Al ajustar el modelo, cada variable obtiene un coeficiente β, que representa su peso en el riesgo. En este caso (fig. 2), el coeficiente más alto es el asociado a tener la máxima puntuación en el test de Braden, y a este factor se le asigna el máximo de puntos (en este caso 80). Los puntos en las demás variables se asignan en proporción a sus coeficientes relativos. Los puntos obtenidos por cada paciente en cada variable se suman y se transforman en una probabilidad, utilizando la función logística inversa. Así, según este nomograma, un paciente de más de 70 años (40 puntos), con diabetes (+ 25 puntos), que ha sufrido un infarto (+ 45 puntos), con Glasgow ≤ 8 (+ 47,5 puntos), con cirugías

previas (+ 60 puntos) y con una puntuación en el test de Braden de 5 (+ 80 puntos), suma en total 297,5 puntos, a lo que corresponde una probabilidad mayor del 80% de sufrir lesión por presión. Esta representación permite estimar de forma intuitiva y rápida la probabilidad de que ocurra un evento, como el desarrollo de una úlcera por presión, a partir de las características clínicas de un paciente.

Aprendizaje automático aplicado a la estimación del coste sanitario por paciente

Determinar el coste total de la atención médica y cuidados asistenciales recibidos por los pacientes en los hospitales resulta una tarea esencial a la hora de asegurar la sostenibilidad de los sistemas sanitarios⁵. En nuestro país, el coste de los cuidados y la atención de enfermería no se incluye a la hora de estimar el coste total por paciente. En otros países se incluye de manera limitada, especialmente en atención primaria⁶.

Por este motivo, Company-Sancho et al.⁷ realizaron un trabajo para determinar el impacto que los procesos y diagnósticos de Enfermería podrían tener en el cálculo del coste por paciente. Para ello, utilizaron la taxonomía establecida por NANDA (North American Nursing Diagnosis Association), NIC (Nursing Interventions Classification) y NOC (Nursing Outcomes Classification).

Básicamente, los autores midieron la capacidad de explicación de la variabilidad observada en un análisis multivariante para la predicción de la variable dependiente «coste total del paciente». Con este fin, se construyó un modelo de predicción para estimar el coste por paciente a partir de ciertos datos, comparando el resultado del modelo con la es-

