



TRABAJO DE FIN DE GRADO DE ENFERMERÍA

REVISIÓN BIBLIOGRÁFICA: IMPLEMENTACIÓN DE INTELIGENCIA ARTIFICIAL PARA LA PREVENCIÓN Y ANÁLISIS DE ÚLCERAS POR PRESIÓN

ALUMNO: RODRIGO SANSERONI COMAS
TUTORES: ANDRÉS PÉREZ MELERO, MARÍA DE LA LUZ CAPOTE TOLEDO

ÍNDICE

ÍNDICE.....	2
ABREVIATURAS	3
RESUMEN	4
ABSTRACT.....	4
PALABRAS CLAVE	4
INTRODUCCIÓN	5
JUSTIFICACIÓN	5
MARCO TEÓRICO	6
ORIGEN DE LA INTELIGENCIA ARTIFICIAL	6
MACHINE LEARNING	7
DEEP LEARNING.....	8
ULCERAS POR PRESIÓN	9
OBJETIVOS	11
OBJETIVO GENERAL	11
OBJETIVOS ESPECÍFICOS	11
METODOLOGÍA.....	12
RESULTADOS.....	13
ANÁLISIS DE IMAGEN	13
SENSORES	14
MODELOS PREDICTIVOS.....	14
DISCUSIÓN: el futuro de la inteligencia artificial y las úlceras por presión	16
ANÁLISIS DE IMAGEN	16
SENSORES	19
MODELOS PREDICTIVOS.....	21
PERSPECTIVAS GENERALES.....	24
CONCLUSIONES.....	26
ANEXOS	27
BIBLIOGRAFIA	30

ABREVIATURAS

- **UPP** (úlceras por presión)
- **EPUAP** (del inglés European Pressure Ulcer Advisory Panel)
- **GNEAUPP** (Grupo Nacional para el Estudio y Asesoramiento en Úlceras por Presión y Heridas Crónicas)
- **IA** (inteligencia artificial)
- **ML** (del inglés Machine Learning)
- **SVM** (del inglés Support Vector Machine)
- **KNN** (K Nearest Neighbor)
- **DT** (Decision Tree)
- **ANN** (del inglés Artificial Neural Network)
- **DL** (del inglés Deep Learning)
- **CNN** (del inglés Convolutional Neural Network)
- **NPUAP** (del inglés National Pressure Ulcer Advisory Panel)
- **PAN** (del inglés Pressure Injury Alliance)
- **LR** (del inglés Linear Regression)
- **RF** (del inglés Random Forest)

RESUMEN

El desarrollo de úlceras por presión es un problema evitable que tiene lugar fundamentalmente en centros hospitalarios con consecuencias considerables tanto para los individuos que las sufren como para el sistema sanitario. La inteligencia artificial ha surgido como una alternativa a los métodos tradicionales de apoyo al juicio clínico que realizan las enfermeras para la prevención, diagnóstico y tratamiento de estas lesiones. Al ser un campo de estudio innovador, nuevos artículos son publicados cada poco tiempo y son necesarias revisiones que reúnan la evidencia reciente. El objetivo de este trabajo es analizar las aplicaciones de la inteligencia artificial en la prevención y el diagnóstico de úlceras por presión y discutir sus fortalezas y limitaciones.

Para ello se ha realizado una revisión bibliográfica narrativa de los estudios publicados en los últimos cuatro años, incluyéndose un total de 23 artículos. Se han identificado tres áreas de investigación: análisis de imagen, procesamiento de información de sensores y sistemas predictivos. Los algoritmos son capaces de establecer relaciones complejas entre grandes cantidades de factores de riesgo para predecir quiénes desarrollarán lesiones y de segmentar y analizar los tejidos de una úlcera de forma precisa a través de una imagen. De esta manera la inteligencia artificial ha demostrado en condiciones experimentales poseer las cualidades necesarias para erigirse como nueva herramienta de asistencia enfermera en la prevención y análisis de úlceras por presión. Sin embargo, son necesarios más estudios que respalden su uso y superen las limitaciones a las que se enfrenta.

ABSTRACT

The development of pressure ulcers is a preventable problem that occurs primarily in hospital settings with considerable consequences for both the individuals who suffer from them and the healthcare system. Artificial intelligence has emerged as an alternative to traditional methods of supporting nurses' clinical judgement in the prevention, diagnosis and treatment of pressure ulcers. As an innovative field of study, new articles are published every few years and reviews are needed to bring together recent evidence. The aim of this paper is to analyse the applications of artificial intelligence in the prevention and diagnosis of pressure ulcers and to discuss its strengths and limitations.

A narrative literature review of the studies published in the last four years was carried out, including a total of 23 articles. Three areas of research were identified: image analysis, sensor information processing and predictive systems. Algorithms are able to establish complex relationships between large numbers of risk factors to predict who will develop lesions and to accurately segment and analyse ulcer tissues from an image. In this way, artificial intelligence has demonstrated in experimental conditions the necessary qualities to emerge as a new tool to aid in the prevention and analysis of pressure ulcers. However, further studies are needed to support its use and overcome the limitations it faces.

PALABRAS CLAVE

Inteligencia Artificial, Úlcera por Presión, Pressure Ulcer, Artificial Intelligence.

INTRODUCCIÓN

JUSTIFICACIÓN

El Grupo Nacional para el Estudio y Asesoramiento en Úlceras por Presión y Heridas Crónicas (GNEAUPP) define las UPP (úlceras por presión) como “lesiones de origen isquémico localizadas en la piel y/o tejidos subyacentes, principalmente sobre una prominencia ósea, como resultado de la presión, o la presión en combinación con fuerzas de cizalla; pudiendo aparecer también sobre tejidos blandos sometidos a presión externa por diferentes materiales o dispositivos sanitarios”(1).

La prevención de la aparición de UPP es reconocida como un estándar de calidad de atención enfermera, y el tratamiento de este tipo de lesiones es también competencia en su gran mayoría de los profesionales enfermeros. Sin embargo, según los últimos datos disponibles (del año 2022) proporcionados por el GNEAUPP que contó con la muestra más amplia y representativa de hospitales públicos y residencias españolas, la prevalencia de UPP es de un 6,05 % (2). Este tipo de lesiones se originan fundamentalmente durante la estancia en hospitales y otras instituciones médicas, por lo que insisten en la importancia de mejorar la calidad asistencial y centrar los esfuerzos sanitarios en la prevención.

A pesar de tener conocimiento sobre la aplicación de escalas para valoración de riesgo y de ser formadas en la terapéutica de estas lesiones, las enfermeras siguen encontrando dificultades para enfrentarse a este problema evitable que genera consecuencias negativas tanto en el individuo como en el sistema sanitario: dolor, infecciones, disminución de la calidad de vida, prolongación de estancias hospitalarias y aumento del gasto hospitalario son algunos de los efectos de las UPP (3).

Por ese motivo, actualmente la industria médica está desarrollando nuevos recursos que apoyen el trabajo de las enfermeras, entre ellos los basados en IA (inteligencia artificial). Las altas capacidades que demuestra esta tecnología en tareas como la interpretación de imágenes o la realización de predicciones (4) abren un abanico de renovadas oportunidades en la prevención y análisis de lesiones por presión que ya es contemplado por instituciones de referencia internacional como la EPUAP (del inglés European Pressure Ulcer Advisory Panel) (3).

Al tratarse de una aplicación emergente por la IA que parece prometedora y poco explorada, recientemente se están realizando múltiples proyectos alrededor del mundo que tratan de desarrollar los mejores algoritmos, sistemas, bases de datos y aplicaciones. En la carrera por la búsqueda de los mejores resultados nuevos estudios aparecen cada año, por lo que son necesarias revisiones que sintetizen y analicen la evidencia disponible desde un punto de vista crítico, considerando las ventajas y limitaciones que ofrece la inteligencia artificial.

Con el propósito de comprender el estado de la cuestión y de dar luz sobre conocimientos generales de un campo que para la enfermería ha resultado ser hasta ahora ajeno, se considera conveniente exponer de forma breve e introductoria los distintos tipos de inteligencia artificial, sus relaciones y funcionamiento. Además, se expondrá de manera también breve la información más actualizada disponible de UPP.

ORIGEN DE LA INTELIGENCIA ARTIFICIAL

Resulta complejo definir el concepto de IA teniendo en cuenta que el término de inteligencia humana también presenta dificultades a la hora de ser descrito con precisión, pero la Comisión Europea (5), reuniendo la bibliografía existente, concluye que la IA engloba aquellos sistemas capaces de percibir el entorno, procesar información, y tomar decisiones orientadas a la consecución de tareas específicas. Por lo tanto, se trata de programas informáticos que ejecutan actividades similares a las realizadas por el ser humano, como el aprendizaje, el razonamiento, la creatividad o la capacidad de hacer planes y predicciones.

Al alejarse del debate filosófico que se abre al pensar si características tan propiamente humanas como el pensamiento, el razonamiento o la creatividad podrían ser emuladas o no por ordenadores, trataremos de entender la IA desde un punto de vista pragmático. Por lo tanto, cuando hablemos de IA, sistemas de aprendizaje automático, algoritmos u otros sinónimos nos referiremos a todos aquellos dispositivos capaces de percibir su entorno para tomar decisiones enfocadas a la consecución de un objetivo determinado de la forma más exitosa posible (6).

La IA nace con el objetivo de reproducir, complementar o mejorar el trabajo de los seres humanos en áreas que albergan cierta complejidad (7). Para lograrlo ha sido necesario recorrer casi un siglo de avances tecnológicos partiendo de los primeros modelos que trataban de simular a través de un ordenador las funciones de la neurona humana.

En 1943 Warren McCulloch y Walter Pitts describieron el primer modelo de neurona artificial (modelo MCP). De igual manera que una neurona biológica dispone de unas dendritas que reciben información, un soma que la procesa, y un axón que la trasmite; la neurona MCP recibía información (inputs), la procesaba, y devolvía otra información (outputs) (7).

Más tarde, en 1958 de la mano de Frank Rosenblatt se mejoró la neurona MCP para dar lugar al Perceptrón, neurona que conforma la base de la mayoría de redes neuronales modernas (7). Como se muestra en el *Anexo 1*, en este caso a cada input o información de entrada (x) se le asigna un peso (w) que indica su importancia relativa con respecto al resto de entradas. Realizando una suma ponderada que se compara con un límite de activación se produce un output o salida en forma de 0 o 1 dependiendo de si la suma supera o no el límite. El output o información que se recibe se analiza para ver si se ajusta a nuestros objetivos, y en caso de que no sea así, se modifican los pesos hasta lograr el resultado esperado (6–9).

Sin embargo, las tareas que podían realizar los modelos simples de aquella época eran muy limitadas (7,9) y es que al igual que en el ser humano, la capacidad cognitiva no reside en la unidad de la neurona sino en la conectividad de todas ellas formando el complejo entramado que llamamos tejido nervioso. Las expectativas creadas eran altas pero el poder computacional del que se disponía no era suficiente y el progreso se frenaba, por lo que no sería hasta más tarde cuando se vería un resurgir de las inteligencias artificiales con lo que se conoce como Machine Learning (7).

