



FUNDACIÓN H. A.
BARCELÓ
FACULTAD DE MEDICINA



TRABAJO DE INVESTIGACIÓN FINAL

CARRERA: KINESIOLOGÍA Y FISIATRÍA

DIRECTOR DE CARRERA:

LIC. DIEGO CASTAGNARO

NOMBRE Y APELLIDO:

FEDERICO FRIZZERA

TUTOR:

LIC. CARPIO BELEN

FECHA DE PRESENTACIÓN

24/04/26

FECHA DE DEFENSA DE TRABAJO FINAL:

24/04/26

TÍTULO DEL TRABAJO:

“EFECTIVIDAD DE LA INTELIGENCIA ARTIFICIAL EN LA PREDICCIÓN DE
LESIONES EN CORREDORES”

SEDE:

LA RIOJA – CAPITAL

Sede Buenos Aires
Av. Las Heras 1907
Tel./Fax: (011) 4800 0200
☎ (011) 1565193479

Sede La Rioja
Benjamín Matienzo 3177
Tel./Fax: (0380) 4422090 / 4438698
☎ (0380) 154811437

Sede Santo Tomé
Centeno 710
Tel./Fax: (03756) 421622
☎ (03756) 15401364

**INSTITUTO UNIVERSITARIO DE CIENCIAS DE LA SALUD
FUNDACIÓN H. BARCELÓ
LICENCIATURA EN KINESIOLOGÍA Y FISIATRÍA**



PÁGINA DE APROBACIÓN

EVALUACIÓN DEL TRABAJO FINAL DE INVESTIGACIÓN

Calificación.....

DEFENSA ORAL DEL TRABAJO DE INVESTIGACIÓN

Calificación.....

TRIBUNAL EXAMINADOR

.....

.....

.....

Agradecimientos

En primer lugar, quiero agradecer a mis padres, porque gracias a su esfuerzo y sacrificio tuve la oportunidad de estudiar lo que me gusta. También a mis abuelos, hermanos, tíos, primos y a toda mi familia, por acompañarme y apoyarme durante todo este proceso.

A mis amigos, por hacer de estos años una etapa muy linda, llena de buenos momentos, y por haber hecho el camino mucho más llevadero.

Agradezco a mi tutora, Lic. Carpio, y a mi asesora, Lic. Batero, por su ayuda y acompañamiento en este trabajo final, y a todos los profesores de la institución por los conocimientos que me brindaron.

Por último, quiero agradecerme a mí mismo por el esfuerzo y la dedicación, por haber estado a la altura del sacrificio de mi familia y por haber alcanzado este logro.

Tabla De Contenido

Resumen.....	6
Abstract.....	7
Introducción.....	8
Planteamiento del problema.....	8
Justificación.....	8
Marco Teórico.....	9
Running.....	9
Epidemiología Y Características De Las Lesiones En Corredores.....	11
Inteligencia Artificial (IA).....	12
Machine Learning/Aprendizaje Automático (ML).....	14
Deep Learning/Aprendizaje Profundo (DL).....	18
Procesamiento Del Lenguaje Natural (PLN).....	21
Dispositivos Tecnológicos Portátiles/Wearables.....	23
Métricas de evaluación de algoritmos.....	26
Variables biomecánicas.....	28
Estado del arte.....	32
Hipótesis.....	36
Objetivos.....	36
Metodología.....	37
Resultados.....	42
Discusión.....	55

Conclusión.....	59
------------------------	-----------

Referencias Bibliográficas.....	60
--	-----------

Resumen

Introducción: El running es una de las actividades deportivas más practicadas a nivel mundial debido a su accesibilidad y beneficios para la salud. Sin embargo, presenta una alta incidencia de lesiones que afectan la continuidad del entrenamiento y el rendimiento deportivo. En los últimos años, la inteligencia artificial ha comenzado a incorporarse en el ámbito deportivo y de la salud con el objetivo de analizar datos biomecánicos y detectar patrones asociados al riesgo de lesión en corredores. **Hipótesis:** En el running la inteligencia artificial es una herramienta eficaz para la predicción de lesiones. **Objetivos:** Confirmar la efectividad de la inteligencia artificial en la predicción de lesiones en corredores mediante una revisión bibliográfica, comparar los resultados obtenidos por distintos algoritmos e identificar los modelos y variables biomecánicas más utilizadas como predictores de lesión. **Metodología:** Se realizó un estudio no experimental con enfoque mixto, de carácter descriptivo, basado en el análisis documental de estudios científicos. La búsqueda bibliográfica se llevó a cabo en bases de datos como PubMed, SciELO, PEDro y ScienceDirect, aplicando criterios de inclusión y exclusión para la selección de los artículos analizados. **Resultados:** Los estudios analizados evidencian una predominancia del uso de algoritmos de machine learning en la predicción de lesiones deportivas. En general, los modelos presentaron niveles de efectividad moderados, aunque algunos enfoques, especialmente aquellos que combinan diferentes arquitecturas de inteligencia artificial, mostraron resultados de efectividad alta. **Conclusión:** La inteligencia artificial presenta un potencial importante para la predicción de lesiones en corredores. Sin embargo, su efectividad depende de diversos factores; metodológicos, de heterogeneidad de datos, arquitecturas/algoritmos utilizados, interpretabilidad, diversidad de variables, entre otros.

Palabras clave: lesiones-running, predicción de lesiones deportivas, inteligencia artificial, aprendizaje automático, aprendizaje profundo, dispositivos portátiles, biomecánica y procesamiento del lenguaje natural.

Abstract

Introduction: Running is one of the most widely practiced sports activities worldwide due to its accessibility and health benefits. However, it presents a high incidence of injuries that affect training continuity and athletic performance. In recent years, artificial intelligence has begun to be incorporated into sports and health fields with the aim of analyzing biomechanical data and detecting patterns associated with injury risk in runners. **Hypothesis:** In running, artificial intelligence is an effective tool for injury prediction. **Objectives:** To confirm the effectiveness of artificial intelligence in predicting injuries in runners through a literature review, to compare the results obtained by different algorithms, and to identify the models and biomechanical variables most frequently used as injury predictors. **Methodology:** A non-experimental study with a mixed and descriptive approach was conducted, based on the documentary analysis of scientific studies. The literature search was carried out in databases such as PubMed, SciELO, PEDro and ScienceDirect, applying inclusion and exclusion criteria for the selection of the analyzed articles. **Results:** The analyzed studies show a predominance of machine learning algorithms in sports injury prediction. In general, the models presented moderate levels of effectiveness, although some approaches, especially those combining different artificial intelligence architectures, showed high effectiveness results. **Conclusion:** Artificial intelligence shows important potential for predicting injuries in runners. However, its effectiveness depends on several factors, including methodological aspects, data heterogeneity, the architectures or algorithms used, interpretability, and the diversity of variables, among others.

Keywords: running-related injuries, sports injury prediction, artificial intelligence, machine learning, deep learning, wearables, biomechanics, natural language processing.

Introducción

El running es una de las actividades deportivas más practicadas a nivel mundial, en los últimos años ha adquirido una gran relevancia debido a su accesibilidad y beneficios para salud. Sin embargo, presenta una alta incidencia de lesiones. Durante los últimos años, la inteligencia artificial ha tomado lugar en muchos ámbitos actuales, tanto a nivel cultural, educativo y en el ámbito de la salud. Uno de ellos ha sido su incorporación y participación en la predicción de lesiones deportivas derivadas del running. El presente estudio aborda cómo la utilización de la inteligencia artificial y sus diferentes ramas (ML, DL y PLN) son eficaces en la participación de la predicción de estas lesiones.

Planteamiento del problema

La prevención de lesiones continúa siendo un desafío para los profesionales de la salud y el deporte, la inteligencia artificial ha mostrado un importante potencial para analizar datos biomecánicos y detectar patrones asociados a riesgo de lesión. Sin embargo, su aplicación en la práctica cotidiana aun es limitada y poco sistematizada.

Una de las principales problemáticas es la gran diversidad de algoritmos, variables, metodologías y dispositivos que utilizan esta herramienta lo que dificulta identificar cuáles son los modelos más confiables y aplicables a estas prácticas.

Sumado a estas limitaciones se encuentra la baja aceptabilidad y capacitación de los profesionales respecto a su correcta interpretación y aplicación. Por esta razón se percibe a la inteligencia artificial como una tecnología costosa y poco accesible para su participación en la predicción de lesiones.

En el running ¿La utilización de IA en la predicción de lesiones es efectiva?

Justificación

El alto índice de lesiones en corredores representa un desafío constante para los kinesiólogos y profesionales del deporte. Las herramientas basadas en IA pueden

proporcionar evaluaciones continuas, objetivas y personalizadas, mejorando las estrategias de prevención.

El presente trabajo busca contribuir al conocimiento científico sobre la efectividad de la IA en la predicción de lesiones, evaluando su fiabilidad, precisión y aplicabilidad en contextos reales. Este enfoque se alinea con los objetivos de la kinesiólogía moderna, que busca optimizar el rendimiento físico mediante la prevención y detección temprana de factores de riesgo.

Marco Teórico

Running.

En las últimas décadas, el running ha ganado un lugar cada vez más importante dentro de las prácticas de actividad física. Muchas personas lo eligen porque es una forma simple de moverse, que no exige grandes recursos ni una preparación compleja para comenzar. Basta con un espacio para correr y cierta constancia para incorporarlo a la rutina. En ese sentido, se trata de una actividad que resulta accesible para una gran parte de la población y que, además, se asocia a múltiples beneficios para la salud. Como señalan Correia et. al (2024), “correr es una de las actividades deportivas más populares y practicadas. Es un deporte accesible y de bajo costo, con beneficios bien conocidos para la salud, que ha atraído a muchas personas que eligen la carrera como su principal actividad deportiva”.

Sin embargo, la forma en que hoy se vive y se practica el running no siempre fue la misma. Durante mucho tiempo, correr estuvo ligado casi exclusivamente al ámbito deportivo formal y al entrenamiento de atletas. No era una actividad extendida entre la población general, sino que aparecía principalmente en contextos competitivos o como parte de la preparación física de otros deportes. Tal como describe Hijós (2018), “durante mucho tiempo y antes de que esta práctica sea un fenómeno global en auge, las personas que

corrían fueron –casi exclusivamente– competidores de atletismo, aunque también lo hacían como complemento físico quienes entrenaban para otras disciplinas específicas.”

Con el paso del tiempo, esta práctica comenzó a expandirse y a ocupar otros espacios más allá del deporte competitivo. Actualmente es común ver corredores entrenando en parques, calles o espacios públicos, muchas veces formando grupos o comunidades que comparten entrenamientos y objetivos deportivos. Esta expansión también se refleja en la gran cantidad de eventos y carreras que se organizan en distintas ciudades. En este contexto, el running reúne hoy a personas con trayectorias, edades y realidades muy distintas. Como señala Hijós (2018), “hoy, la práctica del running nuclea a individuos de edades, sexos y condiciones socio-económicas diversas, que se congregan en ciudades para entrenar y planificar sus competencias.”