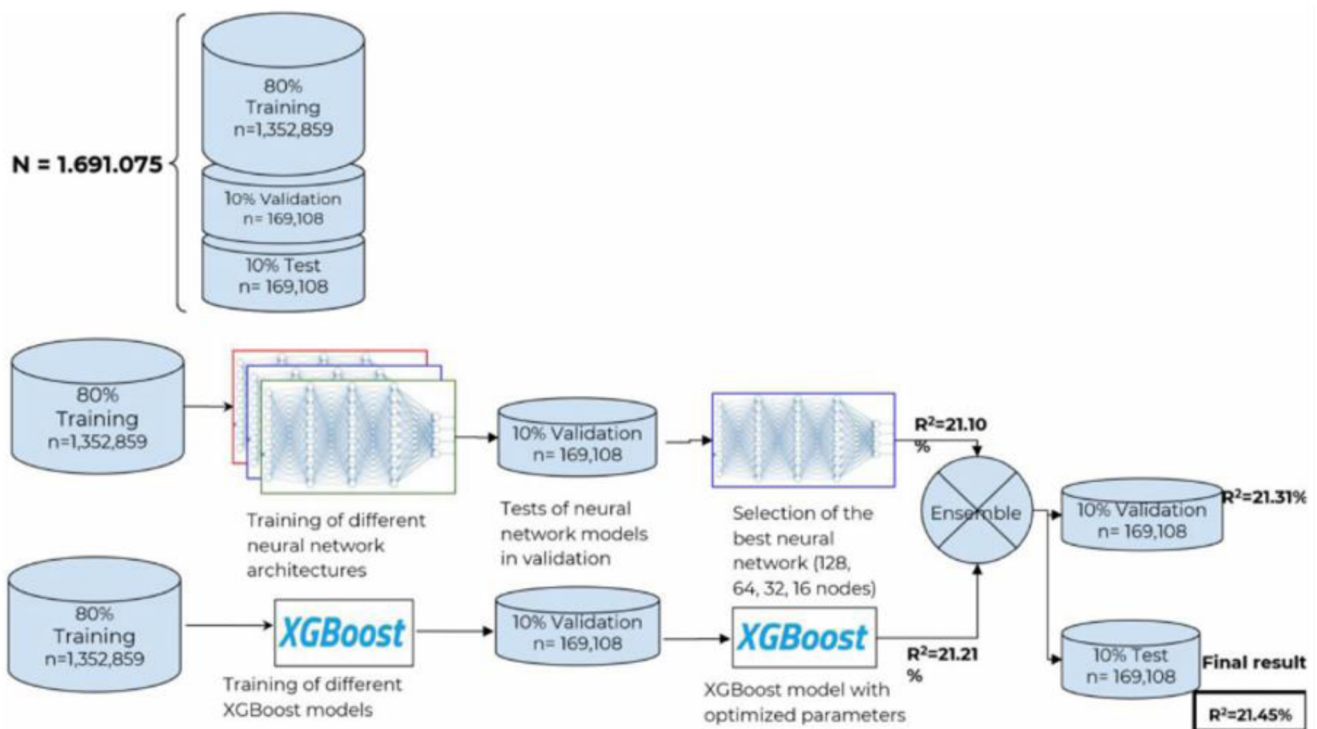


Figura 3. Secuencia de pasos seguidos en el análisis mediante aprendizaje automático.

Fuente: Company-Sancho et al.⁷ (2025).

timación real calculada del coste por paciente. El ajuste del modelo se estudió mediante el cálculo del error cuadrático medio (RMSE) y el coeficiente de determinación (R^2). Estos estadísticos indican lo bien que se ajusta el modelo predictivo a la estimación real, lo que da idea de cuánta variabilidad es imputable a los datos que se usaron en la construcción del modelo.

Para ello, se dispuso de un conjunto de datos de personas de más de 15 años con tarjeta sanitaria en el Servicio de Salud de las Islas Canarias ($n = 1.691.075$), convenientemente anonimizados. Se usaron los siguientes datos por paciente, extraídos de sus historiales médicos de atención primaria: edad, sexo y los datos correspondientes al proceso de enfermería (evaluación, diagnóstico, objetivos e intervenciones). La valoración se basó en los once patrones funcionales de Marjory Gordon, empleando cuatro categorías por patrón: Normal, Riesgo de alteración, Alterado y No evaluable. Para cada paciente de la muestra se realizó una estimación del coste calculado como la suma, durante el año 2018, de visitas y emergencias atendidas en hospitales públicos y de gestión mixta, así como hospitalizaciones, cirugías y coste de medicamentos adquiridos en farmacias. No todos los pacientes de la muestra tenían todos los datos: un 58% de la muestra tenía, al menos, algún dato asociado a enfermería (patrones funcionales, NANDA, NIC, NOC), pero solo un 2,74% tenía todos estos datos.

Para realizar el estudio, el 80% de la muestra se usó para realizar el entrenamiento de los modelos. Otro 10% se empleó para la validación y selección del mejor modelo. El 10% restante de la muestra se usó para realizar la prueba final con los modelos seleccionados.

La figura 3 muestra el proceso seguido. Para construir los modelos predictivos se emplearon, por un lado, redes neuronales y, por otro, modelos XGBoost, que combinan árboles de decisión (fig. 1) ensamblados de manera que cada uno de ellos corrige los errores del anterior. Para seleccionar tanto la mejor arquitectura de red neuronal como el mejor modelo XGBoost entre las diferentes opciones seleccionadas por los investigadores, se empleó el conjunto de datos de validación. Los resultados finales se obtuvieron alimentando los mejores modelos de ambas opciones con el conjunto de datos de prueba y calculando la media aritmética entre ambas estimaciones del coste total por paciente.