MACHINE LEARNING

El ML (Machine Learning) es una rama de la IA que trata de reproducir la forma en la que los seres humanos aprendemos de la experiencia con el objetivo de mejorar nuestros resultados en la realización de tareas (10). Esta tecnología emplea algoritmos para extraer información de grandes cantidades de datos y la procesa sin necesidad de haber sido explícitamente programada para ello para después reconocer patrones, clasificar los datos y realizar predicciones (11)

Distinguimos 3 tipos de ML (10):

- El *aprendizaje supervisado* precisa que entrenemos a la máquina proporcionando ejemplos para el input que vayan asociados a respuestas o valores determinados en el output. El objetivo es lograr la relación deseada entre inputs y outputs en una primera fase de entrenamiento para posteriormente generalizar esas relaciones con datos nuevos, permitiendo por ejemplo hacer predicciones.
En el ámbito de las UPP podría entrenarse un modelo que, empleando datos históricos de factores de riesgo y eventos anteriores de úlceras, permitiese determinar el riesgo de sufrir una UPP que puede tener un paciente recién hospitalizado.
- En el *aprendizaje no supervisado* el sistema es capaz de detectar patrones en la información que proporcionamos sin la necesidad de enlazar los inputs con respuestas concretas, siendo útil en la extracción de características comunes de un gran grupo de elementos.
Con este tipo de ML podrían recopilarse datos sobre la distribución de la presión en colchones o cojines a través de sensores de presión, que posteriormente podrían ser agrupados para indicar áreas de riesgo para el desarrollo de UPP.
- El *aprendizaje reforzado* guarda similitudes con el condicionamiento operante descrito por Skinner (12), de modo que describimos las acciones que el sistema tiene permitido realizar en un determinado entorno y dejamos que busque las soluciones óptimas a través de ensayo y error tratando de conseguir la mayor recompensa posible.
Este tipo de ML permitiría, por ejemplo, determinar y ajustar el tratamiento más beneficioso para pacientes que están sufriendo una UPP considerando eventos previos y las respuestas que el individuo va mostrando a lo largo del tiempo. Podrían optimizarse no solo las curas, sino las terapias nutricionales o los cambios posturales.

Las características del ML hacen que sea una tecnología con un gran número de aplicaciones gracias a su capacidad para clasificar, analizar, recomendar, predecir y diagnosticar (6). En el ámbito médico estas características han abierto su uso a la predicción de enfermedades y desenlaces, a la ayuda en la toma de decisiones, y al manejo de grandes cantidades de datos de pacientes (13).

Como se ha mencionado antes, para poder realizar todas estas tareas la tecnología se basa en distintos algoritmos: SVM (Support Vector Machine), KNN (K Nearest Neighbor), DT (Decision Tree) ... cada uno de los cuales puede emplearse par distintas tareas (8,11). Sin embargo, dentro de todos ellos el más complejo y de más interés debido a sus potenciales aplicaciones son las redes neuronales artificiales o ANNs (Artificial Neural Networks) (8).

Hacia 1990 la capacidad de procesamiento de los ordenadores aumentó, así como la posibilidad de almacenar datos a costes menores, lo que permitió el desarrollo de las ANNs (7). Su complejidad varía en función de la red, pero la estructura básica es la misma y su funcionamiento es muy similar al del tejido nervioso: disponemos de información de entrada e información de salida que es procesada por una red de neuronas. Cada neurona forma un nodo, que actúa como

una unidad de intercambio de información. Entre cada conexión de neuronas o sinapsis se transmitirá la información si se alcanza el umbral de activación que, como se mencionó antes, dependía de la intensidad de la señal. La señal es modificable a través del peso, por lo que se irá ajustando a medida que el algoritmo aprende según los resultados que se quieran obtener (10).

En las redes neuronales artificiales las neuronas se organizan en capas, teniendo un comúnmente tres: una capa de entrada que recibe la información (por ejemplo, fotos de UPP), una capa de salida que produce el resultado (por ejemplo, la clasificación del estadio de la UPP) y una capa intermedia que realiza las operaciones matemáticas y establece las relaciones no lineales (una relación no lineal es una relación compleja en la que se tienen en cuenta distintas variables; por ejemplo, aunque un coche vaya a una determinada velocidad la hora a la que llegue a su destino dependerá también de otros factores como los semáforos o el tráfico, que deben tenerse en cuenta si se quiere crear una relación no lineal) entre las otras dos capas (10).

El número de nodos de la red neuronal, sus características y el número de capas intermedias, también llamadas capas ocultas, determinará la complejidad de la red. Cuando se habla de SVM, KNN, DT y otros algoritmos, así como de redes neuronales de un máximo de 3 capas se hace referencia a ML superficial, pero al introducir más de una capa oculta en la red se estará hablando entonces de ML profundo o Deep Learning (9). En el *Anexo 2* se ilustran los distintos tipos de ML.

DEEP LEARNING

El DL (Deep Learning) es una rama del ML cuyo interés ha crecido desde el año 2000 al haber permitido avances importantes en campos en los que la comunidad científica se encontraba estancada, especialmente en el reconocimiento de imágenes y de lenguaje(9,14). Aunque el Machine Learning superficial puede resolver ciertos problemas de manera rápida y eficiente, presenta limitaciones al enfrentarse a la complejidad del mundo real como en el reconocimiento de objetos reales, voces humanas o vídeos (9).

Entre sus puntos fuertes destaca que el DL supera otra de las principales dificultades a las que se enfrentaba el ML superficial: el procesamiento de datos naturales en bruto (datos que no han sido procesados, analizados o interpretados, que se encuentran en su forma original). Gracias a la complejidad del algoritmo, no es necesario modificar la información antes de proporcionársela al sistema, sino que puede alimentarse con los datos tal cual se reciben (14). La IA será capaz de extraer automáticamente las características importantes. Esto es especialmente relevante en el procesamiento de imágenes y texto al tratarse de archivos que contienen gran cantidad de información en bruto.

La forma más común de ML (profundo o no) es el ML supervisado (15). Como se ha mencionado antes, en estos sistemas habrá una primera fase en la que se asocian los inputs a los outputs según nuestros objetivos con información conocida de entrenamiento. Posteriormente, cuando se introduzcan datos nuevos, el sistema será capaz de ejecutar las tareas para las que lo hemos entrenado. Si se quisiese por ejemplo crear un sistema que clasificase el tipo de tejido que presenta una úlcera, debería en primer lugar conseguirse una gran cantidad de imágenes de úlceras clasificadas según el tejido que tienen. Durante el entrenamiento se mostraría a la máquina una imagen que respondería con un output en forma de vectores con una puntuación, correspondiendo cada puntuación a un tipo de tejido distinto. Al no haber entrenado al sistema, difícilmente la respuesta será la correcta. Se crearía entonces una función objetivo que midiese el error entre la puntuación de salida y la esperada para que la máquina ajustase los pesos, reduciendo el error. En una red neuronal profunda pueden encontrarse cientos de millones de

imágenes y pesos (15), por lo que su aplicabilidad en el ámbito médico y enfermero es muy amplia.

La arquitectura básica del DL consiste en redes neuronales complejas con múltiples capas ocultas de procesamiento no lineal dentro de las cuales encontramos cientos o miles de neuronas. Las capas cercanas a la capa de input procesan y aprenden las características más sencillas, mientras que las características complejas son procesadas en capas cercanas al output (6). Más adelante se explicará cómo los programadores emplean este tipo de estructura a su favor eliminando solo algunas capas de redes neuronales existentes para introducir capas nuevas, de modo que no necesitan entrenar a los sistemas desde cero, partiendo de lo que ya tienen aprendido. En función del tipo de input y el objetivo de la red, se establecen distintos tipos de DL (14).

Las CNNs (del inglés Convolutional Neural Networks) o redes neuronales convolucionales son un tipo de red neuronal profunda que ha sido empleado con éxito en la detección, segmentación y reconocimiento de objetos y regiones de imágenes desde el principio de los años 2000 (15), siendo actualmente una de las tecnologías con mayor proyección para el análisis de voz e imagen (9).

En las CNNs las imágenes serán entendidas como un conjunto de píxeles y el aprendizaje se realizará de forma jerárquica. Por ejemplo, la primera capa de la red procesará características básicas como pueden ser la presencia y localización de bordes y esquinas, la segunda localizará aristas, la tercera unirá los diseños para identificar la correspondencia con objetos conocidos, y así sucesivamente hasta formar características complejas (15). Posteriormente, las características que se han generado de forma automática tras el entrenamiento del algoritmo se emplearán para reconocer de forma predictiva objetos en nuevas imágenes (10).

ULCERAS POR PRESIÓN

Para añadir una definición de UPP a la anteriormente citada de la GNEAUPP, en la última actualización disponible de 2019 de la Guía de Práctica Clínica elaborada por la EPUAP, la NPUAP (National Pressure Ulcer Advisory Panel) y la PAN (Pressure Injury Alliance) (3), la lesión por presión se define como “un daño localizado en la piel y/o los tejidos subyacentes, como resultado de la presión o presión en combinación con cizallamiento”.

Cuando hablamos de presión hacemos referencia a la fuerza que actúa de forma perpendicular a la piel provocando el aplastamiento del tejido entre dos planos duros, siendo normalmente la prominencia ósea del paciente y la superficie sobre la que se encuentra apoyado los planos entre los que se ejercerá la presión. Por otro lado, en el cizallamiento la fuerza se ejercerá de forma paralela, de modo que los tejidos externos se mantienen adheridos a la superficie y los internos se desplazan sobre estos ejerciendo fricción (1,3).

Las lesiones por presión suelen ocurrir sobre una prominencia ósea, aunque esta no es un elemento necesario. La úlcera se producirá por la carga mecánica persistente sobre tejidos débiles, pudiendo también estar ocasionada por dispositivos médicos u otros objetos (3). La GNEAUPP define las UPP relacionadas con dispositivos sanitarios como “*lesiones localizadas en la piel o tejidos subyacentes como resultado de una presión sostenida y causada por un dispositivo sanitario diagnóstico o terapéutico*” (1).

Su importancia radica en que se cree que se corresponden con 1 de cada 3 lesiones por presión. La dificultad de su terapéutica se objetiva, por un lado, en la ausencia de escalas de valoración adecuadas para estas lesiones, y por otro, en que la retirada del dispositivo que las ocasiona no

es viable en muchas ocasiones debido a la enfermedad del paciente. La valoración del riesgo y la implementación de acciones preventivas y de tratamiento dependerán por tanto del juicio de la enfermera (1).

Cuando hablemos de UPP hacemos referencia a lesiones provocadas por presiones de diferente intensidad sostenidas en el tiempo y no a grandes cargas aplicadas en un momento puntual (3). Según la GNEAUPP la presión de oclusión capilar máxima es de 20 mmHg, de manera que si ejercemos una presión superior en una zona determinada durante un tiempo prolongado distintos mecanismos fisiopatológicos comenzarán a degenerar el tejido (1).

La forma en la que las células son afectadas por las cargas que producen la lesión constituye un proceso complejo en el que intervienen distintos factores como el tejido en el que se produce y sus propiedades, el tipo de fuerza, la intensidad y su distribución (3). Puede afirmarse que la deformación celular continua generada por la presión produce daños en las células y los tejidos, ya sea perjudicando a la propia célula, alterando la microcirculación y restringiendo la llegada de oxígeno y nutrientes, obstruyendo el drenaje linfático de sustancias de desecho, o produciendo inflamación y edema. Todo ello conduce a isquemia, hipoxia, disminución del aporte de nutrientes e imposibilidad de eliminación de desechos metabólicos. La disminución de nutrientes y la acumulación de restos produce un ambiente ácido extracelular con la consecuente muerte de la célula y tejidos (3).

La susceptibilidad del tejido de sufrir una lesión por presión depende del tipo de paciente, estando determinada por factores internos o intrínsecos (relacionados con el estado de salud del paciente) y externos o extrínsecos (relacionados con el entorno o dependientes del paciente y el cuidador) (16).

Los factores internos se corresponden con las características del individuo y la tolerancia de sus tejidos a las fuerzas que pueden producir una lesión, que dependerá tanto del tipo de tejido afectado como de su capacidad de reparación (3). A lo largo de la vida las particularidades de los tejidos cambian (morfología, tolerancia, características mecánicas...) como consecuencia de la edad, la nutrición, la hidratación, las enfermedades... debiéndose tener esto en cuenta a la hora de valorar el riesgo de un paciente. Por ejemplo, en las personas de edad avanzada o aquellas con una lesión del sistema nervioso central encontraremos una disminución de la densidad capilar además de inflamación crónica en los tejidos, por lo que la tolerancia y capacidad de recuperación serán menores (3).