De esta manera, el running no solo se ha consolidado como una práctica deportiva, sino también como una forma de actividad física que muchas personas incorporan a su vida cotidiana, ya sea con fines recreativos, de salud o de superación personal

Figura 1. *Running*



Nota. Imagen generada con ChatGPT (OpenAI, 2026) a partir del prompt: “Personas corriendo”.

Epidemiología Y Características De Las Lesiones En Corredores

A pesar de los beneficios asociados a la práctica del running, la aparición de lesiones es una preocupación frecuente tanto para corredores como para profesionales de la salud y del deporte. Estas lesiones pueden afectar la continuidad del entrenamiento, el rendimiento deportivo e incluso llevar a la interrupción temporal o permanente de la práctica. Por este motivo, distintos estudios han intentado cuantificar su frecuencia dentro de la población de corredores. En este contexto, “las lesiones relacionadas con la carrera (RRI, por sus siglas en inglés) son comunes entre los corredores, con una tasa de incidencia que varía entre 4,26 (corredores recreativos) y 33,07 (corredores novatos) por cada 1000 horas de exposición a la carrera” (Correia et al., 2024).

Comprender cómo y por qué se producen estas lesiones resulta un aspecto central para su prevención. La literatura científica coincide en que no existe una única causa que

explique su aparición, sino que suelen intervenir distintos factores que se combinan entre sí y que pueden variar según las características de cada corredor. En relación con esto, según Correia et al. (2024) las lesiones relacionadas con el running tienen un origen multifactorial, ya que se dan por la interacción de características personales del corredor, aspectos morfológicos, factores biomecánicos de la carrera, variables asociadas al entrenamiento, y la experiencia deportiva, así como las condiciones de salud y estilo de vida.

Además de analizar sus causas, diferentes investigaciones también han identificado cuáles son las regiones corporales que suelen verse más comprometidas en los corredores. Este tipo de información resulta relevante para orientar tanto la prevención como la evaluación clínica de las lesiones más habituales. En este sentido, “la rodilla, la pierna inferior y el pie son las zonas más afectadas, mientras que el síndrome de dolor patelofemoral, el estrés tibial medial, la fascitis plantar, el síndrome de la banda iliotibial y la tendinopatía aquilea son los diagnósticos más frecuentes” (Correia et al., 2024).

Inteligencia Artificial (IA)

La inteligencia artificial puede definirse como un campo interdisciplinario de la ciencia y la tecnología orientado al desarrollo de sistemas capaces de realizar tareas que tradicionalmente requieren capacidades cognitivas humanas como el razonamiento, el aprendizaje, la toma de decisiones y la resolución de problemas. (Pérez & Negrete Yankelevich, 2025). Se ocupa principalmente de comprender y llevar a cabo tareas inteligentes como pensar, adquirir nuevas habilidades y adaptarse a nuevos contextos y desafíos. (Sarker, H. S. 2022).

Dentro de este campo amplio, la inteligencia artificial puede aplicarse en diferentes áreas según el tipo de tarea que se desea abordar o el tipo de datos que se analizan. En este sentido, Sarker (2022) describe diversas áreas de aplicación de la IA, las cuales se orientan a resolver problemas específicos en distintos ámbitos tecnológicos.

IA Analítica

Se orienta al análisis de datos con el objetivo de identificar patrones, relaciones y conocimientos que permitan apoyar a la toma de decisiones, utilizando para ella técnicas de aprendizaje automático y profundo. Sarker, H. S. (2022).

IA Funcional

Analiza grandes volúmenes de datos para identificar patrones, y a diferencia de la IA analítica, ejecuta acciones automáticas en tiempo real en lugar de limitarse a generar recomendaciones. Sarker, H. S. (2022).

IA Interactiva

Permite automatizar y optimizar la comunicación mediante sistemas capaces de interactuar con los usuarios, como chats bots o asistentes inteligentes, utilizando técnicas de aprendizaje automático y otros métodos de IA. Sarker, H. S. (2022). 4

IA Textual

Se basa en técnicas de procesamiento del lenguaje natural para analizar y generar texto, permitiendo tareas como reconocimiento de voz, traducción automática y respuestas automatizadas a consultas. Sarker, H. S. (2022).

IA Visual

Interpreta imágenes y videos permitiendo a las maquinas reconocer, clasificar y extraer información a partir de datos visuales. Sarker, H. S. (2022).

Dentro del campo de la inteligencia artificial también se desarrollaron distintos subcampos orientados al procesamiento y análisis de datos, entre los que se destacan el machine learning (ML), el deep learning (DL) y el procesamiento del lenguaje natural (PLN).

El machine learning se centra en el desarrollo de algoritmos capaces de aprender a partir de los datos y detectar patrones sin necesidad de ser programados explícitamente para cada tarea. El deep learning, considerado una subárea del machine learning, utiliza redes neuronales artificiales profundas para analizar grandes volúmenes de información y reconocer patrones complejos. Por su parte, el Procesamiento del Lenguaje Natural se enfoca en el análisis e interpretación del lenguaje humano por parte de las máquinas, permitiendo trabajar con datos textuales o verbales. Estos enfoques constituyen actualmente algunas de las herramientas más utilizadas dentro de la inteligencia artificial y han sido ampliamente aplicados en diferentes áreas de investigación.

Figura 2. IA en Running



Nota. Imagen generada con ChatGPT (OpenAI, 2026) a partir del prompt: "Personas corriendo, analizadas por inteligencia artificial".

Machine Learning/Aprendizaje Automático (ML)

EL aprendizaje automático es el estudio de algoritmos informáticos que automatizan la construcción de modelos analíticos. Los modelos de ML a menudo se componen de un conjunto de reglas, procedimientos o "funciones de transferencia" sofisticadas que se

pueden usar para descubrir patrones de datos interesantes o anticipar el comportamiento. El aprendizaje automático también se conoce como análisis predictivo que hace predicciones sobre ciertas incógnitas en el futuro a través del uso de datos. Sarker, H. S. (2022).

Enfoques o Paradigmas ML

En ML encontramos enfoques o paradigmas que definen como aprende el modelo.

Aprendizaje Supervisado. En este enfoque, los datos de entrenamiento incluyen tanto las variables de entrada (también llamadas features o atributos) como las salidas deseadas (etiquetas o valores objetivo). El objetivo del modelo es aprender una función que permita predecir correctamente la salida correspondiente a nuevas entradas. Algunos ejemplos comunes de tareas supervisadas son la clasificación y la regresión. Melián León, S. (2025).

Aprendizaje No Supervisado. En este caso, los datos de entrenamiento solo contienen las variables de entrada, sin información sobre la salida esperada. El objetivo del modelo es descubrir estructuras ocultas, patrones o agrupaciones naturales dentro de los datos. Un ejemplo típico de este enfoque es el clustering (agrupamiento), donde se intenta identificar subconjuntos homogéneos en un conjunto de datos. Melián León, S. (2025).

Aprendizaje Semi-Supervisado. Puede considerarse como una hibridación de ambas técnicas explicadas anteriormente, ya que utiliza datos etiquetados y no etiquetados para entrenar un modelo. Podría ser efectivo para mejorar el rendimiento del modelo cuando los datos deben etiquetarse automáticamente sin interacción humana. Sarker, H. S. (2022).

Aprendizaje De Refuerzo. En general, es capaz de percibir e interpretar su entorno, tomar acciones y aprender a través de prueba y error, es decir, un enfoque impulsado por el

entorno, en el que el entorno generalmente se modela como un proceso de decisión de Markov y las decisiones se toman utilizando una función de recompensa. Sarker, H. S. (2022).

Algoritmos En ML Aprendizaje Supervisado

El aprendizaje supervisado es uno de los enfoques más utilizados dentro del Machine Learning. En este paradigma, los algoritmos aprenden a partir de datos previamente etiquetados para identificar patrones y realizar predicciones o clasificaciones sobre nuevos datos. Debido a esta capacidad predictiva, es el enfoque más empleado en estudios orientados a la predicción de lesiones, ya que permite entrenar modelos utilizando información previa de los corredores y sus características. Dentro de este enfoque se desarrollaron distintos algoritmos, cada uno con características y aplicaciones particulares:

Arboles de Decisión/Decision trees. Modelo supervisado que organiza los datos en una estructura de árbol para tomar decisiones de clasificación o regresión. Cada nodo representa una condición sobre un atributo, y la ruta desde la raíz hasta una hoja determina la predicción, siendo fácil de interpretar y aplicar en distintos dominios. Sarker, H. S. (2022).

Regresión Lineal/Linear regression. Es un método de aprendizaje supervisado que busca modelar la relación entre una variable dependiente continua y una o más variables independientes mediante una función lineal. Su finalidad es predecir valores numéricos a partir de datos etiquetados, ajustando el modelo a través de la minimización de una función de pérdida para lograr la mejor aproximación posible. Nasteski (2017).

Naive Bayes. Es un clasificador probabilístico basado en el teorema de Bayes que asume independencia entre las características. Se utiliza para clasificación binaria o multiclase en tareas como filtrado de spam o clasificación de texto, y es eficiente incluso con pocos datos de entrenamiento, aunque su rendimiento puede verse limitado por la independencia de los atributos. Sarker, H. S. (2022).

Regresión logística/Logistic Regression. Regresión Logística. La regresión logística es un modelo estadístico de clasificación utilizado como referencia en estudios de predicción de lesiones deportivas. No es adaptativa como otros algoritmos de ML y es consistentemente superada por modelos modernos de aprendizaje automático (Amendolara et al., 2023)

Bosques Aleatorio/Random Forest. Es un método de ensamblaje supervisado que combina múltiples árboles de decisión entrenados en distintas submuestras de datos para mejorar la precisión y reducir el sobreajuste. Se puede usar en clasificación o regresión y funciona bien con datos categóricos y continuos. Sarker, H. S. (2022).

Adaptive Boosting (AdaBoost). Es un algoritmo de ensamble por boosting que representa una mejora significativa en capacidad predictiva respecto a la regresión logística clásica y a los árboles de decisión en los que se basa. Es más transparente que las redes neuronales y posee capacidad para manejar grandes conjuntos de variables, siendo especialmente útil en problemas de clasificación binaria como la predicción de lesiones deportivas (Amendolara et al., 2023).

Impulso de gradiente extremo (XGBoost). Es un algoritmo de aprendizaje automático que utiliza un marco de gradient boosting para resolver problemas de predicción. Su funcionamiento se basa en la construcción secuencial de árboles de decisión, donde cada árbol nuevo corrige los errores del anterior. Para evitar el sobreajuste y aumentar la generalización del modelo, se aplica validación cruzada de k-fold (Luu et al., 2020).

Máquina de vectores de soporte (SVM). Es un método supervisado que clasifica datos buscando un hiperplano que maximice la separación entre clases. Funciona bien en espacios de alta dimensión y con distintos núcleos, pero puede ser sensible al ruido o a clases solapadas. Sarker, H. S. (2022).