Se construyeron tres modelos de predicción empleando diferentes combinaciones de variables, obteniéndose, en la comparación entre el valor real del coste por paciente y el valor predicho por el modelo combinado, los valores:

- $R^2 = 11,47$, cuando se incluyó únicamente edad y sexo.
- $R^2 = 14,75$, cuando se incluyeron sexo, edad y patrones funcionales.
- $R^2 = 21,45$, cuando se incluyeron sexo, edad, patrones funcionales y NANDA-NIC-NOC.

Estos resultados evidencian que la utilización de los datos de patrones funcionales, NANDA, NIC y NOC influye notablemente en la estimación del coste total por paciente en los hospitales. Esto se hace aún más evidente si se tiene en cuenta el escaso número de pacientes (2,74%) que tiene informados todos estos datos relativos al proceso de atención y cuidados de Enfermería.

Redes neuronales aplicadas al análisis de imágenes para el diagnóstico de Alzheimer

El análisis de imágenes es uno de los campos en los que con mayor frecuencia se utilizan las redes neuronales convolucionales (CNN) dentro del paradigma de aprendizaje automático que se denomina aprendizaje profundo o *deep learning*. Son múltiples las aplicaciones del *deep learning* en el ámbito de la salud (detección de tumores, por ejemplo), aunque hemos elegido como ejemplo de aplicación el trabajo presentado en Chen et al.⁸

Este trabajo se centra en la aplicación de un modelo de CNN para mejorar el diagnóstico y los cuidados de la enfermedad de Alzheimer (EA) utilizando imágenes de resonancias magnéticas (RM). El objetivo de la investigación fue *segmentar* las imágenes de RM aplicando el modelo de CNN. Por segmentación entendemos, en este caso, asociar determinadas áreas de la imagen con ciertas características de la EA. Esto significa que la CNN está entrenada para identificar y delimitar regiones específicas dentro de las imágenes que son relevantes para el diagnóstico del Alzhei-

mer, asociando esas zonas con características o patrones indicativos de la enfermedad.

El modelo de CNN empleado tiene una capa de entrada, la capa de convolución, la capa de submuestreo y la capa de salida. La capa de convolución aplica una serie de filtros a la imagen de la RM para producir mapas de características: cada filtro generará un mapa de características diferente. Por ejemplo, puede haber un filtro específico por cada área de la RM que se desea analizar. El mapa de características produce un vector o secuencia numérica que caracteriza esa zona: por ejemplo, podría determinar el porcentaje en que el tono de color de un píxel es superior o inferior a un determinado umbral. Los mapas de características producidos por la capa de convolución se introducen en la capa de submuestreo, que reduce su dimensionalidad (número de elementos del vector o secuencia). Esta capa agrupa los valores por regiones o ventanas de un determinado tamaño (por ejemplo, 10 × 10 píxeles), produciendo una cantidad de valores numéricos que la representan (siempre muy inferior al número total de valores originales en la región). Siguiendo con nuestro ejemplo, la capa de submuestreo podría caracterizar una ventana con los valores máximo y mínimo de los porcentajes calculados.

La metodología empleada consistió en la selección de 18 pacientes con Alzheimer y 18 voluntarios sanos, como grupo de control. Se aplicó el modelo de CNN para segmentar las imágenes de RM de los pacientes y se compararon sus efectos de segmentación con otros dos modelos: una red neuronal *completamente* convolucional (FCNN) y un modelo basado en *Support Vector Machine* (SVM). La FCNN se diferencia de la CNN en que solo hay una capa intermedia que implementa la convolución (hay una capa de entrada, y la salida es la salida de las funciones de convolución). El segundo modelo se basa en la estimación de los parámetros de un conjunto de ecuaciones que definen hiperplanos que separan las muestras en clases diferentes: en este caso, segmentarían zonas de la imagen asociándolas con determinadas características de la EA. Los principales resultados de esta comparativa fueron:

- El modelo de CNN mostró una mayor precisión en la segmentación de las zonas de las RM relacionadas con la EA en comparación con los modelos FCNN y SVM.
- Se observó que el giro parahipocampal y el putamen eran más grandes en el grupo de control (sano).
- En el grupo de pacientes con Alzheimer, la amplitud de la fluctuación de baja frecuencia (ALFF) se correlacionó positivamente con la puntuación MMSE (*mini-mental state examination*) en el giro del cíngulo bilateral y el precúneo.

Tras el análisis de las imágenes de RM, se sacaron las siguientes conclusiones:

- La estructura de la materia gris está dañada en pacientes con Alzheimer.
- La ALFF del hipocampo y la homogeneidad regional están implicadas en el mecanismo de compensación neuronal del daño hipocampal.
- Cuando los cuidadores habían adoptado un método de enfermería activo con el paciente, se observaron menores daños en las zonas de las RM asociadas a la EA.

Por tanto, este trabajo destaca el potencial del modelo de CNN propuesto para una detección temprana y más precisa de la EA a través de la segmentación de imágenes de RM, lo que podría llevar a tratamientos y estrategias de manejo más efectivos.

Deep learning aplicado a la estimación de la probabilidad de reingreso

La historia clínica electrónica contiene una gran cantidad de información valiosa sobre procesos asistenciales tales como: síntomas, diagnósticos, resultados de radiología, actividades diarias, antecedentes

personales o evolución, entre otros. Además, se estima que el 80% de los datos sanitarios disponibles están en formato narrativo⁹. Sin embargo, las historias clínicas son datos no estructurados, de alta dimensionalidad y dispersión, lo que dificulta su uso en modelos de aprendizaje automático clínicos. Además, a diferencia de los textos estándar, se utilizan abreviaturas y jergas con una estructura gramatical particular. Estas características hacen que los textos clínicos sean especialmente interesantes para trabajar sobre ellos utilizando grandes modelos de lenguaje (LLM), a la par que complicados.

El trabajo presentado por Huang et al.¹⁰ muestra cómo utilizar un LLM sobre un conjunto de historias clínicas electrónicas para predecir la probabilidad de ingreso hospitalario de un paciente a 30 días. El modelo presentado, ClinicalBERT, se basa en la arquitectura de redes neuronales profundas BERT (*Bidirectional Encoder Representation from Transformers*), que a su vez, se basa en la arquitectura Transformer.

BERT fue desarrollado por Google¹¹ y fue entrenado con un corpus de textos basados en la Wikipedia y BookCorpus¹². Estos textos son generalistas y no contienen lenguaje clínico, por lo que los autores de ClinicalBERT reentrenaron el modelo BERT original con la base de datos *Medical Information Mart for Intensive Care III* (MIMIC-III)¹³. El proceso de reentrenamiento de una red neuronal profunda consiste en eliminar típicamente la capa de salida y sustituirla por una nueva capa cuyos pesos se van a calcular durante el reentrenamiento, y *congelar* el resto de capas para que el reentrenamiento no modifique los pesos de la red original. La idea base de este procedimiento es que las capas más internas de la red original, entrenadas sobre textos genéricos, ya conocen ciertas estructuras gramaticales que no hay que volver a entrenar, mientras que las últimas capas son las que están especializadas en detalles relativos al contenido particular del corpus con el que han sido entrenadas. A esta técnica se la conoce con el nombre de «transferencia de aprendizaje»¹⁴.

Una vez reentrenado el modelo, los autores presentan resultados experimentales comparando la capacidad predictiva del reingreso a 30 días a partir de los registros en la historia clínica electrónica de varios modelos, incluyendo a ClinicalBERT. Estos resultados muestran un mejor desempeño de ClinicalBERT frente al resto de los modelos.