Dentro de los factores intrínsecos que más deben considerarse según la GNEAUPP (1) encontramos la edad, la toma de medicación (sedantes, diuréticos, benzodiazepinas, corticoides...) los trastornos vasculares o de transporte de oxígeno, las alteraciones cognitivas y nutricionales, las incontinencias o neuropatías, y la movilidad reducida como principal causa (3) entre otras.

Los factores externos engloban todos aquellos elementos del entorno que pueden ser controlados y modificados como la intensidad y duración de la compresión o la fricción (3), humedad, sujeciones mecánicas, dispositivos sanitarios, hábitos tóxicos (tabaquismo y alcohol), entorno social de riesgo o formación inadecuada de los cuidadores (1).

Uniendo ambos factores, la EUPAP establece distintas poblaciones de riesgo sobre las que el personal de enfermería debe prestar especial atención, como son los pacientes en unidades de críticos (debido a la inestabilidad hemodinámica, escasa perfusión, inmovilidad...); lesionados de médula espinal (debido a la inmovilidad, alteraciones de la sensibilidad y fisiopatológicas); pacientes en cuidados paliativos (por sus múltiples alteraciones orgánicas); población pediátrica

(por su piel frágil escasamente desarrollada); personas institucionalizadas o pacientes sometidos a largas operaciones (por la inmovilidad en las superficies duras del quirófano) (3).

En cuanto a la categorización de las lesiones, a pesar de que existen distintos sistemas de clasificación que presentan variaciones (17), nos atenemos al empleado en nuestra región geográfica. De este modo la GNEAUPP, EUPAP y NPUAP coinciden en un sistema de clasificación en función de la profundidad de la úlcera (*Anexo 3*), de modo que se encuentran las siguientes categorías (1,3,17):

- Categoría I. Eritema no blanqueable: la piel se encuentra intacta, pero con enrojecimiento no blanqueable en un área determinada sobre una prominencia ósea. Puede ser difícil de identificar en personas de piel oscura. Puede indicar que la persona presenta riesgo de sufrir una lesión.
- Categoría II. Úlcera de espesor parcial: se pierde la continuidad de la dermis, presentado una úlcera superficial abierta con un lecho de la herida rosado y sin esfacelos. El lecho es brillante o seco sin esfacelos o hematomas. La flictena es otra forma de presentación de esta categoría.
- Categoría III: Pérdida total del espesor de la piel: se pierde todo el grosor de la piel, pudiendo haber tejido subcutáneo visible, pero sin exposición de huesos, músculos o tendones. Puede haber esfacelos, cavitaciones o tunelizaciones.
- Categoría IV: Pérdida total del espesor de los tejidos: se exponen el músculo, tendones o huesos, siendo estos últimos susceptibles de infectarse. A menudo se observan cavitaciones y tunelizaciones.

Al margen de estas cuatro categorías, la NPUAP propone dos tipos distintos de úlceras: aquellas que no se pueden clasificar debido a que el tejido esfacelado o necrótico cubren la lesión y no resulta posible objetivar la profundidad; y la posible lesión de tejidos profundos, donde se observaría un área de la piel de color púrpura o marrón o una ampolla llena de sangre debido a la lesión de los tejidos blandos, pero sin pérdida de la continuidad, por lo que desconoce el daño en capas inferiores (1).

OBJETIVOS

OBJETIVO GENERAL

Analizar las aplicaciones de la inteligencia artificial en la prevención y diagnóstico de las úlceras por presión en el ámbito de la enfermería.

OBJETIVOS ESPECÍFICOS

- Describir el funcionamiento básico de las tecnologías de inteligencia artificial más relevantes en el contexto de la prevención y diagnóstico de las UPP.
- Analizar las posibilidades de aplicación actual de inteligencia artificial en la prevención y diagnóstico de las úlceras por presión.
- Contrastar los métodos tradicionales de prevención y diagnóstico con los basados en inteligencia artificial según sus fortalezas y limitaciones.

Para la realización de este trabajo y cumplimentación de los objetivos anteriormente descritos se ha propuesto una búsqueda bibliográfica en bases de datos de carácter científico-médico (Pubmed, Cinhal, Web of Science y Cochrane library) empleado los descriptores MeSH “pressure ulcer”, “artificial intelligence”, “nurse” y “nursing”. Se emplearon términos en inglés debido a la mayor amplitud de resultados.

Con el fin de reunir la información más actualizada posible y teniendo en cuenta que se trata de un campo de investigación emergente, se acotó la búsqueda a los artículos publicados del año 2020 en adelante. Posteriormente fueron seleccionados los estudios según la medida en la cual su título y su abstract se adecuaba a los objetivos propuestos. Finalmente, como último criterio de exclusión, se descartaron aquellos artículos con menor índice de impacto en Journal Citation Reports (JCR).

Al margen de esta búsqueda, se tomaron como válidos para la discusión los artículos y guías clínicas más actualizadas disponibles en la web del GNEAUPP y del EPUAP, al ser consideradas las instituciones de referencia a nivel nacional y europeo respectivamente en lo que atañe a UPP.

Además, con el fin de ampliar información sobre IA para garantizar una comprensión mínima de este campo de conocimiento fue necesario acudir a otras bases de datos de carácter no médico (Springer Link, IEE Xplore y Google Scholar) con el objetivo referenciar definiciones y conceptos. Se emplearon criterios de inclusión más laxos, aceptando aquellos artículos publicados a partir del año 2000 y cuyo contenido satisficiera el motivo de búsqueda.

RESULTADOS

Tras la búsqueda y selección de los artículos según los criterios definidos en el apartado de metodología, se procedió a su análisis. Del total de 23 artículos (n=23), se identificaron tres líneas fundamentales de investigación en base al uso que se le proporcionaba a la IA: análisis de imagen (n=11), procesamiento de información procedente de sensores (n=3) y modelos predictivos (n=9),

Con la finalidad de lograr una mayor comprensión de cada una de las líneas de investigación, se presentarán los resultados por cada uno de los grupos definidos.

ANÁLISIS DE IMAGEN

En el estudio realizado por Silva et al. (18) se combinaron distintos algoritmos de ML para medir el área de piel afectada por UPP, logrando un 96% de exactitud en la medición de las 105 imágenes de prueba. Liu et al. (19) también emplearon una CNN para segmentar y medir el área de lesiones por presión. Al comparar su precisión con métodos tradicionales de medida obtuvieron un error relativo medio del 26,2%.

En otro estudio, el mismo Liu et al. (20) desarrolló un software para cuidadores informales que pretendía detectar la presencia de eritema y necrosis en UPP. La red logró un 99,4% de exactitud en clasificación de eritema y un 94,8% en clasificación de necrosis. También Lau et al. (21) desarrollaron una aplicación para móvil con el objetivo de asesorar a cuidadores informales, logrando un 63,3% de precisión en clasificación de úlceras.

Por otro lado, en el estudio realizado por Zoppo et al. (22) se creó un dispositivo portátil (Wound Viewer) que analizaba no solo las dimensiones sino también el tipo de tejido, para después clasificar las úlceras. Incluía lesiones por presión, vasculares y de pie diabético. En pruebas prospectivas logró un 96% de concordancia a la hora de clasificar con el diagnóstico realizado por médicos. Sakakibara et al. (23) entrenaron un algoritmo para determinar la presencia de necrosis en lesiones por presión, logrando un 100% de correspondencia con la opinión médica tomada de referencia en 24 imágenes de prueba.

Swerdlow et al. (24) emplearon una CNN para segmentar y clasificar úlceras, fallando en la categorización de 9 imágenes en una prueba final con 124. Seo et al. (25) lograron clasificar UPP con una exactitud del 91% con su algoritmo, comparando el desempeño de la máquina con el de enfermeras con distintos grados de experiencia. Este tipo de prueba también fue realizada por Kim et al. (26) que comparó el desempeño de su CNN con 24 participantes (médicos, enfermeras y estudiantes), logrando una exactitud máxima del 79,3% frente al 50,1% de los participantes.

En la revisión sistemática realizada por Zahia et al. (27) se discute la viabilidad de los sistemas de diagnóstico de úlceras no invasivos, y las características que estos deben reunir. Concluyen que las ventajas que proporciona el DL frente a otras tecnologías es la razón de su creciente uso por los investigadores. Por último, Ohura et al. (28) emplearon su red convolucional entrenada con 356 imágenes de UPP para la segmentación de otro tipo de lesiones, logrando una exactitud del 98,1% en las 40 fotografías de prueba.

SENSORES

En un estudio publicado en 2023 por Stern et al. (29) se comparó el desempeño de redes convolucionales en la diferenciación de tres posturas distintas (izquierda, derecha y supina) adquiridas en una cama a través de mapas de calor capturados por una esterilla que se posicionaba sobre el colchón. Se emplearon distintos modelos 2D (AlexNet, ResNet-18, GoogleNET y ShuffleNet) y 3D, todos ellos preentrenados con la base de datos ImageNet (base de datos de imágenes que contiene más de un millón de archivos).

De los 13 sujetos estudiados se obtuvieron un total de 182 posturas, logrando una exactitud mayor del 97% con el modelo 3D y del 99% con el modelo 2D (ResNet y ShuffleNet mostraron los mejores resultados) en la clasificación.

En el estudio llevado a cabo por Matar et al. (30) se trató de diferenciar además de las tres posturas mencionadas anteriormente, la prona. Esta postura es difícil de distinguir de la posición supina, de modo que en muchos estudios se excluye para garantizar mayor precisión y mejores resultados. Para la medición se emplearon sensores textiles de presión localizados debajo de las sábanas. La información fue procesada por una FFANN (Feed Forward Artificial Neural Network), un tipo de red neuronal. La precisión en identificación de posturas fue de un 97,9%.

Por último, Gruenerbel et al. (31) aplicaron sensores portátiles a un grupo de 60 pacientes que monitorizaban de forma continua la presión, temperatura y saturación de oxígeno de la zona susceptible de lesión para cada individuo. El sensor demostró proporcionar medidas fiables al compararse los datos con los recogidos por las enfermeras. A través de ML se relacionaron los tres parámetros, mostrando correlación entre los aumentos de presión y temperatura y descenso de la saturación. En una segunda parte del estudio se buscó desarrollar un algoritmo que en base a cambios en estos valores avisase de que debía realizarse un cambio postural de forma profiláctica. El sistema de alarma se desarrolló de forma exitosa basándose en los datos de un único paciente que sufrió una úlcera en el transcurso del estudio.

MODELOS PREDICTIVOS

Lee et al. (32) extrajeron mediante ML los factores que determinaban el riesgo de UPP en 60 residencias coreanas incluyendo 57 variables, tanto individuales como administrativas, logrando inferir con un 84,3% de precisión que el tiempo dedicado a cada residente o la proporción de encamados por centro eran factores decisivos. Chun et al. (33) realizaron su investigación en población pediátrica, y además de buscar factores predictores entrenaron un algoritmo para pronosticar la evolución de UPP estadio I en los 7 próximos días. Su exactitud fue de un 82%.

En el estudio realizado por Lusting et al. (34) se desarrolló un algoritmo que detectaba la probabilidad de desarrollar una lesión de tejidos profundos en el talón a partir de medidas diarias de la humedad subepidérmica. Lograron un 79% de exactitud, y programaron otro algoritmo que predijese el riesgo de que la lesión se produjese al día siguiente, con un 77% de exactitud. Un estudio similar al realizado por Dweekat et al. (35), que trataron de predecir no sólo quién sufriría UPP sino cuándo, estableciendo riesgo alto (en menos de 7 días) o medio (en más de 7 días). Los resultados fueron del 74,7% y 75% de capacidad de predicción respectivamente.

Por su parte, Anderson et al. (36) tomaron una muestra de 18.893 pacientes quirúrgicos y extrajeron 2 años de datos clínicos para predecir el riesgo de desarrollar una lesión por presión. La exactitud empleando RF (del inglés *Random Forest*) fue de un 99%. Song et al. (37) trataron también de elaborar una herramienta de predicción con una muestra de pacientes tanto hospitalarios como domiciliarios, logrando una exactitud del 91% y 85% respectivamente.