K-vecinos más cercanos (KNN). Es un algoritmo supervisado que predice la clase o valor de un punto basándose en la proximidad a sus k vecinos más cercanos, sin construir un modelo interno, siendo su rendimiento dependiente de la calidad de los datos y de la elección de k. Sarker, H. S. (2022).

Figura 3. *Procesamiento de múltiples datos*



Nota. Imagen generada con ChatGPT (OpenAI) a partir del prompt: "IA procesando grandes cantidades de datos". 2026.

Deep Learning/Aprendizaje Profundo (DL)

El aprendizaje profundo (DL) ha transformado significativamente el campo de la inteligencia artificial (IA), logrando un excelente rendimiento en diferentes aplicaciones y demostrando capacidades robustas en el manejo de grandes cantidades de datos y cálculos complejos.

Este campo, un subconjunto del aprendizaje automático (ML), utiliza arquitecturas que comprenden numerosas capas de nodos o neuronas, donde cada capa está diseñada para modelar patrones cada vez más complejos en los datos.

Las redes neuronales a menudo se dividen en aprendizaje superficial y profundo. Una distinción fundamental entre los modelos radica en el número de capas ocultas dentro de la red. Las redes superficiales, típicamente con una o dos capas ocultas, tienen una capacidad limitada para aprender características complejas, mientras que las redes neuronales profundas con múltiples capas ocultas son capaces de extraer características jerárquicas y realizar representaciones de datos más sofisticadas (Mienye, I.D; & Swart, T.G., 2024).

Mienye, I. D., & Swart, T. G. (2024). establece que los modelos de aprendizaje profundo tienen una serie de componentes como capas, funciones de activación, funciones de pérdida y algoritmos de optimización para aprender y realizar predicciones a partir de los datos.

Capas

Las capas son los componentes fundamentales de los modelos de aprendizaje profundo y determinan cómo se procesan y transforman los datos a medida que se mueven a través de la red. Un modelo típico de aprendizaje profundo consta de una capa de entrada, una o más capas ocultas y una capa de salida.

La capa de entrada recibe los datos sin procesar, como imágenes o texto, que luego pasan a través de las capas ocultas donde ocurren varios cálculos y transformaciones. Las capas ocultas son donde el modelo aprende a extraer características y patrones relevantes de los datos. Finalmente, la capa de salida produce la predicción o clasificación final basada en la información procesada (Mienye, I. D., & Swart, T. G, 2024).


Además de estas capas estándar, los modelos de aprendizaje profundo a menudo incorporan capas especializadas diseñadas para tareas específicas:

Capas convolucionales. se utilizan en las CNN (convolutional layer) para detectar jerarquías espaciales en datos de imágenes mediante la aplicación de filtros que aprenden a reconocer patrones como bordes y texturas.

Capas densas o completamente conectada. Generalmente se encuentran hacia el final de una red, conectan cada neurona con cada neurona en la capa anterior, lo que permite un razonamiento de alto nivel basado en las características extraídas por las capas anteriores.

Capas recurrentes. Como las que se utilizan en las RNN (recurrent layer) y sus variantes como las LSTM (long short-term memory) y las unidades recurrentes controladas (GRU gated recurrent unit), están diseñadas para capturar dependencias temporales en datos secuenciales, lo que las hace adecuadas para tareas que involucran series temporales o procesamiento del lenguaje natural. Estas capas especializadas permiten que los modelos de aprendizaje profundo manejen una amplia gama de tareas complejas al aprender y representar eficazmente patrones intrincados en los datos (Mienye, I. D., & Swart, T. G., 2024).

Figura 4. Aprendizaje Profundo



Nota. Imagen generada con ChatGPT (OpenAI) a partir del prompt: “Estructura del deep learning”. 2026.

Procesamiento Del Lenguaje Natural (PLN)

El Procesamiento del Lenguaje Natural (PLN) es una subdisciplina de la inteligencia artificial que se ocupa de la interacción entre humanos y computadoras mediante el lenguaje natural. Su objetivo es desarrollar algoritmos capaces de comprender, analizar y generar lenguaje humano.


El PLN tiene una amplia gama de aplicaciones, entre las que se incluyen la traducción automática, los chatbots, el análisis de sentimientos, el reconocimiento de voz, entre otras. También se ha aplicado en campos como la salud, las finanzas y el derecho, donde los datos en lenguaje natural son abundantes y valiosos (Dande, A. A., & Pund, M. A., 2023).

Dande, A. A., & Pund, M. A. (2023) describe aplicaciones y casos de uso de PLN:

- **Clasificación De Texto** consiste en asignar automáticamente a un texto una o varias categorías predefinidas según su contenido, para ello se utilizan diferentes algoritmos de ML. Sus aplicaciones incluyen el análisis de sentimiento, detección de spam y clasificación de noticias.
- **Reconocimiento de identidades** (NER), permite identificar y clasificar automáticamente entidades como personas, organizaciones, lugares o fechas dentro de un texto.
- **Análisis de sentimientos** busca identificar el tono emocional de un texto (positivo, negativo o neutral). Se aplica en áreas como redes sociales, marketing y reputación de marca.
- **Traducción automática** transforma textos de un idioma a otro de forma automática.
- **Reconocimiento de voz** convierte en texto al lenguaje verbal, con aplicaciones en asistentes virtuales, transcripción automática y aprendizaje de idiomas.

- **Word embeddings** son una técnica del PLN que representa palabras como vectores en un espacio de alta dimensión, capturando su significado semántico.
- **Algoritmos de PLN basados en contexto** analizan palabras y frases considerando su entorno, mejorando tareas como análisis de sentimientos, clasificación de textos y traducción automática.
- **Etiquetado de partes del habla** asigna categorías gramaticales a cada palabra de un texto, como sustantivos o verbos, y es clave en tareas como análisis de textos, generación de resúmenes y modelado de temas.
- **Modelado de temas** permite descubrir los tópicos principales de un texto a partir de la frecuencia y coocurrencia de las palabras, usando métodos de aprendizaje automático o basados en diccionarios.
- **Desambiguación del sentido de las palabras** determina el significado adecuado de una palabra según su contexto.

Figura 5. *Procesamiento del lenguaje natural.*



Nota. Imagen generada con ChatGPT (OpenAI) a partir del prompt: "Funcionamiento del PLN". 2026.


Dispositivos Tecnológicos Portátiles/Wearables

El desarrollo de dispositivos tecnológicos y wearables ha transformado la forma en que se registra y analiza la actividad física en corredores. Estos dispositivos permiten recopilar de manera continua datos relacionados con variables fisiológicas, biomecánicas y de entrenamiento, como la distancia recorrida, la velocidad, la frecuencia cardíaca o el tiempo de contacto con el suelo. La disponibilidad de este tipo de información ha favorecido la utilización de herramientas de inteligencia artificial, ya que los modelos pueden analizar grandes volúmenes de datos (los cuales se registran con estos dispositivos) para identificar patrones asociados al rendimiento o al riesgo de lesión. En este contexto, los wearables se convierten en una fuente clave de datos para el desarrollo de modelos orientados a la predicción de lesiones en corredores.

Los WT pueden describirse como dispositivos que se usan en el cuerpo, no invasivos e incorporan varios componentes electrónicos como sensores, unidades de comunicación, procesadores, actuadores y fuentes de energía. (Seçkin, Ateş, & Seçkin, 2023).

Son dispositivos del Internet de las Cosas (IoT) y constan de tres capas: sensor, procesamiento y red. Las dos primeras capas, sensor y procesador, abarcan todas las operaciones que se realizan únicamente en el hardware electrónico del WT. Además, diversos dispositivos externos, métodos de computación y protocolos de comunicación se incorporan a la capa de red como parte del WT. (Seçkin, Ateş, & Seçkin, 2023).

Figura 6. *Corredor utilizando wearables y dispositivos inteligentes*



Nota. Imagen generada con ChatGPT (OpenAI) a partir del prompt: “Persona corriendo, utilizando wearables”. 2026.

Sensores

Los sensores son dispositivos que detectan y miden cambios en variables físicas, fisiológicas o ambientales, transformando esa información en datos que pueden registrarse y analizarse.

En el deporte, permiten monitorear de forma objetiva distintos aspectos del rendimiento y del estado del atleta. Actualmente suelen venir integrados en dispositivos tecnológicos portátiles y wearables, como relojes o pulseras deportivas, que recopilan datos durante el entrenamiento.

Sensores fisiológicos. Según Seçkin, Ateş, & Seçkin (2023) los datos fisiológicos son proporcionados por sensores como EMG (electromiografía), ECG (electrocardiograma), EEG (electroencefalograma), oxímetros sensores de presión arterial (BPS) y otros dispositivos los cuales proporcionan información relevante sobre la salud y el rendimiento de una persona.

Sensores biomecánicos. La biomecánica es la aplicación de los principios de la ingeniería mecánica a los organismos vivos y abarca estudios a nivel tisular y articular. Implica la aplicación de fuerzas a los sistemas biológicos e incluye específicamente los efectos de las fuerzas aplicadas al cuerpo humano. En este ámbito, los datos de movimiento se refieren al uso de sensores para monitorizar los movimientos esqueléticos y la actividad muscular de los atletas. En el deporte, el sensor principal para la detección de movimiento es la IMU, aunque también se utilizan otros sensores como los de fuerza y los EMG. (Seçkin, Ateş, & Seçkin, 2023).

Sensores de Ubicación. Los sensores de localización se utilizan para rastrear los cambios de posición y los movimientos de los atletas. Los sistemas de posicionamiento portátiles más fundamentales. (Seçkin, Ateş, & Seçkin, 2023).

Sensores de condiciones ambientales. Son sensores que miden efectos ambientales como la calidad del aire, la humedad, la temperatura, la presión del aire y el nivel de luz UV. Estos sensores se utilizan para monitorear la condición del entorno donde están presentes los atletas. (Seçkin, Ateş, & Seçkin, 2023).

Fotoplethismografía (PPG). Según Jamieson et al. (2025) la PPG es una técnica óptica, no invasiva que mide cambios en el volumen sanguíneo mediante luz infrarroja a través de la piel. Permite estimar la FC (frecuencia cardíaca), su variabilidad, saturación de oxígeno, presión arterial y frecuencia respiratoria.

Unidad De Medición Inercial/IMU (inertial measurement unit)

Es un conjunto de sensores integrados los cuales pueden o no estar integrados en los dispositivos tecnológicos o wearables y aportar datos respecto al movimiento del corredor. En el deporte, las IMU se utilizan para analizar la técnica, medir la intensidad del movimiento, evaluar el rendimiento y detectar posibles riesgos de lesión.

Estos dispositivos permiten calcular la aceleración lineal y velocidad angular de los movimientos en tres ejes preestablecidos (x, y, z) de manera precisa y confiable lo anterior

captando la información brindada en la ejecución de movimientos por medio de un acelerómetro, el cual logra calcular la velocidad en relación con la ejecución del movimiento, traduciendo esta información a aceleración; y los cambios posicionales que se encargan de brindar información a los giroscopios, ofreciendo así la posibilidad de medir el posicionamiento de una estructura corporal en relación con un punto fijo (Castellanos-Ruíz et al., 2021).