Una característica interesante del modelo es su capacidad de refinar la predicción de reingreso a 30 días de manera incremental, es decir, el modelo realiza una predicción basándose en las notas clínicas disponibles y, a medida que se crean nuevas notas, el modelo refina su predicción teniendo en cuenta las nuevas notas. Otra característica interesante del modelo es que es capaz de indicar qué términos o frases específicas han tenido una mayor importancia en la predicción del reingreso a 30 días. De este modo, es posible verificar los resultados de la predicción por parte de personal especializado.

Finalmente, gracias al proceso de transferencia de aprendizaje es posible reentrenar ClinicalBERT con otras bases de datos de, por ejemplo, conjuntos de notas clínicas de otros hospitales, ya que el personal de cada hospital tiene una idiosincrasia propia en la toma de notas clínicas.

Monitorización predictiva de procesos aplicada a la predicción de actividades y resultados en el proceso hospitalario

La minería de procesos en el ámbito sanitario ha pasado de centrarse en la identificación de patrones de ejecución (*process discovery*), la verificación de protocolos (*conformance checking*) y la mejora continua (*enhancement*), a incluir técnicas de monitoreo predictivo de procesos que permiten anticipar eventos clínicos antes de que ocurran, como por ejemplo el riesgo de deterioro del paciente o la aparición de complicaciones. La capacidad predictiva resulta especialmente útil en entornos hospitalarios complejos donde se requieren decisiones rápidas y basadas en datos, aunque su adopción aún enfrenta retos como la alta variabilidad de los procesos y la existencia de datos en distintos niveles de abstracción¹⁵.

Las técnicas revisadas en la literatura, que incluyen enfoques basados en aprendizaje supervisado, modelos de series temporales y métodos híbridos, han demostrado ser efectivas en la predicción de resultados,

tiempos y riesgos dentro de procesos complejos¹⁶. Estas técnicas se agrupan principalmente en tres categorías: predicción del siguiente evento o su atributo, predicción del resultado final del caso, y predicción del tiempo restante hasta su finalización¹⁷.

Como ejemplo de la primera categoría en monitoreo de procesos, en Pasquadi bisceglie et al.¹⁸ se propone un enfoque, denominado LEGOLAS, para predecir ingresos hospitalarios desde urgencias, codificando las trazas del recorrido de los pacientes en urgencias mediante plantillas narrativas que capturan los eventos clínicos, superando así la limitación tradicional de asumir un único valor por categoría. El método se aplica en tres pasos. En primer lugar, se extraen las trazas etiquetadas de los pacientes en urgencias para transformarlas en historias de texto semánticas. En segundo lugar, aplica *fine-tuning* sobre modelos de lenguaje de gran tamaño (LLM) adaptados al dominio clínico mediante un corpus reducido de relatos semánticos. Evaluado sobre el registro MIMICEL, demuestra mejoras en precisión y anticipación de las predicciones respecto a métodos previos, especialmente en etapas tempranas, lo cual resulta clave para optimizar proactivamente los recursos hospitalarios. Finalmente, integra un módulo XAI *post-hoc* para explicar cómo cada parte de la narrativa de la historia de texto tiene un efecto en las decisiones del LLM.

En la categoría del resultado de la ejecución, en Aringhieri et al.¹⁹ se muestra un enfoque para predecir si un paciente puede ser tratado de manera segura en su domicilio, dentro del servicio de hospitalización a domicilio, a partir de los datos recogidos en urgencias. Para ello, transforma el historial clínico de cada paciente en una secuencia de eventos, siguiendo el enfoque típico de los registros de procesos. Además, usa herramientas de monitoreo predictivo que implementa enfoques basados en algoritmos de aprendizaje automático, los cuales se pueden utilizar para entrenar un modelo predictivo capaz de aprender las correlaciones entre las variables que describen los datos del paciente, los exámenes que ha realizado (características) y la hospitalización en casa o en otra sala del hospital. Una parte clave del enfoque es la conversión de diagnósticos escritos en lenguaje natural a códigos estandarizados (en este caso, CIE-9-CM), lo que permite estructurar mejor la información para el modelo. Finalmente, se evalúa rigurosamente la calidad de las predicciones mediante métricas estadísticas adecuadas.