En las revisiones sistemáticas realizadas por Tehrany et al. (38), Toffaha et al. (39) se determinó que los algoritmos de ML más empleados para la predicción de UPP son LR (del inglés *Linear Regression*) y RF, logrando de forma conjunta una capacidad de predicción mayor del 80% del desarrollo de lesiones en unidades de cuidados intensivos (38). Por otro lado, Pei et al. (40) realizaron un metaanálisis que concluyó que los modelos de ML incluidos en su estudio predijeron correctamente el 79% de los pacientes que desarrollarían UPP y el 87% de los que no, a pesar de que una gran proporción de los estudios (88,9%) tenía alto riesgo de sesgo.

DISCUSIÓN: EL FUTURO DE LA INTELIGENCIA ARTIFICIAL Y LAS ÚLCERAS POR PRESIÓN

ANÁLISIS DE IMAGEN

Una parte fundamental del diagnóstico y tratamiento de las UPP consiste en la valoración de la propia lesión. Existen métodos tradicionales para la medición del área y la profundidad de las heridas, así como escalas que permiten clasificar, estandarizar y ver la evolución de las úlceras. La clasificación de las lesiones facilita el desarrollo de planes de cuidados, la selección de tratamientos y la comunicación entre profesionales, además de mejorar la calidad metodológica de los estudios sobre úlceras y permitir la comparación de datos entre instituciones (3).

Las formas de medir tradicionales pueden resultar invasivas. El progreso de la IA en el procesamiento, análisis e interpretación de imágenes ha permitido el desarrollo de algoritmos que son capaces tanto de medir superficies como de clasificar según categorías preestablecidas, ofreciendo una alternativa a estos métodos invasivos. Además, al tratarse de inteligencias automáticas ofrece una potencial asistencia de primera línea para la clasificación de las lesiones, donde los resultados podrían obtenerse de manera confiable al instante.

La rama de la IA especializada en el análisis de imágenes son las redes neuronales convolucionales (CNN). En su revisión sistemática Zahia et al. (27) resaltan sus múltiples aplicaciones en otras áreas biomédicas y su reciente comienzo en el análisis de UPP. Demuestran una gran capacidad en el reconocimiento y segmentación de imágenes, pero su auge se debe especialmente a que son capaces de aprender factores a los que algoritmos pasados presentaban demasiada sensibilidad como el ángulo de la cámara, la luz, la distancia al objetivo... De los estudios incluidos en la revisión, 8 de 10 (19–22,24–26,28) emplearon redes convolucionales y tan solo 2 (18,23) emplearon algoritmos distintos (algoritmos de ML).

Para interpretar una imagen, el algoritmo debe ejecutar distintas tareas por separado: segmentación, medida, clasificación y evaluación. Puede realizar una de ellas, combinaciones o todas, en función de su complejidad. La segmentación consiste en determinar los límites de la herida, separándola del resto de la imagen. La medida consiste en el análisis de la superficie y/o profundidad, pudiendo ser en dos dimensiones o tres. La clasificación consiste en determinar la presencia o cantidad de distintos tejidos, o categorización según criterios establecidos. Por último, la evaluación consiste en monitorizar el proceso de curación (27).

Para que la IA realice estas funciones de interpretación no es suficiente con que identifique el conjunto de píxeles que constituyen la úlcera, sino que tiene que ser capaz de reconocer que esos píxeles unidos constituyen una úlcera. Para ello se emplea la fase de entrenamiento. Las imágenes escogidas para el entrenamiento son a menudo seleccionadas de las bases de datos de cada centro (26), lo que limita en cierta medida la validez externa y la posibilidad de generalizar el uso de los algoritmos a pesar de los buenos resultados internos que pueden llegar a lograr.

El proceso de selección y etiquetado (*labelling*) de las imágenes es uno de las mayores preocupaciones de los expertos (27). Consiste en unir el input que introducimos a la máquina (la foto de la úlcera) con el output que deseamos (por ejemplo, la clasificación en estadio). El inconveniente que presenta es la necesidad de tiempo por parte de los profesionales a lo largo de todo el proceso de etiquetado. Algunos estudios como el de Kim et al. (26) o el de Seo et al. (25) afirman que para el correcto aprendizaje de una clase se necesitan entre 150 y 500

imágenes, entendiendo una clase como una rama de la clasificación. Esto implicaría demandar el tiempo de profesionales para clasificar todas esas imágenes. El número de imágenes de entrenamiento en los estudios seleccionados fue variado, desde las 50 empleadas por Sakakibara et al. (23) a las 2.754 empleadas por Seo et al. (25).

Los programadores han diseñado diferentes técnicas para superar este inconveniente, reduciendo la necesidad de disponer de profesionales sanitarios especializados durante grandes cantidades de tiempo, a menudo cirujanos plásticos o enfermeras especialistas (20,23–26). El uso de estas técnicas, que a continuación se explicarán, es otra de las principales ventajas que ofrece el DL frente al ML, ya que corresponden únicamente a los sistemas de aprendizaje profundo (27). Las dos técnicas utilizadas son el aprendizaje por transferencia (*transfer learning*) y el aumento de datos (*data augmentation*), empleados en 5 de los artículos revisados (19,20,24–26).

El aprendizaje por transferencia consiste en aprovechar un sistema que ha adquirido conocimientos al ser entrenado para una tarea determinada para mejorar el rendimiento en otra tarea. Por ejemplo, si disponemos de un sistema con conocimientos capaz de identificar superficies cutáneas y heridas, puede aplicarse ese conocimiento al estudio de úlceras. En este caso, muchos de los autores dispusieron de modelos preentrenados en Imagenet, una base de datos que contiene más de 14 millones de fotos etiquetadas (19,20,25,26,28). Esto reduce considerablemente la complejidad que conlleva entrenar un modelo capaz de reconocer los elementos presentes en una imagen, porque no se está entrenando desde cero, sino sobre conocimientos ya asentados.

Por otro lado, el aumento de datos resulta útil para mejorar la consistencia del modelo y evitar escasez de datos o desequilibrios en las muestras, de modo que, por ejemplo, si se disponen de menos imágenes de úlceras estadio I que del resto, pueden aumentarse los datos de esa clase (19–21,24–26). Se logra a través de un mecanismo sencillo que consiste en realizar pequeñas modificaciones a las imágenes de las que ya se dispone como rotarlas, voltearlas o crear zooms. De esta manera se obtienen imágenes nuevas con las que entrenar al sistema sin la necesidad de una persona que las categorice de nuevo. Es una solución que los investigadores emplean también ante la falta de bancos de imágenes de úlceras amplios y de calidad (27).

Una vez se dispone de un algoritmo entrenado, se prueba con las imágenes de testeo previamente apartadas de las imágenes de entrenamiento, o se introducen imágenes nuevas. La mayoría de estudios fueron retrospectivos (18,20,23–26), de modo que emplearon imágenes de archivo. Este tipo de estudios resultan útiles para determinar qué algoritmos son más efectivos en función de nuestros objetivos, probar la utilidad de los sistemas y servir como base para el desarrollo de nuevos programas, pero son difícilmente generalizables en contextos reales por su carácter retrospectivo y experimental.

Sin embargo, también se han encontrado estudios prospectivos que permiten acercarnos al funcionamiento y resultados que cabría esperar en situaciones reales. Por ejemplo, Zoppo et al. (22) desarrollaron un dispositivo portátil que medía las úlceras, su composición y las clasificaba. Fotografiaron 150 úlceras, 50 de las cuales eran por presión, y la clasificación proporcionada por el sistema concordó en un 96% con la proporcionada por profesionales. Lau et al. (21) realizaron una prueba prospectiva con su aplicación de teléfono sobre 10 imágenes de úlceras pegadas sobre la piel para probar el reconocimiento del sistema, y se clasificaron bien 8 de ellas (teniendo en cuenta que era una herramienta para cuidadores informales). Liu et al. (19) realizaron mediciones de la superficie de las úlceras de 20 pacientes que acudieron a su hospital tanto de la forma tradicional (rotulando sobre un papel cuadriculado) como con el sistema automático.

Solo encontraron problemas en la medición de dos lesiones debido a la escasez de imágenes de entrenamiento.

Unida a la elaboración de estudios prospectivos debe ir el desarrollo de dispositivos portátiles que lleven incorporados los algoritmos de interpretación automática. La implantación clínica real de la IA será posible cuando vaya unida a herramientas portátiles y funcionales, con interfaces sencillas y manejables que no entorpezcan el trabajo, sino que lo faciliten. El Wound Viewer, por ejemplo, cumple estas características (ver *Anexo 4*), y fue diseñado con el objetivo de apoyar en el diagnóstico rápido aquellos profesionales que realizan asistencia domiciliaria (22). Otros autores apuestan por el desarrollo de aplicaciones que puedan ser instaladas en los teléfonos móviles. Esto supondría una disminución de costes (al no tener que comprar dispositivos nuevos especializados) y un aumento de la accesibilidad (abriendo paso a la creación de aplicaciones tanto para profesionales como para cuidadores informales).

Dentro de los artículos incluidos en esta revisión tres de trabajaron la aplicabilidad directa de sus algoritmos en *smartphones*. Esto no quiere decir que puedan encontrarse sus aplicaciones disponibles para uso público, pero sí que se ha logrado la compatibilidad con teléfonos. Por ejemplo, YOLOv4 es una aplicación diseñada para móviles que detecta y clasifica las lesiones en tiempo real destinada a personal no cualificado (21). Fue probada en un entorno real con distintas condiciones ambientales y distintos dispositivos, logrando una exactitud de clasificación del 80 al 90%. Por otro lado, Liu et al. (20) desarrollaron un software para cuidadores que determina la necesidad de ir a buscar atención hospitalaria en función de la presencia de eritema y la cantidad de necrosis de la lesión. Compararon el desempeño del algoritmo con tres cirujanos plásticos por separado, logrando identificar con mayor precisión la presencia de eritema. En el estudio previamente mencionado de Liu et al. (19) en el que se segmentaba y medía el área de UPP de forma automática, se empleó DL y tecnología LiDAR (presente en muchos teléfonos móviles y tabletas).

El hecho de que un algoritmo sea compatible con *smartphones* y pueda ser llevado al usuario implica que se adapte a las condiciones cambiantes de las imágenes que se toman fuera de condiciones experimentales y que no son manipuladas. La tecnología debe ser capaz de distinguir adecuadamente la úlcera del resto de elementos de la imagen y proporcionar medidas confiables, además de adaptarse a los distintos tipos de luz, ángulos y distancias (21,27). El DL está mostrando resultados prometedores en la resolución de estos problemas (27).

Una de las grandes cuestiones que puede surgir es si ante los resultados favorables que muestra la IA en la interpretación de imágenes a pesar de su reciente aplicación para el estudio de UPP, será posible que sustituya a la enfermera en estas funciones en un futuro próximo. Para ello resulta interesante la comparación que hacen muchos estudios entre el desempeño de profesionales y desempeño de algoritmos. Como se ha mencionado antes, Liu et al. (20) compararon su algoritmo de detección de eritema y necrosis con tres cirujanos plásticos, logrando el primero mejores resultados en la identificación de eritema, y similares en necrosis. Seo et al. (25) realizaron la comparación entre dos enfermeras de distinta experiencia y su algoritmo de clasificación de úlceras, obteniendo precisiones mayores que la profesional con 5 años de experiencia y ligeramente menores que la profesional con 19 años de experiencia (84, 91 y 93% de precisión respectivamente). Por último, Sakakibara et al. (23) contrastaron el desempeño de 8 dermatólogos residentes, 8 enfermeras con menos de 5 años de experiencia y 8 estudiantes médicos de final de año con su red convolucional de clasificación. Se observó que la IA obtuvo mejores resultados en la mayoría de clasificaciones, pero no solo eso, sino que redujo el grado de desacuerdo entre los profesionales cuanto trabajaron apoyados por esta

herramienta. La precisión también se vio disminuida en un 16,7% cuando el algoritmo fallaba en su predicción.