A través de estos sensores que vienen incluidos en las wearables se recolecta información y datos de los corredores, para posteriormente, en base a estos datos entrenar a la inteligencia artificial para realizar la predicción de lesiones. La cual para evaluar su efectividad se basa en diferentes métricas.

Métricas de evaluación de algoritmos

En el campo de la predicción de lesiones en corredores, conocer el rendimiento real de un modelo de inteligencia artificial es tan importante como el modelo en sí. Una predicción incorrecta puede significar que un corredor en riesgo no reciba atención preventiva a tiempo, o que recursos sean destinados a casos que no los necesitan. Por eso, la elección y correcta interpretación de las métricas de rendimiento resulta fundamental.

Evaluar si un modelo de inteligencia artificial realmente funciona bien no es una tarea simple. Las métricas de rendimiento son útiles tanto durante el entrenamiento del modelo como en su validación, y permiten entender con precisión qué está haciendo bien y qué está fallando (Erickson y Kitamura, 2021).

El punto de partida es siempre la matriz de confusión, una tabla que organiza los resultados del modelo en cuatro categorías (Erickson y Kitamura, 2021):

- **Verdaderos positivos (true positives, TP):** casos positivos que el modelo detectó correctamente.
- **Verdaderos negativos (true negatives, TN):** casos negativos que el modelo también clasificó bien.

- **Falsos positivos (false positives, FP):** casos negativos que el modelo confundió con positivos.
- **Falsos negativos (false negatives, FN):** casos positivos que el modelo no logró detectar.

A partir de esos cuatro valores se calculan todas las demás métricas (Erickson y Kitamura, 2021).

Las principales métricas que se derivan de la matriz de confusión son las siguientes (Erickson y Kitamura, 2021):

- **Sensibilidad (sensitivity / recall, TPR):** indica qué fracción de los casos positivos reales el modelo identificó correctamente. Es crítica en medicina, donde lo último que se quiere es que el modelo pase por alto un caso real.
- **Especificidad (specificity):** hace lo mismo, pero para los casos negativos, midiendo qué fracción de los casos realmente negativos fueron identificados como tales.
- **Valor predictivo positivo (VPP / positive predictive value, PPV):** también conocido como precisión (precision), indica qué proporción de los casos que el modelo marcó como positivos eran realmente positivos.
- **Valor predictivo negativo (VPN / negative predictive value, NPV):** la contraparte del anterior, indica qué proporción de los casos clasificados como negativos eran realmente negativos.
- **Exactitud (accuracy, ACC):** la más conocida y simple, dice qué fracción del total de casos el modelo clasificó correctamente. Sin embargo, puede ser engañosa cuando los datos están desbalanceados.
- **F1-score:** combina precisión y sensibilidad en un solo número a través de su media armónica, penalizando los valores extremos de cualquiera de las dos.

Las siguientes dos métricas adicionales resultan especialmente útiles cuando se quiere evaluar el modelo de forma más global (Erickson y Kitamura, 2021):

- **Curva ROC y AUC-ROC (receiver operating characteristic / area under the ROC curve):** muestra gráficamente el balance entre sensibilidad y tasa de falsos positivos (false positive rate, FPR) a distintos umbrales de decisión. Un AUC-ROC de 1 representa un modelo perfecto, mientras que un valor de 0.5 equivale a adivinar al azar. Su ventaja es que resume el rendimiento general del modelo sin depender del umbral elegido, aunque no define cuál umbral usar en la práctica.
- **Curva precisión-recall y AUC-PRC (precision-recall curve / area under the precision-recall curve):** representa la relación entre precisión y sensibilidad del modelo. Esta métrica resulta especialmente útil cuando existe un fuerte desbalance entre clases, es decir, cuando una de ellas es mucho más frecuente que la otra.

Variables Biomecánicas

Variables biomecánicas son utilizadas como dato para la predicción, de igual forma que variables de carga de entrenamiento (distancia recorrida, desnivel, ritmo de carrera, etc.) y variables fisiológicas/vitales (frecuencia cardiaca, frecuencia respiratoria, saturación de oxígeno, etc.) dependiendo con que datos se entrene el modelo se realiza la predicción en este apartado se describen las principales variables biomecánicas utilizadas como predictores de lesión.

Cadencia

La cadencia es definida como el número de pasos por minuto, se ha identificado como uno de los factores más influyentes y modificables para optimizar la mecánica de la carrera y reducir el riesgo de lesiones. Los valores típicos de cadencia en corredores recreativos varían de 150 a 170 pasos por minuto, mientras que los corredores de élite a menudo superan los 180 pasos por minuto. (Figueiredo, Silva, & Sousa, 2025).

Fuerzas de reacción al suelo (GRF)

La fuerza de reacción del suelo (GRF, por sus siglas en inglés) se define según (Adams et al., 2018). Como la fuerza que el suelo ejerce sobre el cuerpo durante la carrera y cuya magnitud y características se relacionan con el desarrollo de lesiones. En este sentido, se afirma que “los altos niveles de ciertas métricas de fuerzas de reacción del suelo durante la carrera se asocian con el desarrollo de lesiones comunes relacionadas con la carrera”, lo que pone de manifiesto su relevancia clínica en corredores (Adams et al., 2018). Específicamente, en su estudio describe el componente vertical de esta fuerza, señalando que “las altas tasas de carga vertical promedio e instantánea (AVLR e IVLR, respectivamente) de las fuerzas de reacción del suelo vertical se asocian con corredores con fractura por estrés tibial, fasciopatía plantar y dolor patelofemoral”. Asimismo, se menciona que “los altos niveles de la fuerza de reacción vertical del suelo máxima (vGRF máxima) se han asociado con dolor de rodilla y otras lesiones relacionadas con la carrera”. La GRF es la fuerza generada por el contacto del pie con el suelo durante la carrera, la cual puede analizarse mediante métricas como la tasa de carga vertical, la fuerza vertical máxima y el impulso de frenado, parámetros que se han vinculado con distintas lesiones en corredores.

Oscilación vertical

La oscilación vertical se define como el desplazamiento vertical del centro de masa del corredor durante cada ciclo de carrera, es decir, cuánto "rebota" el cuerpo hacia arriba y hacia abajo en cada zancada. Adams et al. (2018) establecen que valores elevados de oscilación vertical se asocian con un mayor gasto energético y una mayor carga sobre las estructuras articulares del miembro inferior, lo que incrementa el riesgo de lesión. En sentido contrario, una oscilación vertical reducida se relaciona con una mecánica de carrera más eficiente y económica. Esta variable es frecuentemente registrada mediante

dispositivos wearables y constituye uno de los parámetros biomecánicos más utilizados para el entrenamiento y la prevención de lesiones en corredores (Adams et al., 2018).

Carga interna y carga externa

La carga de entrenamiento puede clasificarse en dos dimensiones complementarias. La carga externa hace referencia a los estímulos físicos objetivos impuestos al corredor, como la distancia recorrida, la velocidad, el desnivel acumulado y el tiempo de contacto con el suelo. La carga interna, en cambio, representa la respuesta fisiológica y perceptual del organismo ante esos estímulos, e incluye variables como la frecuencia cardíaca, la percepción subjetiva del esfuerzo (RPE) y los niveles de fatiga acumulada. Según Dudley et al. (2023), el desequilibrio entre ambas cargas, particularmente cuando la carga externa aumenta de forma abrupta sin que el organismo haya tenido tiempo de adaptarse, es uno de los principales factores de riesgo de lesión en atletas. En el contexto del running, el monitoreo conjunto de la carga interna y externa mediante wearables y algoritmos de inteligencia artificial permite detectar patrones de sobreentrenamiento y anticipar situaciones de riesgo antes de que se produzca la lesión.

Impacto y carga biomecánica acumulada

El impacto hace referencia a las fuerzas mecánicas que actúan sobre el sistema musculoesquelético del corredor en cada contacto con el suelo, incluyendo la tasa de carga vertical, el pico de impacto y la carga acumulada a lo largo de una sesión de entrenamiento. Rahlf et al. (2022), en un protocolo de estudio prospectivo longitudinal orientado a identificar factores de riesgo de lesión en corredores mediante machine learning, incluyen parámetros como la longitud de zancada, la cadencia, la cinemática articular y la carga biomecánica acumulada como variables predictoras centrales. Los autores señalan que la combinación de estas variables biomecánicas con datos de entrenamiento y características individuales del corredor potencia significativamente la capacidad predictiva de los modelos de IA, superando el rendimiento de los métodos de evaluación tradicionales.

Tiempo de contacto con el suelo

El tiempo de contacto con el suelo (TCE) se define como el intervalo de tiempo durante el cual el pie permanece en contacto con la superficie durante cada zancada. Es una variable espacio-temporal clave registrada habitualmente mediante wearables y su análisis es fundamental para comprender la mecánica de la carrera. Anderson et al. (2022) demostraron en su revisión sistemática y metaanálisis que aumentar la cadencia de carrera produce un tiempo de contacto con el suelo más corto, favoreciendo una distribución más equilibrada de las cargas articulares. Valores elevados de TCE se asocian con una mayor carga acumulada sobre las estructuras del miembro inferior siendo relevante su monitoreo continuo en corredores recreativos y de élite.

Longitud de zancada

La longitud de zancada se define como la distancia horizontal recorrida entre dos contactos sucesivos del mismo pie con el suelo, y constituye una de las variables espacio-temporales más estudiadas en relación con el riesgo de lesión en running. Rahlf et al. (2022) señalan que "debido a las razones frecuentemente multifactoriales e individuales de las lesiones en corredores, se requiere un cambio en el pensamiento para dar cuenta del proceso dinámico de los diversos factores de riesgo" e incluyen la longitud de zancada como uno de los parámetros biomecánicos centrales de su protocolo de ML.

Figura 7. Variables biomecánicas.



Nota. Imagen generada con ChatGPT (OpenAI) a partir del prompt: “Carrera analizada en laboratorio”. 2026.

Estado Del Arte

Según la literatura existente la IA revoluciona la ciencia del deporte. “Actualmente, la IA permite a los científicos deportivos aprovechar conjuntos de datos masivos que antes eran demasiado complejos para el análisis manual, transformándolos en información práctica. Esta información abarca diversas aplicaciones, como la gestión de la carga, la prevención de lesiones, la exploración y la optimización del rendimiento”. (Mateus et al., 2025)

El avance tecnológico y la utilización de dispositivos portátiles (wearables) con la capacidad de obtener al momento datos fisiológicos, (frecuencia cardiaca, frecuencia respiratoria, sensación de fatiga, sueño, estrés...) datos del terreno, variables de entrenamiento como ritmo de carrera, desnivel del terreno, distancia recorrida, velocidad

media, etc. A demás dispositivos que tienen integrados IMUs (unidades de medición inercial) que traen incorporados acelerómetros y giroscopios que pueden medir aceleración en los 3 ejes y rotaciones. Dispositivos los cuales incluyen GRF (fuerzas de reacción al suelo) que en conjunto aportan métricas y datos que según Mateus et al. (2025) “Al combinarse con la IA, estos datos pueden refinar los programas de entrenamiento, optimizar los protocolos de recuperación y minimizar el riesgo de sobreentrenamiento y lesiones relacionadas”.

