

Applications of Big Data and Artificial Intelligence in Preventing Injuries in Soccer Players

Ariano Selim Alban Gomez¹ ; Sebastian Guerrero Manrique² 

^{1,3}Universidad Tecnológica del Perú, Perú, U21205301@utp.edu.pe, U21202888@utp.edu.pe

Abstract – *This study analyzes the factors that make soccer players more prone to injuries, considering physical, biomechanical, psychological, and contextual variables. Risk factors such as injury history, neuromuscular fatigue, biomechanical asymmetries, training load, age, positional profile, stress, and environmental conditions are identified. It highlights tools based on Artificial Intelligence (AI) and Big Data used to integrate these factors and prevent injuries, including supervised algorithms (Random Forest, SVM, k-NN), neural networks (CNN, RNN), IoT sensors, Big Data platforms, clustering techniques, and explainable models (XAI). These models outperform traditional methods by offering continuous monitoring, analysis of multiple data sources, and adaptation to the player's condition, achieving over 90% accuracy in injury prediction and a 30% reduction in injury incidence. The methodology used follows the PICO model and the PRISMA protocol, which allowed for a rigorous systematic review. Bibliometric and content analyses are presented, along with a critical discussion of gaps in evidence and practical applicability. The conclusions summarize the key contributions and propose recommendations for future research.*

Keywords– *Sports injuries, injury risk, soccer, artificial intelligence, injury prevention.*

Aplicaciones de Big Data e Inteligencia Artificial en la Prevención de Lesiones en Futbolistas

Ariano Selim Alban Gomez¹; Sebastian Guerrero Manrique²

^{1,3}Universidad Tecnológica del Perú, Perú, U21205301@utp.edu.pe, U21202888@utp.edu.pe

Resumen -- Este estudio analiza los factores que hacen a los futbolistas más propensos a lesiones, considerando variables físicas, biomecánicas, psicológicas y contextuales. Se identifican factores de riesgo como el historial de lesiones, fatiga neuromuscular, asimetrías biomecánicas, carga de entrenamiento, edad, perfil posicional, estrés y condiciones ambientales. Se destacan herramientas basadas en Inteligencia Artificial (IA) y Big Data utilizadas para integrar estos factores y prevenir lesiones, incluyendo algoritmos supervisados (Random Forest, SVM, k-NN), redes neuronales (CNN, RNN), sensores IoT, plataformas Big Data, técnicas de clustering y modelos explicables (XAI). Estos modelos superan a los métodos tradicionales al ofrecer monitoreo continuo, análisis de múltiples fuentes de datos y adaptación al estado del jugador, logrando una precisión superior al 90% en predicción de lesiones y una reducción del 30% en su incidencia. La metodología empleada sigue el modelo PICO y el protocolo PRISMA, lo que permitió una revisión sistemática rigurosa. Se presentan análisis bibliométricos y de contenido, junto a una discusión crítica sobre vacíos de evidencia y aplicabilidad práctica. Las conclusiones resumen los aportes clave y proponen recomendaciones para futuras investigaciones.

Palabras claves-- Lesiones deportivas, riesgo de lesión, fútbol, inteligencia artificial, prevención de lesiones.

I. INTRODUCCIÓN

La evolución del fútbol profesional ha ido de la mano con la incorporación de tecnologías emergentes como el Big Data y la Inteligencia Artificial (IA), utilizadas para mejorar el rendimiento físico y preservar la salud del jugador. Estas herramientas permiten recopilar datos en tiempo real sobre variables como carga de entrenamiento, frecuencia cardíaca, aceleración o fatiga acumulada, integrándolos mediante algoritmos inteligentes que identifican patrones de riesgo [1]. Clubes como el Liverpool FC ya exploran estas soluciones, aunque los resultados aún son variados [2]. Investigaciones han demostrado el potencial de modelos de IA y aprendizaje automático para analizar métricas fisiológicas en niveles tanto profesionales como formativos, con resultados prometedores en contextos controlados [3], [4], [5]. Sin embargo, la prevención de lesiones sigue siendo un desafío, ya que estas herramientas aún presentan limitaciones al integrar factores multidimensionales como los biomecánicos, emocionales o contextuales [3], [5]. También enfrentan dificultades en términos de explicabilidad clínica y umbrales precisos de riesgo, lo que reduce su aplicabilidad. Incluso en contextos con alta inversión tecnológica, como muestran Rocchetti et al. [2], los resultados no siempre son concluyentes ni estadísticamente significativos.

Ante este panorama, se vuelve fundamental una Revisión Sistemática de Literatura (RSL) centrada en el uso de IA y Big Data para la prevención de lesiones en fútbol. Este análisis

permitirá consolidar la evidencia actual, identificar los modelos más eficaces y detectar vacíos que obstaculizan su aplicación clínica [3]. La publicación de una RSL orientará futuras investigaciones, apoyará decisiones técnicas y médicas, y promoverá soluciones más precisas, interpretables y personalizadas. Además, ofrecerá una visión panorámica del estado del arte, ayudando a trazar el camino hacia un fútbol más saludable, respaldado por tecnología enfocada en el bienestar del deportista.