En base a estos resultados no se puede generalizar que actualmente la IA sea más precisa que los sanitarios en el análisis de UPP. Debe tenerse en cuenta que el nivel de conocimiento de cada individuo es subjetivo, y que para las comparaciones no se emplearon situaciones reales con asistencia in situ, sino que simplemente se confrontó la categorización de imágenes. Sin embargo, si puede afirmarse que los resultados generales obtenidos por la IA son alentadores, y que incorporada al criterio médico o enfermero puede resultar en una mejora de sus funciones.

Los algoritmos siempre presentarán limitaciones que deberán ser compensadas con el juicio clínico de la enfermera. La valoración de una úlcera no implica únicamente el sentido de la vista, sino que otros elementos como la temperatura de la piel, la cantidad y olor del exudado u otros síntomas concomitantes que refiera el paciente también deben tenerse presentes en el diagnóstico y tratamiento. Por ejemplo, la máquina es capaz de determinar la presencia de eritema, pero no de distinguir un eritema blanqueable de uno no blanqueable, que determinará el diagnóstico de una úlcera estadio I. Por otro lado, todo aquello que no capte la imagen no puede ser analizado, por ello se ha visto en los artículos revisados la limitación en la interpretación de úlceras cavitadas, senos de drenaje y espacios muertos profundos (19,20).

Independientemente de la precisión de la IA, estas herramientas siempre actuarán como un sistema de ayuda en la interpretación de úlceras y no como un sustituto de la actividad enfermera. Abren la posibilidad a la monitorización no invasiva, evitando manipulaciones en el lecho de la herida que pueden producir dolor e infecciones (27). Pueden identificar y cuantificar zonas eritematosas, infectadas, necróticas y de granulación además de realizar mediciones y clasificaciones. Todo ello permite obtener diagnósticos certeros y datos precisos sobre el estado de curación (22), sentando la base para cuidados individualizados y basados en la evidencia.

SENSORES

Como se ha descrito en la introducción del presente trabajo, la mayoría de lesiones por presión se producen por la presión mantenida en el tiempo sobre prominencias óseas u otras superficies duras. Como consecuencia de la compresión se reducen el aporte de oxígeno y nutrientes, se deforman las células y se desencadenan procesos inflamatorios que acaban con su destrucción. Este proceso fisiopatológico hace que la monitorización de la postura corporal resulte un área de investigación prometedora. La premisa es que, si mediante sensores logran detectarse las distintas posturas corporales y las áreas sometidas a una mayor carga, podrán establecerse cambios posturales adaptados a cada paciente.

En su artículo, Gruenerbel et al. (31) mencionan que la aparición de úlceras por presión no es consecuencia de la falta de conocimientos, sino de la falta de recursos temporales, económicos y humanos. Si bien es cierto que la formación de una úlcera es un proceso multifactorial, la propia EPUAP (3) indica en su guía clínica que por definición: sin presión mantenida en el tejido no puede haber UPP.

Excluyendo los casos en los que la movilización precoz no es posible ya sea porque el enfermo se encuentra al cargo de un cuidador informal que carece de los medios o conocimientos necesarios o ya sea porque la movilización resulta imposible, muchas de las lesiones por presión podrían prevenirse. A pesar de ser conscientes de la sencillez de esta medida, el porcentaje de

UPP hospitalarias se sigue manteniendo alto, y es responsabilidad de las enfermeras y enfermeros.

La sobrecarga de trabajo, los altos ratios de pacientes por cada profesional, la necesidad de más personal o la falta de tiempo pueden ser factores que motiven la desatención de los cambios posturales por parte de las enfermeras. El desarrollo de sistemas capaces de determinar cuándo un paciente está manteniendo una postura durante un tiempo prolongado pudiendo comprometer el estado de su piel y capaces además de enviar un aviso a la enfermera para que esa postura se cambie, aumentaría la conciencia sobre el cambio postural.

Actualmente, las posturas que los pacientes adquieren en la cama son detectadas mediante cámaras de infrarrojos o dispositivos portátiles. Si bien han sido métodos empleados hasta ahora, presentan ciertos inconvenientes. Por ejemplo, las cámaras infrarrojas son muy sensibles a los cambios ambientales (como movimientos o temperatura), además de suponer un obstáculo en cuanto a la privacidad del paciente. Por otro lado, los dispositivos portátiles pueden resultar incómodos, resultando en una posible disminución de la adherencia terapéutica o en alteraciones de patrones funcionales como el sueño (30).

Hasta el momento en el que se realiza este trabajo se tiene constancia de que en los estudios que tratan de identificar la postura corporal en la cama, los investigadores se encuentran con la dificultad de separar la postura prona de la supina debido al parecido que existe entre ambas (30). La solución por la que se opta es o bien por ignorar por completo la postura prona o bien incluirla dentro de la clasificación como supina, como es el caso del estudio realizado por Stern et al. (29). A pesar de ello, pueden encontrarse estudios como el de Matar et al. (30) en el que sí se lograron diferenciar ambas posturas con una exactitud del 97.9%.

En ambos estudios se emplearon redes neuronales profundas para el procesamiento de la información, que recibían como input la información de los sensores y proporcionaban como output la postura de los sujetos. Este tipo de arquitecturas permite procesar un gran número de inputs y deducir relaciones complejas y no lineales entre los datos. Las predicciones son posteriormente generalizadas cuando el algoritmo se encuentra con datos nuevos (30).

Si bien esta tecnología es capaz de realizar sus tareas con muy buenos resultados, su aplicación a día de hoy parece lejana. En primer lugar, debemos tener en cuenta que los estudios han sido realizados en condiciones experimentales y con población sana: Matar et al. (30) emplearon 12 sujetos de entre 21 y 33 años, y Stern et al. (29) emplearon 13 jóvenes de entre 19 y 24 años. Sería necesario conocer el funcionamiento de los sistemas de reconocimiento postural en el tipo de paciente sobre el que se aplicará esta tecnología, generalmente ancianos o pacientes hospitalizados.

Se desconoce también si elementos característicos que podemos encontrar en las camas como sábanas, almohadas o mantas interferirían en la medición de los sensores de presión, ya que no están mencionados en la literatura. Por otro lado, serían necesarios más estudios que determinasen el tipo de sensor de medición más aplicable a contextos reales. En los dos artículos ya mencionados la postura corporal se detecta a través de una esterilla o un colchón. Posiblemente este tipo de iniciativas serán más fáciles de abordar a nivel económico y de infraestructura si el dispositivo de captación de la presión puede incorporarse a los colchones ya existentes, sin requerir grandes instalaciones, inversiones o que se deseche el material del que ya se dispone. De cualquier manera, habría que garantizar la compatibilidad de los sensores con los distintos tipos de colchones que se encuentran en los hospitales.

Una alternativa a estos sistemas de monitorización es la propuesta por Gruenerbel et al. (31), en la que se miden distintos parámetros directamente del paciente sin la interferencia de agentes externos. Conociendo la fisiopatología de la formación de lesiones por presión, la medición de la saturación y la temperatura puede proporcionar información en tiempo real sobre la cantidad de presión y el estado de oxigenación de los tejidos, permitiendo actuar de forma anticipada a la aparición de lesiones.

Para ello emplearon un sensor portátil que pegaron cerca de las zonas más susceptibles de sufrir lesiones para cada paciente (generalmente el sacro o la espina iliaca superior posterior) (*Anexo 5*). La portabilidad es uno de los factores a tener en cuenta en el desarrollo de dispositivos de monitorización. Puede observarse que la unión de la medicina y tecnología avanza hacia un mundo en el que los pacientes disponen de información continua y portátil sobre su estado de salud: relojes que miden la saturación periférica de oxígeno o el sueño, bandas de frecuencia cardíaca, sensores de glucemia conectados teléfonos móviles, etc.

El problema más grande que entraña la portabilidad es la comodidad del individuo (30). Si se crea un artilugio que realiza unas mediciones excepcionales, pero causa discomfort, no lograremos la adherencia terapéutica necesaria para evitar la lesión por presión o causaremos una incomodidad evitable a nuestros pacientes. Por ejemplo, Gruenerbel et al. (31) mencionan que algunos de los participantes abandonaron su estudio antes de tiempo por incomodidad con el dispositivo.

Aunque las conclusiones de este artículo no son generalizables por los mismos motivos que los estudios anteriormente mencionados, se observó que la saturación de oxígeno en la zona afectada disminuía de forma acelerada (un 7% en 1,5 horas) en las horas previas a la aparición de una lesión visible. Este hallazgo concuerda con la fisiopatología que conocemos de formación de UPP. En base a estos hallazgos, posteriormente desarrollaron un algoritmo sencillo que avisaba cuando detectaba estos cambios notables, para poder actuar en consecuencia (31).

Lo interesante esta línea de investigación es que ataca de forma directa a la causa fisiopatológica de la UPP: a través de una monitorización continua e individualizada avisa antes de que la presión se mantenga demasiado para evitar la pérdida de oxigenación del tejido. Sin embargo, antes de que esta tecnología pueda ser empleada en contextos clínicos reales serían necesarios distintos requisitos en los que los investigadores deben trabajar. Por un lado, desarrollar un dispositivo portátil, cómodo y fiable que no resulte una molestia para los pacientes. Por otro lado, realizar más estudios que confirmen esta hipótesis y entrenar los algoritmos con muestras mayores para garantizar mejores precisiones. Por último, realizar estudios prospectivos para probar la efectividad del sistema preventivo en un contexto real.

Si todo ello se lograra con éxito se dispondría de un sistema que probablemente lograra prevenir un gran número de úlceras por presión en centros hospitalarios y residencias. En el mejor de los casos los cuidados se podrían llevar a cabo a nivel ambulatorio gracias a la portabilidad de los sensores, de manera que podrían llevarse a cabo también por cuidadores informales.

MODELOS PREDICTIVOS

Para la evaluar el riesgo de padecer una UPP, la EPUAUP (3) propone realizar una evaluación del riesgo estructurada. Sin embargo, en su guía clínica no queda del todo claro qué estructura debemos seguir ya que no existe un consenso científico internacional. Se hace hincapié en la importancia del juicio clínico como pilar que debe fundamentar el proceso de determinar qué pacientes son susceptibles de sufrir este tipo de lesiones. No obstante, el juicio clínico es una

habilidad que depende tanto del conocimiento como de la experiencia que tiene cada profesional, siendo completamente subjetivo.

Con el objetivo de consensuar y objetivar los criterios que determinan la susceptibilidad de los pacientes, se elaboraron escalas que apoyan el juicio clínico. Su elaboración se basó en la evidencia presente en la literatura, opiniones de expertos y la adaptación de escalas previamente existentes. Las tres escalas más comúnmente empleadas según la EPUAP (3) son la Norton (1962), Waterlow (1985) y Braden (1987).

Sin embargo, estas herramientas tienen una capacidad predictiva limitada: no permiten identificar la importancia de unos factores sobre otros, no contemplan la complejidad del individuo y del ambiente, no son válidas para todo tipo de pacientes y puede resultar complejo detectar cambios a lo largo del tiempo (3). El número de ítems que valoran son escasos (Norton evalúa 5, Braden evalúa 6 y Waterlow evalúa 10) y, además, no coinciden entre escalas.

Estas herramientas de valoración de riesgo de úlceras fueron creadas antes de que se tuviese acceso a grandes cantidades de datos y a sistemas predictivos como los que encontramos en la actualidad. La EPUAP (3) reconoce que las escalas tienen una capacidad predictiva insuficiente como para elaborar planes preventivos y se limita a proporcionar información general y estandarizada. Se deja de esta forma la puerta abierta al desarrollo de tecnologías que sean capaces de determinar el riesgo que tiene un paciente de sufrir una UPP para asistir a los profesionales con una mayor exactitud.

Como se ha mencionado en la introducción de este trabajo, la interpretación, análisis y clasificación de cantidades masivas de datos, así como la elaboración de predicciones son unas de las aplicaciones más prometedoras de la inteligencia artificial (11). En el campo de las UPP estas competencias han permitido el desarrollo de distintos modelos predictivos capaces de determinar qué pacientes sufrirán una lesión por presión y capaces de inferir factores determinantes en el desarrollo de úlceras en función del lugar y objetivo del estudio.