Un ejemplo del sobre wearables se puede evidenciar en Berzosa et al. (2024) “Este estudio investigó las evaluaciones biomecánicas en carreras de trail, comparando dos dispositivos portátiles: el medidor de potencia Stryd y el GARMIN RP”.

Investigación realizada en España, con el objetivo de comparación de dispositivos portátiles, se observa en sus resultados la fiabilidad de los dispositivos al obtener los datos. Métricas evaluadas (potencia, velocidad, cadencia, oscilación vertical y tiempo de contacto con el suelo). Berzosa et al. (2024)

A partir de estos datos o métricas se pueden entrenar modelos o algoritmos de IA para la predicción de lesiones. Raju et al. (2026) quien realizo una comparación en la utilización de machine learning con diferentes algoritmos en 200 atletas universitarios que realizaban prácticas deportivas diferentes. “Las variables que se incluirán en el conjunto de datos son carga de trabajo, recuperación, rendimiento y factores demográficos” Raju et al. (2026) Utilizo modelos de aprendizaje cruzado basados en aprendizaje supervisado:

Tabla 1. *Modelo de IA utilizado*

Modelos	Accuracy	Precisión	Recall	F1-Score	ROC.AUC
Random Forest	0,98	1,00	0,70	0,81	0.97

XGBoost	0,97	0,83	0,70	0,75	0.92
ANN	0,95	0,73	0,40	0,49	0,95

Estas métricas representan según Raju et al. (2026) “alta capacidad de discriminación, además de poder manejar respuestas categóricas y continuas mixtas, características de los registros deportivos estructurados. El modelo identificó correctamente 28 atletas lesionados y 160 no lesionados.

Hubo 12 casos de lesiones que fueron identificados incorrectamente como no lesionados.

No se produjeron falsos positivos (predicciones de lesión incorrectas), lo que explica la exactitud perfecta (1,00) para la clase no lesionada”.

Ren et al. (2024) “En este artículo, se utiliza el algoritmo de aprendizaje profundo para estudiar un sistema de monitoreo en tiempo real de lesiones deportivas”. El artículo presenta un esquema de diseño integral para un sistema de monitoreo de lesiones deportivas, integrando hardware y software, lo que permite una supervisión y análisis completos de las lesiones deportivas.

Los pasos específicos de este método son los siguientes:

- Detección de video
- Detección de articulaciones humanas
- Análisis y ajuste polinómico
- Cálculo de la media
- Eliminación de la media (centrado)
- Reducción de dimensionalidad

- Clasificador SVM

Se aplicó este modelo a 30 participantes los cuales cada 1/3 practicaba un deporte o disciplina diferentes (10 running, 10 aeróbicos y 10 tenis de mesa). La comparación fue del sistema propuesto (DL) y los métodos tradicionales basados en experiencia humana.

Sistema propuesto (DL) **running** >94% (promedio 96.28%) **aeróbico** 91–96% (promedio 93.55%) **tenis de mesa** 85–90% (promedio 87.68%).

Métodos tradicionales **running** 89–95% (promedio 92.13%) **aeróbico** 88–92% (promedio 90%) **tenis de mesa** 82–86% (promedio 83.76%).

El sistema basado en aprendizaje profundo mejora la precisión promedio en 3.87% frente al método tradicional.

Li, Wang y Chen (2025) en su estudio implementa un enfoque híbrido de inteligencia artificial que combina **procesamiento de lenguaje natural (PLN)** mediante un modelo de lenguaje profundo tipo transformer (RoBERTa) con machine learning supervisado, específicamente un Random Forest optimizado, para analizar datos clínicos estructurados y no estructurados y mejorar la predicción de riesgo en atletas.

Según Li, Wang y Chen (2025) el modelo aprovecha la minería de textos biomédicos basada en PLN y el aprendizaje automático para clasificar arritmias, miocardiopatía hipertrófica (MCH) y otras afecciones cardiovasculares con alta precisión.

- 92,5 % de precisión diagnóstica, garantizando una alta fiabilidad en la clasificación del riesgo cardiovascular.
- 92,7 % de precisión, minimizando falsos positivos en la predicción de enfermedades.
- 99,23 % de recuperación (sensibilidad), capturando casi todos los casos reales de riesgo cardiovascular.

- Puntuación F1 del 95,6 %, que equilibra la precisión y la recuperación para una clasificación óptima.
- AUC-ROC del 98,1 %, lo que demuestra la capacidad del modelo para distinguir entre casos con enfermedad y sin enfermedad.
- Tasa de falsos negativos (FNR) del 2,1 %, lo que indica un riesgo bajo de pasar por alto pacientes de alto riesgo.

“Los profesionales de la salud utilizan la minería de textos biomédicos, combinada con registros clínicos estructurados y algoritmos de aprendizaje automático en sus sistemas para detectar arritmias y miocardiopatía hipertrófica”. (Li, Wang & Chen, 2025).

Hipótesis

En el running la IA es una herramienta eficaz para la predicción de lesiones.

Objetivos

Objetivo General

Confirmar la efectividad de la inteligencia artificial en la predicción de lesiones en corredores, mediante una revisión bibliográfica.

Objetivos Específicos

- Comparar los resultados obtenidos por distintos algoritmos en términos de precisión.
- Identificar los modelos de IA más utilizados en la predicción de lesiones deportivas en corredores.
- Describir las variables biomecánicas más utilizadas como predictores de lesión en corredores (GRF, cadencia, oscilación vertical, impacto, carga interna/externa, etc.).

Metodología

Diseño

El presente trabajo es de tipo no experimental con un enfoque mixto, de carácter descriptivo, basado en el análisis documental de estudios científicos publicados. El estudio se basa en la recopilación, revisión y análisis de evidencia científica reciente sobre IA y su funcionamiento, teniendo en cuenta la falta de literatura de modelos específicos de IA en running se adaptarán y orientarán al objetivo de investigación.

Se eligió este enfoque mixto que conforma una característica cuantitativa porque analiza resultados numéricos, tales como métricas de rendimiento de los modelos de predicción (precisión, sensibilidad, especificidad, AUC, tasas de incidencia de lesión, entre otros), lo que permite evaluar objetivamente la efectividad de la inteligencia artificial. A su vez, es cualitativo porque interpreta y analiza de manera crítica la aplicación de estos modelos, las variables biomecánicas utilizadas y su relevancia en el contexto de la prevención de lesiones.

Muestreo

Dado el diseño no experimental basado en revisión y análisis documental, se aplica un muestreo no probabilístico intencional o por conveniencia, orientado a seleccionar aquellos estudios que cumplan con los criterios de inclusión y exclusión respecto al objeto de estudio.

Método de búsqueda

La búsqueda bibliográfica se realizó en las bases de datos PubMed, SciELO, PEDro y ScienceDirect, complementada con el uso de asistentes de inteligencia artificial como apoyo para la identificación inicial de referencias. Todos los artículos identificados fueron verificados individualmente confirmando su existencia a través de su DOI o URL oficial antes de su inclusión.

La búsqueda se realizó en inglés y español mediante operadores booleanos (AND, OR) combinando los siguientes términos: running-related injuries, sports injury prediction, artificial intelligence, machine learning, deep learning, wearables, biomechanics y natural language processing.

Los resultados fueron filtrados aplicando los criterios de inclusión y exclusión definidos, priorizando publicaciones entre 2021 y 2026 en revistas científicas revisadas por pares y de acceso abierto. Se seleccionaron los artículos de mayor relevancia con respecto al objetivo de investigación, conformando una muestra final de 13 artículos para su análisis.

Tabla 2. *Criterios de inclusión y exclusión*

Criterios de Inclusión	Criterios de Exclusión
Artículos que apliquen mínimo un modelo de IA: Machine learning/aprendizaje automático (ML), deep learning/aprendizaje profundo (DI) o procesamiento del lenguaje natural (PLN) para predicción.	Estudios cuya aplicación de la IA sea exclusivamente para deportes que no comprenden carrera (running).
Artículos originales, revisiones sistemáticas, revisiones narrativas publicadas en revistas científicas revisadas por pares (peer review) o en repositorios académicos reconocidos.	Estudios publicados anteriores al año 2021
Estudios que al menos aporten métricas de rendimiento de modelos	Artículos con acceso restringido o modalidad de pago

• Artículos con menos de 5 años de antigüedad (periodo 2021-2026)	
---	--

Categorización De Variables

Tabla 3. Variables categorizadas

Variable conceptual	Variable Operacional	Indicador	Instrumento
Tipo de estudio	Cualitativa nominal	1. Estudios predictivos con datos reales 2. Estudios predictivos con datasets* 3. Revisión sistemática con o sin metaanálisis 4. Revisión narrativa 5. otro	Artículos seleccionados
Edad del deportista	Cuantitativa Discreta agrupada	1. Menor a 18 2. 19 – 30 3. 31 – 50 4. Mayor de 50 5. No informa	Artículos seleccionados
Sexo del deportista	Cualitativa nominal	1. Hombre 2. Mujer 3. Ambos 4. No informa	Artículos seleccionados
Historial de lesiones previas	Cualitativa nominal	1. Si 2. No 3. No informa	Artículos seleccionados
Nivel de experiencia del deportista	Cualitativa nominal	1. Novato 2. Recreativo 3. Elite 4. Otro 5. No informa	Artículos seleccionados

Subcampos de IA utilizados	Cualitativa nominal	1. Machine learning 2. Deep learning 3. Procesamiento del lenguaje natural 4. Mixto	Artículos seleccionados
Algoritmos/modelos empleados	Cualitativa nominal	1. Random forest 2. Árboles de decisiones 3. Máquina de vectores de soporte (SMV) 4. XGBoost 5. Regresión logística 6. K-vecinos más cercanos (KNN) 7. Redes neuronales convolucionales (CNN) 8. Red neuronal recurrente (RNN) 9. Redes neuronales de memoria a corto y largo plazo (LSTM) 10. Red neuronal gráfica (GNN) 11. Red neuronal artificial (ANN) 12. Naive bayes 13. Aumento de gradiente extremo 14. Transformer 15. Otros 16. No aplica	Artículos seleccionados
Variables de predicción para entrenamiento de algoritmo	Cualitativa nominal	1. Biomecánicas 2. Fisiológicas/vitales 3. Carga de entrenamiento 4. Mixto 5. No informa	Artículos seleccionados

Métricas de rendimiento de los algoritmos	Cualitativa nominal	1. Accuracy (Exactitud del modelo) 2. Precision (Precisión del modelo) 3. Recall (Sensibilidad del modelo) 4. F1-Score 5. AUC-ROC 6. Tasa de falsos negativos (FNR) 7. Híbrido (combinación de más de una)	Artículos seleccionados
Efectividad del modelo	Cualitativa ordinal	Alta* Moderada* Baja*	Artículos seleccionados

Notas. * Notas. ***Alta**: evidencia fuerte de efectividad, **Moderada**: evidencia razonable pero no concluyente, **Baja**: Evidencia insuficiente / pobre desempeño. ***Dataset**: es un conjunto estructurado de datos organizado para su análisis. Estos datos pueden provenir de registros reales, bases de datos públicas o datos sintéticos generados artificialmente.