Conclusión

El análisis resumido del conjunto de trabajos seleccionados que se han mostrado en este artículo demuestra el gran potencial que presentan las técnicas de aprendizaje automático (destacando el *deep learning* como método más reciente) y la minería de procesos en el contexto de la atención sanitaria y cuidados a los pacientes. Todavía queda un amplio camino por explorar en este sentido: por ejemplo, se podrían usar técnicas de aprendizaje no supervisado (*clustering*) para establecer tipologías de pacientes en función de valoraciones de enfermería, lo que podría ayudar a establecer pautas específicas de cuidados en función de las características de los pacientes. También, los modelos predictivos (regresión, por ejemplo) y las redes neuronales podrían emplearse para estimar con cierta antelación (24-48 horas) potenciales empeoramientos de pacientes basándose en la evolución tanto de ciertas constantes clínicas como de las valoraciones de enfermería, lo que contribuiría a mejorar la atención hospitalaria. Por último, es indudable el potencial que presentan las técnicas de minería de procesos para predecir posibles desviaciones en el proceso de hospitalización, que podrían reforzar la toma de decisiones en un sistema de alertas tempranas con redes neuronales o modelos de regresión, contribuyendo, en parte, a explicar el porqué de una alerta sobre un paciente.

Financiación

Este trabajo está parcialmente financiado por la Universitat Jaume I a través de la red temática multidisciplinar de colaboración en investigación e innovación NursIA – *Nursing and healthcare system innovation*

through artificial Intelligence Applications. La entidad financiadora no ha intervenido en el diseño, en el desarrollo ni en la redacción del manuscrito.

Consideraciones éticas

El presente estudio se basa en el análisis de literatura científica publicada. No ha implicado la participación de personas ni el uso de datos clínicos o personales, por lo que no ha requerido la evaluación ni la aprobación de un Comité de Ética de la Investigación.

Consentimiento informado

Por la naturaleza del estudio no se incluye la participación de sujetos ni el uso de datos individuales, por lo que no ha sido necesario obtener consentimiento informado.

Protección de datos

Este trabajo no ha utilizado datos personales ni información identificable de pacientes.

Declaración sobre el uso de inteligencia artificial

Los autores declaran que se han utilizado herramientas de inteligencia artificial generativa únicamente como apoyo en tareas de mejora lingüística. Los autores han revisado y validado íntegramente el contenido final y asumen plena responsabilidad sobre el mismo.

Contribución de los autores

Todos los autores cumplen los criterios internacionales de autoría científica. Han contribuido de forma sustancial a la concepción del trabajo, análisis de la literatura, redacción y revisión crítica del manuscrito, y han aprobado la versión final para su publicación.

Conflicto de intereses

Los autores declaran no tener ningún conflicto de intereses.