Todos los artículos que fueron revisados y están incluidos en este apartado de la revisión emplearon ML como tecnología para elaborar sus sistemas predictivos. Se recuerda que el ML es una rama de la IA que trata de reproducir el pensamiento humano a través de algoritmos que extraen información de grandes cantidades de datos y la procesan con el objetivo de reconocer patrones, clasificar y predecir. La mayoría de los trabajos realizaron una comparación del desempeño de distintos algoritmos, concluyendo la mayoría que RF (Random Forest) era el que mejores resultados proporcionaba (32,33,36–38). La revisión sistemática realizada por Toffaha et al. (39) coincidió en que RF, junto con LR (Linear Regression), eran los algoritmos más empleados con objetivos predictivos. Esto puede deberse gracias a su capacidad de establecer relaciones complejas y no lineales entre datos (38): RF es una combinación muy amplia de árboles de decisión que derivan en un único resultado. De esta manera, de la pregunta “¿sufrirá el paciente una UPP?” (input), saldrán numerosas ramas que contemplen todos los factores de riesgo que los programadores hayan decidido incluir, para proporcionar una respuesta (output).

La cantidad de variables que se tiene en cuenta depende de los objetivos del estudio. Chun et al. (33) emplearon 21 variables de 152 pacientes pediátricos para determinar el pronóstico de sus lesiones en los próximos 7 días; Song et al. (37) emplearon 28 variables en su estudio con 9.148 pacientes para su modelo predictivo; Dweekat et al. (35) emplearon 98 variables de 15.889 sujetos para predecir quién y cuándo sufriría lesiones; y Lee et al. (32) emplearon 57 variables de 60 residencias, logrando un total de 14.400.000 billones de combinaciones de RF. Teniendo en cuenta la magnitud de datos que se manejan, la capacidad de estos sistemas de evaluar la complejidad de los factores tanto personales como ambientales que influyen en el

desarrollo de UPP es infinitamente mayor que la de escalas y sistemas estadísticos tradicionales (40).

Las variables que se tienen en cuenta para la elaboración de los modelos son aquellas que según la literatura desempeñan un factor importante en el desarrollo de UPP. Esto garantiza que los modelos son entrenados en base a información científica y consensuada, al menos en lo que a variables respecta. Por otro lado, la información de los pacientes se extrae de las historias clínicas de los hospitales (34–37,39), que contienen datos desestructurados que el ML puede estructurar y analizar (38). Esto presenta ventajas e inconvenientes.

La principal ventaja es la disponibilidad y accesibilidad de la información, al tener cada hospital acceso a cantidades inmensas de historias clínicas que quedan guardadas durante años. Sin embargo, debe tenerse en cuenta que esta información no se ha almacenado con el propósito de emplearla con fines como los que plantean estos estudios (40). Y es que, a pesar de la capacidad del ML de procesar datos crudos y no estructurados, en el ámbito sanitario los márgenes de error son estrechos, y trabajar con datos de mala calidad puede dar lugar a fallos.

Los autores reflejan su preocupación por los datos con los que se alimentan a los algoritmos: *“para que una IA produzca datos fiables debe ser entrenada con información objetiva, estandarizada, clínicamente relevante y anatómicamente específica a la fisiopatología de las UPP”* argumentan Lusting et al. (34). Toffaha et al. (39) declaran en su revisión que todavía los algoritmos no han sido entrenados con bases de datos consistentes, ya sea en información o en cantidad de datos, lo que ha impedido que desarrollen de forma plena su capacidad predictiva. Esto no implica que la IA esté proporcionando malos resultados, sino que serían mejores y más fiables si lográsemos superar algunas de las limitaciones a las que se enfrenta.

Se ha visto que una de las limitaciones que encontramos para la aplicación actual del ML es el carácter retrospectivo de los estudios. Todos los artículos analizados fueron retrospectivos (32–37). Sabemos que en estas condiciones los algoritmos funcionan, como se ha reflejado en el apartado de resultados, pero su aplicabilidad es limitada en situaciones reales. Es necesario comenzar a realizar estudios prospectivos en los que se compruebe la capacidad predictiva *a posteriori*.

Para que el ML sea aplicable en distintas situaciones clínicas también es un requisito que los algoritmos se entrenen con distintos tipos de poblaciones. En la revisión se ha encontrado un estudio multicéntrico (Toffaha et al. (39)), y estudios que se realizaban en distintos servicios en un mismo centro (Anderson et al. (36)); pero como mencionan Pei et al. (40) entrenar un algoritmo con un tipo de subpoblación puede hacer que sea muy preciso para ese grupo de personas, pero menos preciso una vez se generaliza. Los factores de riesgo individuales y sociales que presentan los pacientes para el desarrollo de una UPP varían entre individuos de distintos países, ciudades o incluso dentro de las propias poblaciones, de modo que los algoritmos deben ser entrenados teniendo en cuenta la variabilidad de subpoblaciones a la que se enfrentarán.

En cuanto a los datos, los autores reflejan también la importancia de que sean proporcionados. En los estudios retrospectivos de predicción se selecciona una población para entrenar al algoritmo dentro de la cual se encuentran individuos que sufrieron UPP e individuos que no. El problema radica en que la proporción de afectados es siempre mucho menor a la de individuos sanos, lo que implica que uno de los grupos esté infrarrepresentado. Por ejemplo, del estudio de Lusting et al. (34) sufrieron una UPP 10 de los 182 sujetos; del estudio de Anderson et al. (36) 959 de los 18.943; y del estudio de Dweekat et al. (35) 485 de los 15.889. Puede observarse que existe desequilibrio en los grupos.

La desproporción en las muestras puede dar lugar a errores por lo que es necesario emplear técnicas de programación que hagan al algoritmo más favorable para la predicción de las clases menos representadas. Entre estas técnicas una de las más empleadas es el sobremuestreo (*oversampling*), una técnica de rebalanceo de datos que aumenta la representación de los grupos más pequeños de la muestra (40). Sin embargo, al emplear estas técnicas puede producirse sobreajuste (*overfitting*) cuando el algoritmo pasa a ser empleado con información nueva (35). El sobreajuste se produce cuando un sistema de ML ha sido entrenado con pocos datos en relación con su complejidad, de modo que es capaz de memorizar los datos de entrenamiento con facilidad, pero presenta dificultades al generalizar. Esto hace del rebalanceo una solución temporal al desequilibrio de datos y abre la puerta al desarrollo de herramientas que no pierdan capacidad de predicción por el desequilibrio de datos.

Cabe resaltar que los modelos desarrollados hasta el momento ejecutan sus tareas con resultados notables. Pei J et al. (40) describieron en su metaanálisis que los algoritmos predecían de media el 79% de los pacientes que sufrirían lesiones y el 87% que no. No obstante, de cara a la asistencia multiplicarían su utilidad si lograsen determinar no solo quién, sino cuándo aparecerá la lesión. Esto permitiría establecer criterios de prioridad a las enfermeras sobre quién debe ser tratado con mayor urgencia, destinar los recursos a los pacientes más comprometidos e individualizar los cuidados.

Para lograr esto es necesario que los programas contemplen las condiciones cambiantes del paciente, ya que los factores de riesgo se modifican a lo largo del proceso asistencial. Algunos investigadores ya mencionan que en lugar de entrenarse con datos estáticos (de un momento puntual como puede ser el día de ingreso hospitalario) los sistemas deberían entrenarse con datos continuos para mejorar su precisión (39,41). Con esta premisa Dweekat et al. (35) llevaron a cabo su proyecto que se dividió en dos fases: en la primera se identificaba quién desarrollaría una úlcera, y en la segunda cuándo. Debido a la insuficiencia de la muestra no se logró proporcionar un día concreto, pero se logró dividir a los pacientes en alto riesgo (lesión en menos de 7 días) y riesgo medio (lesión en más de 7 días).

El ML puede ayudar por lo tanto a anticiparnos con confianza al desarrollo de UPP, gestionar los recursos, adecuar los esfuerzos, establecer tratamientos individualizados y prevenir la iatrogenia. Para que sea plenamente aplicable necesita superar limitaciones, pero esta tecnología ya es contemplada por la EPUAP (3) como una alternativa más completa y sofisticada que los métodos tradicionales de valoración de riesgo: podría incorporarse en las historias clínicas, proporcionar información en tiempo real, contemplar más variables que las escalas conocidas, y mejorar la identificación de riesgos.

A pesar de la precisión que se pueda lograr, no debe olvidarse nunca el juicio clínico como fundamento de la valoración de riesgos, ya que factores que pueden parecer determinantes en el programa pueden no resultarlo en la realidad. La creación de estos sistemas tiene el objetivo de facilitar el trabajo de las enfermeras, asistir en momentos de indecisión e incluso complementarlo para ofrecer una atención más íntegra, pero en ningún caso sustituye las funciones del profesional.

PERSPECTIVAS GENERALES

En la realización de este trabajo se ha visto que a pesar de que las inteligencias artificiales poseen un largo recorrido, su auge y especialmente su aplicación en el ámbito de las lesiones por presión son relativamente recientes. La consecuencia es que la IA ha encontrado su lugar en otras áreas, pero actualmente sigue explorando sus aciertos y limitaciones en lo que atañe a las UPP.

Los resultados observados en las tres áreas de investigación que propone la comunidad científica (análisis de imagen, sensores y modelos predictivos) son alentadores. Si bien el estudio con sensores parece ser el menos referenciado, propone soluciones ambiciosas a la prevención directa de las lesiones. La interpretación automática de imágenes, por su parte, ya ha mostrado ser útil en otras áreas biomédicas como los cánceres de piel (26,27) y su reciente aplicación en la segmentación y análisis de heridas también parece efectiva. Por último, los modelos predictivos se están erigiendo como una nueva alternativa a las herramientas tradicionales de valoración de riesgo, al ser más completos y precisos.

Sin embargo, debe reconocerse que la mayoría de estos resultados son obtenidos en condiciones experimentales. Solo unos pocos estudios de los analizados han sido realizados en contextos reales (19,21,22), todos ellos de análisis de imagen. Teniendo esto en cuenta y con los datos disponibles para este trabajo, no puede afirmarse que la IA se esté empleando actualmente para estos propósitos en la práctica clínica. Todos los resultados que se observan son una aproximación experimental de lo que será el trabajo enfermero con inteligencia artificial.

A día de hoy se están superando dificultades como la dependencia de profesionales que supervisen la información gracias al desarrollo de modelos de aprendizaje no supervisado y a técnicas de transferencia y aumento de datos (19,20,24–26). Según avanzan los modelos se combaten retos que sirven de base para nuevos estudios. Es posible que las redes neuronales de análisis automático de UPP recientemente desarrolladas puedan servir en un futuro como base para el desarrollo de nuevas redes de análisis de UPP u otro tipo de heridas, al igual que otras redes neuronales se están empleando actualmente como estructura inicial para los estudios revisados.

No obstante, previo a la implantación de estas tecnologías deben resolverse problemas como los ya mencionados relativos a los datos. Debe garantizarse que las fuentes con las que se entrenen los algoritmos sean de calidad para obtener resultados de calidad, y cuanto mejores sean los datos, mejores serán los modelos (34,39). Cuando hablamos de datos de calidad hablamos de datos estandarizados, completos, sin errores, relevantes y representativos de la población que se estudia y para los objetivos que se buscan (39).

Un obstáculo no mencionado anteriormente que podemos encontrar a la implantación de la IA como herramienta enfermera, es citado en la revisión de Toffaha et al. (39) y el estudio de Seo et al. (25), y es el problema de las cajas negras. Describe que muchos algoritmos de ML funcionan de una forma desconocida para nosotros, es decir, aunque conozcamos los inputs y los outputs (información y resultados), el procesamiento intermedio de la información es en muchas ocasiones desconocido. En el ámbito médico la transparencia en el manejo de datos es crucial y diversas leyes así lo reflejan en nuestro país, regulando quién puede acceder a los datos personales de los pacientes y de qué maneras. Las preguntas son, por lo tanto, si a la ciudadanía le importa que sus datos sean tratados de una forma relativamente desconocida con fines que a nuestro parecer son justificables; y si los profesionales confiarán en los resultados de sistemas cuyo razonamiento se desconoce.