Métodos De Síntesis

Se realizó una síntesis descriptiva de los artículos incluidos, orientada a describir el uso y la aplicación de la inteligencia artificial para la predicción de lesiones en running. Esta información fue organizada en la **Tabla 4**, que permitió obtener una visión general de aspectos clave como el tipo de estudio, las características de la población, el subcampo de IA utilizado, las variables de predicción empleadas para el entrenamiento de los algoritmos, las métricas de rendimiento reportadas y la efectividad del modelo.


Los resultados fueron clasificados y registrados conforme a las variables previamente definidas en la categorización. A partir de esta tabla, utilizando Microsoft Excel, se elaboraron gráficos de barras univariados para cada variable, permitiendo visualizar su frecuencia y distribución dentro de la muestra. Complementariamente, se elaboraron gráficos de barras

bivariados para examinar la posible relación entre la efectividad del modelo y las demás variables cualitativas analizadas.

Resultados

Tabla 4. *Artículos seleccionados*


Autor	Tipo de estudio	Edad del deportista	Sexo del deportista	Historial de lesiones previas	Nivel de experiencia del deportista	Subcampos de IA	Algoritmos/modelos empleados	Variables de predicción	Métricas de rendimiento	Efectividad del modelo
Amendola et al. (2023)	Revisión narrativa	No informa	No informa	No informa	No informa	Machine learning	No aplica	No informa	Híbrido	Moderada
Dimmick et al. (2023)	Artículo con datos reales	19-30/31-50	Ambos	No informa	Recreativo/otro	Machine learning	Random Forest	Biomecánicas	Accuracy	Baja
Leckey et al. (2025)	Revisión sistemática	No informa	No informa	Si	Recreativo/elite	Machine learning	No aplica	No informa	Híbrido	Moderada
Raju et al. (2026)	Artículo con datasets	No informa	Ambos	Si	Recreativo/otro	Machine learning	1-4-11	Carga de entrenamiento	Híbrido	Alta
Ren et al. (2024)	Artículo con datasets	No informa	No informa	No informa	No informa	Mixto	3-7	Biomecánicas	Accuracy	Alta
Van Eetvelde et al. (2021)	Revisión sistemática	No informa	No informa	No informa	No informa	Machine learning	No aplica	No informa	Híbrido	Moderada
Wu et al. (2026)	Artículo con datos reales	Menor 18/19-30/31-50	Ambos	Si	Recreativo/otro/elite	Machine learning	1-2-3-5-6-12--15	Mixto	AUC-ROC	Baja
Yuan et al. (2025)	Revisión narrativa	No informa	No informa	No informa	No informa	Machine learning	No aplica	No informa	Híbrido	Moderada
Li et al. (2025)	Artículo con datasets	No informa	No informa	No informa	No informa	Mixto	Random forest-Transformer	Fisiológicas/vitales	Híbrido	Alta
Nuyts et al. (2022)	Artículo con datos reales	19-30	Ambos	Si	Recreativo	Machine learning	Regresión logística	Biomecánicas	AUC	Baja
Souaifi et al. (2025)	Revisión sistemática	No informa	No informa	No informa	No informa	Mixto	No aplica	No informa	Híbrido	Moderada
Fang y Chen (2025)	Artículo con datasets	No informa	No informa	No informa	No informa	Deep learning	Red neuronal grafica (GNN)	Carga de entrenamiento	AUC	Moderada
Ye et al. (2023)	Artículo con datasets	No informa	No informa	No informa	No informa	Deep learning	Redes neuronales convolucionales	Carga de entrenamiento	Híbrido	Moderada

Gráfico 1. Tipos de estudio

Este gráfico representa la cantidad y los tipos de estudios utilizados para el análisis de datos. Del total de 13 artículos ($N = 13$), se identificaron ($n=5$) artículos que utilizan datasets en sus diseños (38%); ($n=3$) revisiones sistemáticas (23%); ($n=2$) revisiones narrativas (15%); y ($n=3$) artículos que utilizan población real para la predicción (23%).

Se observa que más de la mitad de los estudios incluidos en la muestra corresponden a diseños que no trabajan con poblaciones reales, siendo los artículos predictivos con datasets el grupo predominante, seguidos por las revisiones sistemáticas y narrativas. Solo una porción menor de los estudios aplica modelos de IA sobre datos obtenidos directamente de corredores. Esto sugiere que, si bien la producción científica en el área es activa, la evidencia basada en poblaciones reales aún es limitada, lo que podría condicionar la generalización de los resultados y su aplicabilidad directa en contextos clínicos o deportivos.


Gráfico 2. Edad del deportista



El grafico 2 nos muestra los grupos etarios de la población de los artículos analizados (N = 13). La mayoría de los estudios, (n=10) 77%, no informa la edad de los deportistas. Además, (n=1) 8% de los artículos reporta dos grupos etarios 19–30 y 31–50 años. Por otra parte, (n=1) 8% presenta tres indicadores etarios <18, 19–30 y 31–50 años. Finalmente, (n=1) 8% informa únicamente el rango etario de 19–30 años.

La mayoría de los estudios analizados omite reportar la edad de los participantes, y aquellos que sí la informan presentan rangos etarios acotados, concentrados principalmente en adultos jóvenes. Esta ausencia sistemática impide analizar si la edad opera como variable diferencial en la efectividad de los modelos de predicción, lo que representa una limitación relevante dado que el perfil etario del corredor puede influir tanto en la biomecánica como en el riesgo de lesión, aspectos que difieren considerablemente entre un corredor joven y uno de mayor edad.

Gráfico 3. Sexo del deportista



Este grafico es la representación de distribución de sexo en los respectivos estudios (N=13), de los cuales el 77% no informan el sexo del participante (n=10), los artículos restantes (n=3) presentan participación de ambos sexos conformando el 23% restante del total.

Se evidencia que la mayoría de los estudios incluidos no informa el sexo de los participantes. Sin embargo, en los trabajos que, si reportan esta variable, la predicción de lesiones se realizó considerando la participación de ambos sexos. Esto sugiere que el sexo no es una variable frecuentemente diferenciada en los estudios analizados, por lo que su influencia específica en la predicción de lesiones mediante inteligencia artificial no puede determinarse con claridad a partir de la evidencia disponible.

Gráfico 4. *Historial de lesiones previas en miembro inferior*




Gráfico 4 muestra los artículos que tomaron en cuenta el historial de lesiones previas en miembro inferior, de la muestra total (N=13). 9 artículos (n=9) no informan sobre el historial de lesiones representando un 69%, 4 (n=4) de la muestra informan historial previo de lesiones de miembro inferior representando un 31%.

Se observa que varios estudios consideran el historial de lesiones previas como una variable dentro de los conjuntos de datos utilizados para entrenar los modelos de predicción. No obstante, en algunos trabajos esta información no es reportada o no se incluye dentro de las variables analizadas, lo que evidencia cierta heterogeneidad en la consideración de este factor dentro de los estudios.

Gráfico 5. Nivel de experiencia del deportista





Gráfico 5 muestra el nivel de experiencia del deportista según los estudios recopilados, del total de la muestra (N=13). Un 62% (n=8) no informa el nivel de experiencia. 8% (n=1) su nivel de experiencia es recreativo, 8% (n=1) con una combinación de recreativo/otro/elite, (n=1) recreativo/elite. 2 artículos (n=2) recreativo/otro 15%.

En cuanto al nivel de experiencia, se observa que los estudios analizan deportistas con distintos niveles de práctica, incluyendo atletas recreativos, universitarios y de mayor nivel competitivo. Sin embargo, varios trabajos no especifican con precisión el nivel deportivo de los participantes, lo que dificulta establecer comparaciones directas entre las poblaciones analizadas.

Gráfico 6. Algoritmo empleado




Representación de la frecuencia de algoritmos utilizados en la muestra total (N=13).

random forest fue el algoritmo con más aparición en los estudios representando un 31% (n=4). Seguido de SMV (máquina de vectores de soporte), regresión logística y redes neuronales convolucionales (CNN) con un 15% cada uno (n=3). Mientras que con un 8% cada uno (n=1) encontramos a K-vecinos más cercanos (KNN), XGBoost, redes neuronales artificiales (ANN), naive bayes, arboles de decision, transformer, GNN y otros. El 38% (n=5) restante corresponde a artículos que no aplicaron de forma práctica los algoritmos. Nota. La frecuencia de cada algoritmo fue calculada en relación con el total de estudios de la muestra (N = 13). Dado que varios artículos emplean más de un algoritmo simultáneamente, la suma de los porcentajes supera el 100%.

En cuanto al uso de algoritmos, se observa que la mayoría de los estudios no aplican modelos de inteligencia artificial de forma práctica. Entre aquellos que si lo implementan random forest aparece como el más utilizado, además se identificaron otros algoritmos de aprendizaje supervisado y redes neuronales con menor frecuencia, sin embargo, esto deja en evidencia la diversidad de enfoques de los estudios analizados.


Gráfico 7. Subcampo de IA utilizado



El grafico 7 representa los subcampos de IA que fueron utilizados en los estudios, de la muestra total (N=13). 8 estudios presentaron aplicación pura de Machine learning 62%. 2 estudios con aplicación de deep learning 15% y 3 artículos utilizaron una combinación de estas arquitecturas 23%.

El machine learning se consolida como el subcampo predominante en los estudios analizados, mientras que el deep learning y los enfoques mixtos representan una proporción considerablemente menor. Esta distribución indica que, a pesar del auge del aprendizaje profundo en otras áreas de la salud, su adopción en la predicción de lesiones en running aún es incipiente. La presencia de enfoques mixtos sugiere, no obstante, una tendencia hacia la integración de múltiples arquitecturas en búsqueda de mayor capacidad predictiva.

Gráfico 8. *Variable de predicción para entrenamiento de algoritmos*



El gráfico 8 representa las variables con las que fueron entrenados los modelos para la predicción, de la muestra total (N=13). El 38% (n=5) no informan sobre las variables; el 23% (n=3) utilizaron variables biomecánicas. En igual valor 23% de los artículos utilizaron variables de carga de entrenamiento. 8% (n=1) variables fisiológicas/vitales y el 8% (n=1) de la muestra total utilizaron variables mixtas combinando las anteriores.

Una proporción considerable de los estudios no informa las variables utilizadas para el entrenamiento de los modelos, lo que limita la reproducibilidad y comparabilidad de los resultados. Entre los estudios que sí las reportan, las variables biomecánicas y las de carga de entrenamiento son las más frecuentes, con escasa presencia de variables fisiológicas y combinaciones mixtas. Esto sugiere que la integración de múltiples tipos de variables en el entrenamiento de los algoritmos aún no está sistematizada, pese a que la naturaleza multifactorial de las lesiones en running requeriría un enfoque más comprehensivo.