Bibliografía

- Olowe KJ, Edoh NL, Zouo SJC, Olamijuwon J. Comprehensive review of logistic regression techniques in predicting health outcomes and trends. *World J Adv Pharm Life Sci*. 2024;7:16–26, <http://dx.doi.org/10.53346/wjapls.2024.7.2.0039>.
- Shipe ME, Deppen SA, Farjah F, Grogan EL. Developing prediction models for clinical use using logistic regression: an overview. *J Thorac Dis*. 2019;11(Suppl 4):S574–S584, <http://dx.doi.org/10.21037/jtd.2019.01.25>.
- Brnabic A, Hess LM. Systematic literature review of machine learning methods used in the analysis of real-world data for patient-provider decision making. *BMC Med Inform Decis Mak*. 2021;21:54, <http://dx.doi.org/10.1186/s12911-021-01403-2>.
- Xu J, Chen D, Deng X, et al. Development and validation of a machine learning algorithm-based risk prediction model of pressure injury in the intensive care unit. *Int Wound J*. 2022;19:1637–1649, <http://dx.doi.org/10.1111/iwj.13764>.
- Walker RM, Boyne GA, Brewer GA. *Public Management and Performance: Research Directions*. Cambridge: Cambridge University Press; 2010, <http://dx.doi.org/10.1017/CBO9780511760587>.
- Laport N, Sermeus W, Vanden Boer G, van Herck P. Adjusting for nursing care case mix in hospital reimbursement. *Policy Polit Nurs Pract*. 2008;9:94–102, <http://dx.doi.org/10.1177/1527154408319696>.
- Company-Sancho MC, González-Chordá VM, Orts-Cortés MI. The nursing process and total health cost variability: an analysis using machine learning. *BMC Nurs*. 2025;24:738, <http://dx.doi.org/10.1186/s12912-025-03304-5>.
- Chen X, Li L, Sharma A, Dhiman G, Vimal S. The application of convolutional neural network model in diagnosis and nursing of MR imaging in Alzheimer's disease. *Interdiscip Sci Comput Life Sci*. 2022;14:34–44, <http://dx.doi.org/10.1007/s12539-021-00450-7>.
- Martin-Sanchez F, Verspoor K. Big data in medicine is driving big changes. *Yearb Med Inform*. 2014;23:14–20, <http://dx.doi.org/10.15265/IY-2014-0004>.
- Huang K, Altosaar J, Ranganath R. ClinicalBERT: modeling clinical notes and predicting hospital readmission. En: *Proceedings of the ACM Conference on Health, Inference and Learning (CHIL)*; 2020, <http://dx.doi.org/10.48550/arXiv.1904.05342>.

11. Devlin J, Chang MW, Lee K, Toutanova K. BERT: pre-training of deep bidirectional transformers for language understanding. *Proc NAACL-HLT*. 2019;4171–4186, <http://dx.doi.org/10.18653/v1/N19-1423>.
12. Zhu Y, Kiros R, Zemel R, et al. Aligning books and movies: towards story-like visual explanations by watching movies and reading books. *IEEE International Conference on Computer Vision (ICCV)*. 2015;11:19–27, <http://dx.doi.org/10.1109/ICCV.2015.11>.
13. Johnson AEW, Pollard TJ, Shen L, et al. MIMIC-III, a freely accessible critical care database. *Sci Data*. 2016;3:160035, <http://dx.doi.org/10.1038/sdata.2016.35>.
14. Howard J, Ruder S. Universal language model fine-tuning for text classification. *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics*. 2018;1:328–339, <http://dx.doi.org/10.18653/v1/P18-1031>.
15. Muñoz-Gama J, Martín N, Fernández-Llatas C, et al. Process mining for healthcare: characteristics and challenges. *J Biomed Inform*. 2022;127:103994, <http://dx.doi.org/10.1016/j.jbi.2022.103994>.
16. Márquez-Chamorro AE, Resinas M, Ruiz-Cortés A. Predictive monitoring of business processes: a survey. *IEEE Trans Serv Comput*. 2018;11:962–977, <http://dx.doi.org/10.1109/TSC.2017.2772256>.
17. Di Francescomarino C, Ghidini C. Predictive process monitoring. En: *Process Mining Handbook*. Springer; 2022, http://dx.doi.org/10.1007/978-3-031-08848-3_10.
18. Pasquadibisceglie V, Appice A, Malerba D, Fiameni G. Leveraging a large language model to predict hospital admissions of emergency department patients. *Expert Syst Appl*. 2025;287:128224, <http://dx.doi.org/10.1016/j.eswa.2025.128224>.
19. Aringhieri R, Boella G, Brunetti E, et al. Leveraging structured data in predictive process monitoring: the case of ICD-9-CM in home hospitalization. *CEUR Workshop Proceedings*. 2021:48–60 <https://ceur-ws.org/Vol-3060/paper-6.pdf>.