Sin embargo, aun teniendo en cuenta sus limitaciones la IA es una tecnología emergente en el campo de las UPP que está demostrando grandes capacidades en la prevención y evaluación de las lesiones. Su uso comienza a ser contemplado por instituciones como la EPUAP en su última actualización de Guía de Práctica Clínica de 2019 (3), por lo que su implantación tendrá lugar en un futuro próximo cuando se disponga de estudios suficientes que justifiquen su uso. Para

cuando ese momento llegue, el último reto que debe vencer la inteligencia artificial es conseguir la aceptación enfermera.

Lograr equipos accesibles, rápidos, fáciles de emplear y que proporcionen datos confiables son requisitos que deben cumplirse para la incorporación de la IA en la práctica clínica. Garantizar que los profesionales conozcan el funcionamiento básico de estas tecnologías y que perciben su uso como una facilitación y una ayuda en su trabajo son los factores que realmente determinarán su uso. Es trabajo de los expertos del sector dar a conocer las ventajas que tendrán la automatización de tareas y la implantación de sistemas de ayuda en la toma de decisiones en el ejercicio profesional enfermero.

CONCLUSIONES

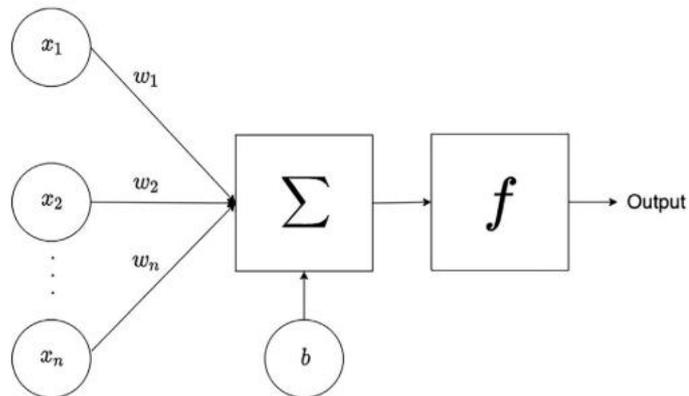
La inteligencia artificial está logrando desarrollarse y abrirse paso en áreas médicas y enfermeras. Los avances en sistemas de aprendizaje automático están permitiendo que los algoritmos realicen cada vez tareas más complejas de una forma más precisa: predicciones, análisis de imagen, reconocimiento de objetos, procesamiento de información o detección de patrones son algunas de ellas.

La conjunción de esta tecnología con el ámbito de las UPP surge ante la necesidad de herramientas para paliar un problema evitable que sigue afectando a una gran parte de la población con consecuencias tanto individuales como sociales. Su aplicación se centra en el análisis de las lesiones a través de imágenes, en la inferencia de factores de riesgo que motivan su desarrollo, en la predicción del riesgo de los individuos y en la interpretación de información procedente de sensores de presión.

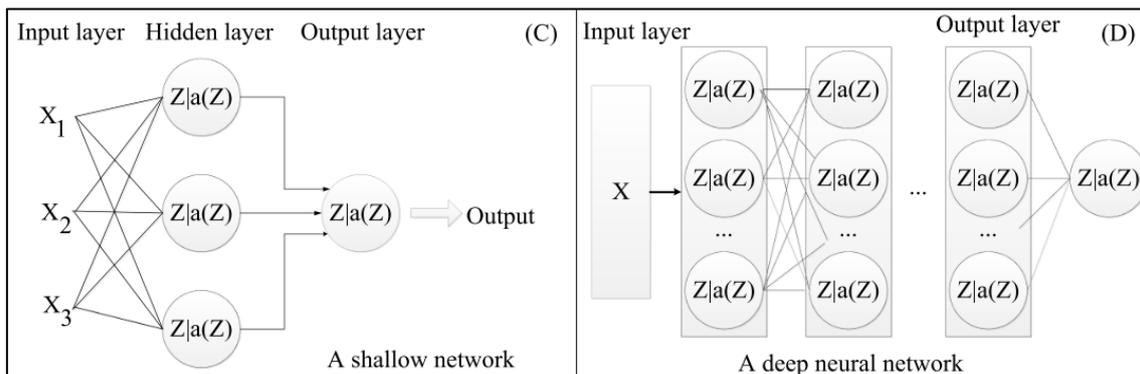
La IA muestra capacidades que se encuentran por encima de lo humano al poder manejar cantidades inmensas de datos y establecer relaciones complejas entre ellos. Es capaz de realizar predicciones, valorar riesgos e interpretar lesiones de forma más precisa que los métodos tradicionales. Sin embargo, al tratarse de una línea de investigación emergente, se requieren más estudios que sustenten su utilidad y sobrepasen sus limitaciones.

Es necesaria una mayor comprensión de la relación entre las predicciones realizadas por la IA y los eventos que sufren en tiempo real los pacientes, por lo que deben realizarse estudios prospectivos. El desarrollo de sensores portátiles que monitoricen las zonas de presión es una de las propuestas más prometedoras para la individualización de los cambios posturales de los pacientes de riesgo, pero primero deben garantizarse su fiabilidad y confortabilidad. La interpretación de lesiones con redes convolucionales ayuda en la medición, clasificación y evaluación de las curas, pero deben entrenarse algoritmos con datos de calidad en estudios prospectivos y multicéntricos. La oportunidad de incorporar la inteligencia artificial a la labor en un futuro es real.

Sobre la base de la evidencia disponible, puede concluirse que la inteligencia artificial reúne los atributos necesarios para ser considerada una potencial herramienta de uso enfermero en la prevención y diagnóstico de UPP. Proporcionar cuidados individualizados, una monitorización continua, priorizar adecuadamente, realizar juicios clínicos seguros, agilizar el trabajo, reducir el tiempo en tareas administrativas, pasar más tiempo con el paciente, disminuir el gasto sanitario y minimizar la iatrogenia son algunos de los resultados que se esperan de la IA, pero antes debe garantizarse la realización de nuevos estudios que combatan sus limitaciones actuales.



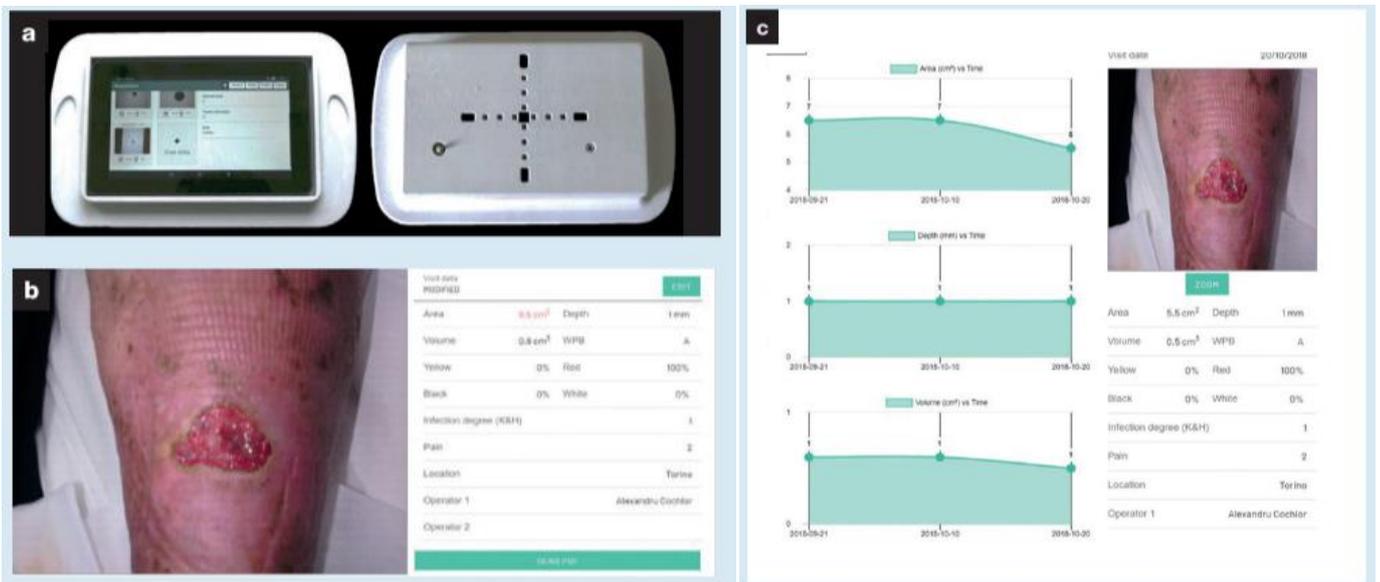
Anexo 1 (7). Ilustra la estructura y funcionamiento del Perceptrón, el tipo de neurona en la que se basan la mayoría de redes neuronales artificiales actuales. Cada input (x) se le asigna un peso (w). Una vez se realiza una suma ponderada se compara con un límite de activación y se produce el output en forma de 0 o 1



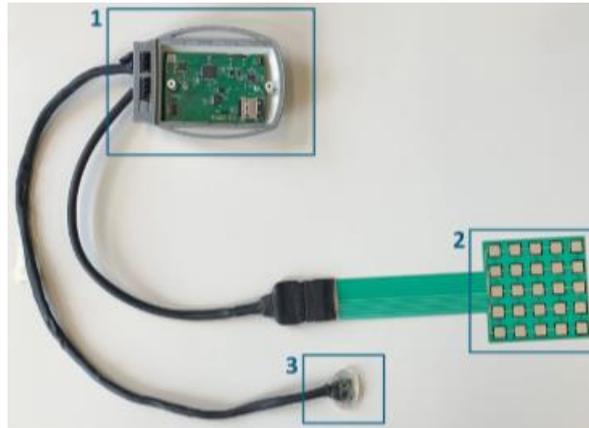
Anexo 2 (9). A la izquierda (C), una red neuronal superficial con una capa de input, una capa oculta y una capa de output. A la derecha (D) una red neuronal profunda con una capa de input, indefinidas capas ocultas y una capa de output. Se observa que las relaciones establecidas son complejas, y que la complejidad de la red dependerá del número de capas ocultas.



Anexo 3 (imágenes extraídas de la página web oficial del GNEAUPP). UPP estadio I (superior izquierda), estadio II (superior derecha), estadio III (inferior izquierda) y estadio IV (inferior derecha).



Anexo 4 (22). Dispositivo portátil Wound Viewer (a), un ejemplo del resultado de un examen tras una foto (b) y un ejemplo de la página de estadísticas para profesionales para evaluar la evolución (c).



Anexo 5 (31): sensor portátil KIPRODE aplicado a los pacientes del estudio. Se observa el sistema con la batería (1), el sensor de presión (2) y el pulsioxímetro con termómetro (3). Se aplicaría en la zona próxima al lugar de mayor susceptibilidad de sufrir una lesión.