Gráfico 9. Métricas de los rendimientos de algoritmos





Gráfico 9 representa las métricas utilizadas para evaluar el rendimiento de los algoritmos de inteligencia artificial entrenados. 8 estudios de la muestra total (N=13) presentaron métricas híbridas incluyendo más de una métrica para la evaluación (n=8) representando un 62%, 2 (n=2) estudios de la muestra utilizaron accuracy como métrica única representando un 15%. Por último, 23% de los estudios (n=3) utilizaron AUC como métrica única.

Se observa que la mayoría de los estudios utiliza más de una métrica para evaluar el rendimiento de los modelos, lo que refleja una tendencia hacia evaluaciones más completas que contemplan distintas dimensiones del desempeño predictivo. Sin embargo, la heterogeneidad en las métricas empleadas entre estudios dificulta la comparación directa de resultados y la determinación de un estándar de evaluación para los modelos de IA aplicados a la predicción de lesiones en running.


Gráfico 10. Efectividad del modelo



El grafico 10 Representa la efectividad de los modelos de IA en base a los criterios anteriormente mencionados en las variables. De la muestra total (N=13) un 54% (n=7) de los artículos presentan una efectividad moderada. Mientras que el 23% (n=3) con efectividad baja y por último el 23% (n=3) presenta una efectividad alta respecto a los criterios antes mencionados.

Más de la mitad de los modelos analizados presenta una efectividad moderada, mientras que la efectividad alta y baja se distribuyen en proporciones iguales entre el resto de la muestra. Estos resultados indican que, si bien la IA demuestra potencial en la predicción de lesiones en corredores, la evidencia disponible no es suficientemente sólida como para afirmar su efectividad de manera concluyente, evidenciando la necesidad de estudios con mayor rigor metodológico y validación externa.

Gráfico 11. Efectividad del modelo-Subcampo de IA aplicado.



Representación de efectividad de la IA según el subcampo utilizado. Machine learning presenta 8% (n=1) de alta efectividad, 23% (n=3) efectividad baja y 31% (n=4) efectividad moderada. Los enfoques mixtos con 8% (n=1) artículos de efectividad moderada y 15% (n=2) efectividad alta. Mientras que deep learning presenta 15% (n=2) artículos con efectividad moderada.

Al analizar la efectividad en función del subcampo de IA utilizado, se observa que los enfoques mixtos concentran una mayor proporción de resultados de efectividad alta en relación con su representación en la muestra. El machine learning, siendo el subcampo más utilizado, presenta resultados distribuidos entre las tres categorías de efectividad, con predominancia moderada. El deep learning, por su parte, muestra únicamente efectividad moderada en los estudios analizados. Esto sugiere que la combinación de múltiples arquitecturas de IA podría asociarse a un mejor desempeño predictivo, aunque el reducido número de estudios en cada subcampo limita la posibilidad de establecer conclusiones definitivas al respecto.

Discusión

Los resultados de esta revisión no permiten afirmar que la inteligencia artificial sea completamente eficaz para predecir lesiones en corredores, sin embargo, tampoco permiten descartarla como herramienta útil complementaria. Esto se debe a diversos factores que influyen en la evaluación de su efectividad (determinadas por las métricas de rendimiento). El desempeño de los modelos no depende únicamente de la arquitectura o del algoritmo utilizado, sino también de la calidad, cantidad y representatividad de los datos con los que son entrenados. En muchos casos, los datasets presentan tamaños de muestra reducidos, registros incompletos o poblaciones muy específicas, lo que limita la capacidad de generalización de los modelos. Por otra parte, la heterogeneidad de los datos y la falta de estandarización en las variables analizadas pueden afectar el rendimiento de los algoritmos. A esto se suma el riesgo de sobreentrenamiento (overfitting), que ocurre cuando el modelo se ajusta demasiado a los datos de entrenamiento y pierde precisión al aplicarse en nuevos contextos. También influyen aspectos metodológicos, como las diferentes definiciones de lesión utilizadas en los estudios y la ausencia de validación externa en algunos modelos. En conjunto, estos factores muestran que la utilidad de la inteligencia artificial en este campo no depende solo del modelo empleado, sino también de la calidad del diseño de los estudios y de los datos disponibles.

En general, los hallazgos muestran una situación intermedia: la inteligencia artificial presenta un potencial importante, pero su desempeño todavía está condicionado por distintas limitaciones presentes en el campo de estudio. Más de la mitad de los trabajos analizados reportó una efectividad moderada, lo que sugiere que los modelos actuales pueden identificar ciertos patrones de riesgo de lesión con cierta consistencia, aunque aún no alcanzan un nivel de precisión suficiente para aplicarse de manera independiente en la práctica clínica, pero superando a métodos tradicionales. Por otra parte, cerca de una cuarta parte de los estudios obtuvo niveles de efectividad altos, lo que indica que, cuando

las condiciones metodológicas son adecuadas, el rendimiento de los modelos puede mejorar considerablemente. Sin embargo, otro grupo similar de estudios presentó una efectividad baja, lo que evidencia que dichas condiciones no siempre están presentes en las investigaciones analizadas. Cabe destacar que dentro de esos estudios con baja efectividad se encuentran revisiones, las cuales aportaron datos de estudios con una cierta antigüedad.

Un aspecto importante para considerar es el tipo de estudios que componen la muestra. Cerca del 40% corresponde a investigaciones basadas en datasets sintéticos o de acceso público, mientras que solo alrededor del 23% trabajó con población real en estudios de aplicación práctica. Esta diferencia es relevante, ya que entrenar modelos con datos reales implica enfrentar la variabilidad propia de los corredores, como diferencias individuales, lesiones poco definidas o adherencia irregular al seguimiento. En cambio, los datasets más estructurados suelen generar resultados más consistentes, lo que podría explicar algunos de los valores de rendimiento más altos observados en la muestra. Sin embargo, esto también plantea la duda de si esos modelos tendrían el mismo desempeño en contextos reales. Por otro lado, las revisiones sistemáticas y narrativas representan cerca del 38% de los estudios incluidos. Aunque estas investigaciones no entrenan modelos ni generan resultados predictivos propios, son útiles para sintetizar la evidencia disponible y describir el estado actual del campo. No obstante, su elevada proporción también sugiere que aún existe una cantidad limitada de estudios originales con datos empíricos, lo que indica que el área todavía se encuentra en una etapa de desarrollo.

Variables como el sexo del deportista, nivel de experiencia y edad. Están ausentes y no son informados en un alto porcentaje de la muestra principalmente en los artículos que utilizan datasets y los que son revisiones. La ausencia de estos datos no es un problema menor, ya que las diferencias entre corredores según su edad, sexo, historial lesional y nivel de experiencia son lo suficientemente significativas como para generar perfiles de riesgo completamente distintos. Un modelo que no contempla estas características no permite

saber a qué tipo de corredor aplica realmente, lo que dificulta tanto la comparación entre estudios como la traducción de los resultados a la práctica clínica. Los estudios que utilizaron población real presentan estas variables, sin embargo, padece la misma problemática en la variable de edad. Si bien presenta e informa la variable, los grupos etarios son muy variados y se encuentra bastante diferencia de edad.

El machine learning clásico es el enfoque más utilizado en la investigación sobre predicción de lesiones deportivas. Esto se debe a que algoritmos como Random Forest y XGBoost ofrecen varias ventajas, como buena capacidad de adaptación, menor costo computacional y una interpretación relativamente sencilla. Estas características los hacen adecuados para este tipo de estudios, donde los conjuntos de datos suelen ser pequeños y los recursos de investigación limitados. En particular, Random Forest, que es el algoritmo más frecuente en los estudios analizados, permite identificar qué variables influyen más en la predicción. Esto resulta útil no solo para anticipar posibles lesiones, sino también para comprender los factores asociados a su aparición. Sin embargo, estos modelos también presentan limitaciones, ya que su rendimiento puede depender de las características del conjunto de datos y disminuir cuando se trabaja con información muy compleja o con muchas variables.

El deep learning representa otro enfoque dentro de la inteligencia artificial. Modelos como, por ejemplo, las redes neuronales convolucionales, los transformers y las redes de grafos. Pueden detectar patrones complejos en grandes volúmenes de datos, especialmente en series temporales. En algunos estudios incluso han mostrado un rendimiento superior al de los algoritmos de machine learning tradicionales. No obstante, su aplicación presenta ciertas dificultades. Por un lado, requieren grandes cantidades de datos y mayor capacidad computacional. Por otro, suelen ser más difíciles de interpretar. Este funcionamiento tipo “caja negra”, debido a las múltiples capas de procesamiento que dificultan comprender cómo se genera la predicción, puede ser una limitación en el ámbito clínico, donde es importante que el profesional entienda y pueda explicar los resultados del

modelo. Por esta razón, su uso en los estudios analizados sigue siendo limitado, probablemente tanto por la disponibilidad de datos como por una cautela metodológica de los investigadores.

En cuanto al procesamiento del lenguaje natural (PLN), su presencia en esta revisión es mínima, aunque plantea una posibilidad interesante. El único estudio identificado se centra en patologías cardiovasculares en atletas y no en lesiones musculoesqueléticas en corredores. Sin embargo, su enfoque podría aplicarse al running, ya que el PLN permite analizar información clínica no estructurada, como notas de entrenamiento o reportes de síntomas (parte subjetiva propia del corredor), que actualmente casi no se integran en los modelos predictivos. Considerando que los corredores suelen comunicar sensaciones de fatiga, molestias o sobrecarga antes de que ocurra una lesión, este tipo de información podría aportar datos relevantes para la predicción. El escaso uso de esta técnica en el contexto del running sugiere una posible línea de investigación futura.

Los enfoques mixtos (que combinan arquitecturas de machine learning con deep learning y/o procesamiento del lenguaje natural) concentraron la mayor proporción de resultados de efectividad alta en relación con la muestra. Esto sugiere que la integración de múltiples arquitecturas puede potenciar el rendimiento predictivo.

Uno de los hallazgos más relevantes de este trabajo es que más de un tercio de los estudios no informó las variables utilizadas para entrenar sus modelos, lo que dificulta evaluar la validez clínica de sus resultados. Entre los estudios que sí las reportaron, las variables biomecánicas y de carga de entrenamiento fueron las más frecuentes, lo que coincide con el conocimiento actual sobre las lesiones por sobreuso en corredores. Sin embargo, la mayoría de los estudios analizó estas variables de forma aislada, sin integrar distintos factores. Considerando que el riesgo de lesión en running es multifactorial, esta fragmentación podría explicar, en parte, la efectividad moderada observada en muchos modelos.

Conclusión

A partir del análisis de los 13 artículos incluidos en esta revisión, puede señalarse que la inteligencia artificial presenta un potencial significativo para la predicción de lesiones en corredores. Sin embargo, la evidencia disponible aún no es suficiente para confirmar de manera concluyente su efectividad. La mayoría de los modelos analizados mostró niveles de efectividad moderados; además, los enfoques mixtos fueron los que obtuvieron los mejores resultados, mientras que el machine learning clásico se mantuvo como el enfoque más utilizado. En conjunto, estos resultados responden al objetivo general del estudio y permiten respaldar la hipótesis planteada, aunque solo de manera parcial.