1. GUÍA DE ACTUACIÓN PARA LA PREVENCIÓN Y CUIDADOS DE LAS ÚLCERAS POR PRESIÓN - GNEAUPP [Internet]. [citado 28 de febrero de 2024]. Disponible en: <https://gneaupp.info/guia-de-actuacion-para-la-prevencion-y-cuidados-de-las-ulceras-por-presion-2/>
2. Prevalencia de las relacionadas con la dependencia en residencias de mayores y centros sociosanitarios de España: resultados del 6.º Estudio Nacional del GNEAUPP 2022 - GNEAUPP [Internet]. [citado 17 de julio de 2024]. Disponible en: <https://gneaupp.info/prevalencia-de-las-relacionadas-con-la-dependencia-en-residencias-de-mayores-y-centros-sociosanitarios-de-espana-resultados-del-6-o-estudio-nacional-del-gneaupp-2022/>
3. Prevention and Treatment of Pressure Ulcers/Injuries: Clinical Practice Guideline.
4. Qi Pamela Ng Z, Ying Janice Ling L, Shi Jocelyn Chew H, Fellow R, Lau Y, Professor A, et al. The role of artificial intelligence in enhancing clinical nursing care: A scoping review. 2021 [citado 26 de febrero de 2024]; Disponible en: <https://onlinelibrary.wiley.com/doi/10.1111/jonm.13425>
5. Samoili S, López Cobo M, Delipetrev B, Martínez-Plumed F, Gómez E, De Prato G, et al. AI Watch. Defining Artificial Intelligence 2.0. [citado 5 de marzo de 2024]; Disponible en: <https://publications.jrc.ec.europa.eu/repository/handle/JRC126426>
6. Shinde PP, Shah S. A Review of Machine Learning and Deep Learning Applications. Proceedings - 2018 4th International Conference on Computing, Communication Control and Automation, ICCUBEA 2018. 2 de julio de 2018;
7. Muthukrishnan N, Maleki F, Ovens K, Reinhold C, Forghani B, Forghani R. Brief History of Artificial Intelligence. *Neuroimaging Clin N Am*. 1 de noviembre de 2020;30(4):393-9.
8. Kanal LN. 11th International Conference on pattern recognition August 31-September 3, 1992 On pattern, categories, and alternate realities. *Pattern Recognit Lett*. 1993;14(3):241-55.
9. Dong S, Wang P, Abbas K. A survey on deep learning and its applications. *Comput Sci Rev* [Internet]. 2021 [citado 26 de febrero de 2024];40:100379. Disponible en: www.elsevier.com/locate/cosrev
10. Janiesch C, Zschech P, Heinrich K. Machine learning and deep learning. [citado 26 de febrero de 2024]; Disponible en: <https://doi.org/10.1007/s12525-021-00475-2>
11. Kayikci S, Khoshgoftaar TM. Blockchain meets machine learning: a survey. [citado 11 de marzo de 2024]; Disponible en: <https://doi.org/10.1186/s40537-023-00852-y>
12. Staddon JER, Cerutti DT. Operant Conditioning. <https://doi.org/10.1146/annurev.psych.54.101601.145124> [Internet]. 28 de noviembre de 2003 [citado 10 de marzo de 2024];54:115-44. Disponible en: <https://www.annualreviews.org/doi/abs/10.1146/annurev.psych.54.101601.145124>
13. Secinaro S, Calandra D, Secinaro A, Muthurangu V, Biancone P. The role of artificial intelligence in healthcare: a structured literature review. *BMC Med Inform Decis Mak* [Internet]. 1 de diciembre de 2021 [citado 9 de marzo de 2024];21(1):1-23. Disponible

en: <https://bmcmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-021-01488-9>

14. Min S, Lee B, Yoon S. Deep learning in bioinformatics. [citado 13 de marzo de 2024]; Disponible en: <https://academic.oup.com/bib/article/18/5/851/2562808>
15. DEEP LEARNING. [citado 26 de febrero de 2024]; Disponible en: <https://www.nature.com/articles/nature14539.pdf>
16. Guía de prevención y manejo de úlceras por presión y heridas crónicas. - GNEAUPP [Internet]. [citado 21 de febrero de 2024]. Disponible en: <https://gneaupp.info/guia-de-prevencion-y-manejo-de-ulceras-por-presion-y-heridas-cronicas/>
17. Kottner J, Cuddigan J, Carville K, Balzer K, Berlowitz D, Law S, et al. Pressure ulcer/injury classification today: An international perspective. *J Tissue Viability* [Internet]. 2020 [citado 21 de marzo de 2024];29:197-203. Disponible en: <https://doi.org/10.1016/j.jtv.2020.04.003>
18. Silva RHL e., Machado AMC. Automatic measurement of pressure ulcers using Support Vector Machines and GrabCut. *Comput Methods Programs Biomed.* 1 de marzo de 2021;200:105867.
19. Liu TJ, Wang H, Christian M, Chang CW, Lai F, Tai HC. Automatic segmentation and measurement of pressure injuries using deep learning models and a LiDAR camera. *123d. C.* [citado 20 de febrero de 2024]; Disponible en: <https://doi.org/10.1038/s41598-022-26812-9>
20. Liu TJ, Christian M, Chu YC, Chen YC, Chang CW, Lai F, et al. A pressure ulcers assessment system for diagnosis and decision making using convolutional neural networks. *Journal of the Formosan Medical Association.* 1 de noviembre de 2022;121(11):2227-36.
21. Lau CH, Yu KHO, Yip TF, Luk LYF, Wai AKC, Sit TY, et al. An artificial intelligence-enabled smartphone app for real-time pressure injury assessment. *Front Med Technol.* 23 de septiembre de 2022;4:905074.
22. Zoppo G, Marrone F, Pittarello M, Farina M, Uberti A, Demarchi D, et al. AI technology for remote clinical assessment and monitoring. *J Wound Care* [Internet]. 2 de diciembre de 2020 [citado 18 de febrero de 2024];29(12):692-706. Disponible en: <https://www.magonlinelibrary.com/doi/10.12968/jowc.2020.29.12.692>
23. Sakakibara S, Takekawa A, Takekawa C, Nagai S, Terashi H. Construction and Validation of an Image Discrimination Algorithm to Discriminate Necrosis from Wounds in Pressure Ulcers. *Journal of Clinical Medicine* 2023, Vol 12, Page 2194 [Internet]. 12 de marzo de 2023 [citado 20 de febrero de 2024];12(6):2194. Disponible en: <https://www.mdpi.com/2077-0383/12/6/2194/htm>
24. Swerdlow M, Guler O, Yaakov R, Armstrong DG. Simultaneous Segmentation and Classification of Pressure Injury Image Data Using Mask-R-CNN. *Comput Math Methods Med.* 2023;2023.
25. Seo S, Kang J, Eom IH, Song H, Park JH, Lee Y, et al. Visual classification of pressure injury stages for nurses: A deep learning model applying modern convolutional neural networks. *J Adv Nurs* [Internet]. 1 de agosto de 2023 [citado 20 de febrero de 2024]; Disponible en: <https://doi.org/10.1111/jan.15211>

- 2024];79(8):3047-56. Disponible en:
<https://onlinelibrary.wiley.com/doi/full/10.1111/jan.15584>
26. Kim J, Lee C, Choi S, Sung DI, Seo J, Na Lee Y, et al. Augmented Decision-Making in wound Care: Evaluating the clinical utility of a Deep-Learning model for pressure injury staging. *Int J Med Inform.* 1 de diciembre de 2023;180:105266.
 27. Zahia S, Begoña M, Zapirain G, Sevillano X, González A, Kim PJ, et al. Pressure injury image analysis with machine learning techniques: A systematic review on previous and possible future methods. 2019 [citado 18 de febrero de 2024]; Disponible en: <https://doi.org/10.1016/j.artmed.2019.101742>
 28. Ohura N, Mitsuno R, Sakisaka M, Terabe Y, Morishige Y, Uchiyama A, et al. Convolutional neural networks for wound detection: the role of artificial intelligence in wound care. <https://doi.org/1012968/jowc201928Sup10S13> [Internet]. 10 de octubre de 2019 [citado 20 de febrero de 2024];28:S13-24. Disponible en: <https://www.magonlinelibrary.com/doi/10.12968/jowc.2019.28.Sup10.S13>
 29. Stern L, Roshan Fekr A. In-Bed Posture Classification Using Deep Neural Network. *Sensors* 2023, Vol 23, Page 2430 [Internet]. 22 de febrero de 2023 [citado 18 de febrero de 2024];23(5):2430. Disponible en: <https://www.mdpi.com/1424-8220/23/5/2430/htm>
 30. Matar G, Lina JM, Kaddoum G. Artificial Neural Network for in-Bed Posture Classification Using Bed-Sheet Pressure Sensors. *IEEE J Biomed Health Inform.* 1 de enero de 2020;24(1):101-10.
 31. Gruenerbel L, Heinrich F, Böhlhoff-Martin J, Röper L, Machens HG, Gruenerbel A, et al. Wearable Prophylaxis Tool for AI-Driven Identification of Early Warning Patterns of Pressure Ulcers. *Bioengineering* 2023, Vol 10, Page 1125 [Internet]. 25 de septiembre de 2023 [citado 20 de febrero de 2024];10(10):1125. Disponible en: <https://www.mdpi.com/2306-5354/10/10/1125/htm>
 32. Lee SK, Shin JH, Ahn J, Lee JY, Jang DE. Identifying the Risk Factors Associated with Nursing Home Residents' Pressure Ulcers Using Machine Learning Methods. *International Journal of Environmental Research and Public Health* 2021, Vol 18, Page 2954 [Internet]. 13 de marzo de 2021 [citado 20 de febrero de 2024];18(6):2954. Disponible en: <https://www.mdpi.com/1660-4601/18/6/2954/htm>
 33. Chun X, Pan L, Lin Y, Ye L, Liang H, Tao J, et al. A model for predicting 7-day pressure injury outcomes in paediatric patients: A machine learning approach 儿科患者7天压力损伤结果的预测模型: 一种机器学习方法. *J Adv Nurs* [Internet]. 1 de marzo de 2021 [citado 20 de febrero de 2024];77(3):1304-14. Disponible en: <https://onlinelibrary.wiley.com/doi/full/10.1111/jan.14680>
 34. Lustig M, Schwartz D, Bryant R, Gefen A. A machine learning algorithm for early detection of heel deep tissue injuries based on a daily history of sub-epidermal moisture measurements. *Int Wound J.* 1 de octubre de 2022;19(6):1339-48.
 35. Dweekat OY, Lam SS, McGrath L. An Integrated System of Multifaceted Machine Learning Models to Predict If and When Hospital-Acquired Pressure Injuries (Bedsore) Occur. *Int J Environ Res Public Health* [Internet]. 1 de enero de 2023 [citado 20 de febrero de 2024];20(1):828. Disponible en: <https://www.mdpi.com/1660-4601/20/1/828/htm>

36. Anderson C, Bekele Z, Qiu Y, Tschannen D, Dinov ID. Modeling and prediction of pressure injury in hospitalized patients using artificial intelligence. *BMC Med Inform Decis Mak* [Internet]. 1 de diciembre de 2021 [citado 18 de febrero de 2024];21(1):1-13. Disponible en: <https://bmcmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-021-01608-5>
37. Song W, Kang MJ, Zhang L, Jung W, Song J, Bates DW, et al. Predicting pressure injury using nursing assessment phenotypes and machine learning methods.
38. Tehrany PM, Zabihi MR, Ghorbani Vajargah P, Tamimi P, Ghaderi A, Norouzkhani N, et al. Risk predictions of hospital-acquired pressure injury in the intensive care unit based on a machine learning algorithm. *Int Wound J*. 1 de noviembre de 2023;20(9):3768-75.
39. Toffaha KM, Simsekler MCE, Omar MA. Leveraging artificial intelligence and decision support systems in hospital-acquired pressure injuries prediction: A comprehensive review. *Artif Intell Med* [Internet]. 1 de julio de 2023 [citado 18 de febrero de 2024];141. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/37295900/>
40. Pei J, Guo X, Tao H, Wei Y, Zhang H, Ma Y, et al. Machine learning-based prediction models for pressure injury: A systematic review and meta-analysis. *Int Wound J* [Internet]. 1 de diciembre de 2023 [citado 20 de febrero de 2024];20(10):4328-39. Disponible en: <https://onlinelibrary.wiley.com/doi/full/10.1111/iwj.14280>
41. Dweekat OY, Lam SS, McGrath L. Machine Learning Techniques, Applications, and Potential Future Opportunities in Pressure Injuries (Bedsore) Management: A Systematic Review. *International Journal of Environmental Research and Public Health* 2023, Vol 20, Page 796 [Internet]. 1 de enero de 2023 [citado 18 de febrero de 2024];20(1):796. Disponible en: <https://www.mdpi.com/1660-4601/20/1/796/htm>