Las limitaciones identificadas durante el análisis, como la heterogeneidad de los datos, la falta de estandarización en las variables y la escasa articulación entre el ámbito tecnológico y el clínico, no niegan el potencial de la inteligencia artificial, sino que indican los desafíos que aún deben abordarse. En base a esto, avanzar hacia investigaciones con poblaciones más diversas, una integración más amplia de variables y una mayor colaboración entre profesionales de la salud y especialistas en inteligencia artificial podría contribuir a mejorar el desarrollo de estos modelos.

Por último, la inteligencia artificial debe considerarse como una herramienta de apoyo para el profesional, y no como un sustituto de su intervención. Su principal utilidad surge cuando se integra con la evaluación clínica y con el conocimiento directo del corredor, permitiendo identificar de forma anticipada posibles situaciones de riesgo y favoreciendo la toma de decisiones preventivas más precisas y personalizadas.

Referencias Bibliográficas

- Adams, D., Pozzi, F., Willy, R. W., Carrol, A., & Zeni, J. (2018). Altering cadence or vertical oscillation during running: Effects on running related injury factors. *International Journal of Sports Physical Therapy*, 13(4), 633–642.
<https://doi.org/10.26603/ijsp20180633>
- Amendolara, A., Pfister, D., Settelmayer, M., Shah, M., Wu, V., Donnelly, S., Johnston, B., Peterson, R., Sant, D., Kriak, J., & Bills, K. (2023). An overview of machine learning applications in sports injury prediction. *Cureus*, 15(9), e46170.
<https://doi.org/10.7759/cureus.46170>
- Anderson, L. M., Martin, J. F., Barton, C. J., & Bonanno, D. R. (2022). What is the effect of changing running step rate on injury, performance and biomechanics? A systematic review and meta-analysis. *Sports Medicine Open*, 8, 112.
<https://doi.org/10.1186/s40798-022-00504-0>
- Berzosa, C., Comeras-Chueca, C., Bascuas, P. J., Gutiérrez, H., & Bataller-Cervero, A. V. (2024). Assessing trail running biomechanics: A comparative analysis of the reliability of Stryd™ and GARMINRP wearable devices. *Sensors*, 24(11), 3570.
<https://doi.org/10.3390/s24113570>
- Carter, J., Chen, X., Cazzola, D., Trewartha, G., & Preatoni, E. (2024). Consumer-priced wearable sensors combined with deep learning can be used to accurately predict ground reaction forces during various treadmill running conditions. *PeerJ*, 12, e17896. <https://doi.org/10.7717/peerj.17896>
- Castellanos-Ruiz, J. A., Montealegre-Mesa, L. M., Martínez-Toro, B. D., Gallo-Serna, J. J., & Almanza-Fuentes, O. (2021). Uso de sensores inerciales en fisioterapia: Una aproximación a procesos de evaluación del movimiento humano. *Universidad y Salud*, 23(1), 55–63. <https://doi.org/10.22267/rus.212301.214>

- Correia, C. K., Machado, J. M., Dominski, F. H., Peduzzi de Castro, M., de Brito Fontana, H., & Ruschel, C. (2024). Risk factors for running-related injuries: An umbrella systematic review. *Journal of Sport and Health Science*, 13(6), 793–804. <https://doi.org/10.1016/j.jshs.2024.04.011>
- Dande, A. A., & Pund, M. A. (2023). A review study on applications of natural language processing. *International Journal of Scientific Research in Science, Engineering and Technology*, 10(2), 122–126. <https://doi.org/10.32628/IJSRSET2310214>
- Dimmick, H. L., van Rassel, C. R., MacInnis, M. J., & Ferber, R. (2023). Use of subject-specific models to detect fatigue-related changes in running biomechanics: A random forest approach. *Frontiers in Sports and Active Living*, 5, 1283316. <https://doi.org/10.3389/fspor.2023.1283316>
- Dudley, C., Weise, J., Johnston, R., & Duthie, G. (2023). Methods of monitoring internal and external loads and their relationships with physical qualities, injury, or illness in adolescent athletes: A systematic review and best-evidence synthesis. *Sports Medicine*, 53(8), 1559–1593. <https://doi.org/10.1007/s40279-023-01844-x>
- Erickson, B. J., & Kitamura, F. (2021). Magician's Corner: 9. Performance Metrics for Machine Learning Models. *Radiology. Artificial intelligence*, 3(3), e200126. <https://doi.org/10.1148/ryai.2021200126>
- Fang, D., Chen, C. Sports injury risk prediction based on temporal graph encoding and graph neural networks: A cross-sport transfer learning framework. *Sci Rep* 15, 37656 (2025). <https://doi.org/10.1038/s41598-025-21613-2>
- Figueiredo, I., Reis e Silva, M. R., & Sousa, J. E. (2025). The influence of running cadence on biomechanics and injury prevention: A systematic review. *Cureus*, 17(8), e90322. <https://doi.org/10.7759/cureus.90322>

- Hijos, M. N. (2018). La historia del running en Argentina. *Materiales para la Historia del Deporte*, (17), 122–135.
https://polired.upm.es/index.php/materiales_historia_deporte/article/view/4072/4261
- Jamieson, A., Chico, T. J. A., Jones, S., Chaturvedi, N., Hughes, A. D., & Orini, M. (2025). A guide to consumer-grade wearables in cardiovascular clinical care and population health for non-experts. *NPJ Cardiovascular Health*, 2(1), 44.
<https://doi.org/10.1038/s44325-025-00082-6>
- Leckey, C., van Dyk, N., Doherty, C., Lawlor, A., & Delahunt, E. (2025). Machine learning approaches to injury risk prediction in sport: A scoping review with evidence synthesis. *British Journal of Sports Medicine*, 59(7), 491–500.
<https://doi.org/10.1136/bjsports-2024-108576>
- Li, A., Wang, Y., & Chen, H. (2025). AI driven cardiovascular risk prediction using NLP and large language models for personalized medicine in athletes. *SLAS Technology*, 32, 100286. <https://doi.org/10.1016/j.slast.2025.100286>
- Luu, B. C., Wright, A. L., Haeberle, H. S., Karnuta, J. M., Schickendantz, M. S., Makhni, E. C., Nwachukwu, B. U., Williams, R. J., & Ramkumar, P. N. (2020). Machine learning outperforms logistic regression analysis to predict next-season NHL player injury: An analysis of 2322 players from 2007 to 2017. *Orthopaedic Journal of Sports Medicine*, 8(9). <https://doi.org/10.1177/2325967120953404>
- Mateus, N., Abade, E., Coutinho, D., Gómez, M.-Á., Lago Peñas, C., & Sampaio, J. (2025). Empowering the sports scientist with artificial intelligence in training, performance, and health management. *Sensors*, 25(1), 139. <https://doi.org/10.3390/s25010139>
- Melián León, S. (2025). *Modelos de predicción en Machine Learning: Una revisión* [Trabajo de fin de grado, Universidad de La Laguna]. Repositorio Institucional de la Universidad de La Laguna. <http://riull.ull.es/xmlui/handle/915/42994>

- Mienye, I. D., & Swart, T. G. (2024). A comprehensive review of deep learning: Architectures, recent advances, and applications. *Information*, 15(12), 755. <https://doi.org/10.3390/info15120755>
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons B*, 4, 51–62. <https://doi.org/10.20544/HORIZONS.B.04.1.17.P05>
- Nuyts, L., De Brabandere, A., Van Rossom, S., Davis, J., & Vanwanseele, B. (2022). Machine-learned-based prediction of lower extremity overuse injuries using pressure plates. *Frontiers in Bioengineering and Biotechnology*, 10, 987118. <https://doi.org/10.3389/fbioe.2022.987118>
- OpenAI. (2026). *ChatGPT* (modelo GPT-5.3) [Modelo de lenguaje de inteligencia artificial]. <https://chat.openai.com>
- Pérez, N. V., & Negrete Yankelevich, S. (2025). Historias de la inteligencia artificial: pasado y presente. *Asclepio. Revista de Historia de la Medicina y de la Ciencia*, 77(2), e1413. <https://doi.org/10.3989/asclepio.2025.1413>
- Rahlf, A. L., Hoenig, T., Stürznickel, J., Cremans, K., Fohrmann, D., Sanchez-Alvarado, A., Rolvien, T., & Hollander, K. (2022). A machine learning approach to identify risk factors for running-related injuries: Study protocol for a prospective longitudinal cohort trial. *BMC Sports Science, Medicine and Rehabilitation*, 14, 75. <https://doi.org/10.1186/s13102-022-00426-0>
- Raju, S., Singamaneni, K. K., & Hooi, L. B. (2026). Machine learning framework for predicting athletic injuries and optimising performance. *BMC Sports Science, Medicine and Rehabilitation*. <https://doi.org/10.1186/s13102-025-01502-x>

- Ren, L., Wang, Y., & Li, K. (2024). Real-time sports injury monitoring system based on the deep learning algorithm. *BMC Medical Imaging*, 24, 122.
<https://doi.org/10.1186/s12880-024-01304-6>
- Sarker, I. H. (2022). AI-based modeling: Techniques, applications and research issues towards automation, intelligent and smart systems. *SN Computer Science*, 3(2), 158.
<https://doi.org/10.1007/s42979-022-01043-x>
- Seçkin, A. Ç., Ateş, B., & Seçkin, M. (2023). Review on wearable technology in sports: Concepts, challenges and opportunities. *Applied Sciences*, 13(18), 10399.
<https://doi.org/10.3390/app131810399>
- Souaifi, M., Dhahbi, W., Jebabli, N., Ceylan, H. İ., Boujabli, M., Muntean, R. I., & Dergaa, I. (2025). *Artificial intelligence in sports biomechanics: A scoping review on wearable technology, motion analysis, and injury prevention*. **Bioengineering**, 12(8), 887.
<https://doi.org/10.3390/bioengineering12080887>
- Van Eetvelde, H., Mendonça, L. D., Ley, C., Seil, R., & Tischer, T. (2021). Machine learning methods in sport injury prediction and prevention: A systematic review. *Journal of Experimental Orthopaedics*, 8, 27. <https://doi.org/10.1186/s40634-021-00346-x>
- Wu, H., Brooke-Wavell, K., Barnes, M. R., Awan, Z., Mastana, S., Allen, S., & Blagrove, R. C. (2026). Multidisciplinary prediction of running-related injuries using machine learning. *npj Digital Medicine*. <https://doi.org/10.1038/s41746-026-02413-y>
- Ye, X., Huang, Y., Bai, Z., & Wang, Y. (2023). A novel approach for sports injury risk prediction: Based on time-series image encoding and deep learning. *Frontiers in Physiology*, 14, Article 1174525. <https://doi.org/10.3389/fphys.2023.1174525>

Yuan, J., Zeng, Q., Li, J., Cong, Z., & Zhang, Y. (2025). Machine learning applications in sports injury prediction: A narrative review. *Science Progress*, 108(4).

<https://doi.org/10.1177/00368504251385956>