II. METODOLOGÍA

Con el objetivo de examinar sistemáticamente la producción científica sobre el uso de Inteligencia Artificial (IA) y Big Data en la prevención de lesiones en futbolistas, se realizó una Revisión Sistemática de Literatura (RSL). Este estudio permitió organizar rigurosamente los hallazgos más relevantes en el ámbito de la salud deportiva. Para estructurar la investigación, se aplicó el enfoque metodológico PICO [6], que facilita la formulación de preguntas precisas mediante la división en población, intervención, comparación y resultados. Además, se siguieron las directrices del protocolo PRISMA [7], ampliamente reconocido por asegurar transparencia, reproducibilidad y exhaustividad en revisiones sistemáticas.

La estrategia metodológica se desarrolló de forma secuencial. En primer lugar, la Tabla I expone la construcción de la pregunta de investigación utilizando el modelo PICO, en el cual se delimitan claramente la población (futbolistas), la intervención (uso de IA y Big Data), el método comparativo (enfoques tradicionales) y el resultado esperado (prevención de lesiones). A partir de esta formulación, se establecieron subpreguntas específicas que orientaron la búsqueda bibliográfica.

TABLA I
Descripción de la pregunta PICO

Tema de investigación: Contribución de la Inteligencia Artificial y el Big Data en la prevención de lesiones deportivas en futbolistas profesionales: una revisión sistemática de literatura.	
Pregunta general: ¿Cómo influye la aplicación de Inteligencia Artificial y Big Data (I) en la prevención de lesiones deportivas (O) en futbolistas (P), en comparación con métodos tradicionales de monitoreo físico y médico (C)?	
Acrónimo y componente	Subpregunta
P: Futbolistas	¿Qué características presentan los futbolistas que los hacen más propensos a sufrir lesiones?
I: IA y Big Data	¿Qué herramientas de Inteligencia Artificial y Big Data se utilizan para prevenir lesiones deportivas en el fútbol?
C: Métodos tradicionales	¿En qué aspectos los enfoques basados en IA y Big Data superan a los métodos tradicionales de prevención y monitoreo?
O: Prevención efectiva	¿Qué nivel de efectividad han demostrado los modelos basados en IA y Big Data para anticipar o reducir lesiones en futbolistas?

En segundo lugar, la Tabla II resume la selección de términos clave para cada componente del modelo PICO, considerando su pertinencia académica y su aparición frecuente en estudios del ámbito deportivo y tecnológico.

TABLA II
Descripción de las palabras clave

Acronimo y componente	Palabras clave
P: Futbolistas	Football players, soccer players, athletes, sports performance
I: Aplicación de IA y Big Data	Artificial intelligence, machine learning, deep learning, Big Data, predictive analytics
C: Métodos tradicionales	Traditional methods, physical monitoring, injury history, clinical assessment
O: Prevención de lesiones	Injury prevention, injury risk, injury prediction, injury monitoring, fatigue detection

Como cierre del método PICO, la Tabla III presenta las ecuaciones de búsqueda aplicadas en las bases de datos Scopus, Web of Science y SciELO, integrando palabras clave en inglés y español mediante operadores booleanos. Estas ecuaciones, diseñadas específicamente para cada base — SCOPUS (EB1), Web of Science (EB2) y SciELO (EB3)—, se construyeron a partir de los términos derivados del modelo PICO. En SCOPUS y Web of Science se priorizaron términos en inglés relacionados con fútbol, inteligencia artificial y prevención de lesiones, mientras que en SciELO se utilizaron equivalentes en español adaptados al contexto latinoamericano. Esta estrategia permitió recuperar estudios relevantes que cumplieran con los criterios de inclusión, enfocados en futbolistas, el uso de tecnologías predictivas y su aplicación en la prevención de lesiones.

TABLA III
Descripción de las ecuaciones de búsqueda

Acronimo	Ecuación de búsqueda
P	football OR soccer OR footballers
I	"artificial intelligence" OR "machine learning" OR "deep learning" OR "predictive analytics" OR "big data"
C	"traditional methods" OR "physical monitoring" OR "medical monitoring"
O	"injury prevention" OR "injury prediction" OR "injury risk" OR "injury monitoring" OR "injury management"
EB1 – SCOPUS: (sport OR soccer) AND ("machine learning" OR "artificial intelligence" OR "deep learning" OR "predictive analytics") AND ("injury prevention" OR "injury prediction" OR "injury risk" OR "injury monitoring")	
EB2 – WEB OF SCIENCE: (football OR soccer) AND ("machine learning" OR "artificial intelligence" OR "deep learning" OR "predictive analytics") AND ("injury prevention" OR "injury prediction" OR "injury risk" OR "injury monitoring")	
EB3 – SCIELO: ("lesiones deportivas" OR "prevención de lesiones" OR "fatiga muscular" OR "biomecánica") AND ("inteligencia artificial" OR "machine learning")	

Una vez recopilados los registros mediante las ecuaciones de búsqueda, se procedió a aplicar criterios de elegibilidad que permitieran asegurar la pertinencia, actualidad y rigurosidad metodológica de los estudios seleccionados. La Tabla IV presenta los criterios de inclusión y exclusión definidos para esta revisión sistemática, con el fin de filtrar aquellos artículos que se alinearán con los objetivos de investigación centrados en la prevención de lesiones mediante el uso de tecnologías inteligentes.

TABLA IV
Descripción de los criterios de elegibilidad

Nº	CRITERIOS DE INCLUSIÓN	Nº	CRITERIOS DE EXCLUSIÓN
CI1	Artículos que se centren en la prevención de lesiones deportivas mediante inteligencia artificial.	CE1	Investigaciones que no detallen de forma precisa el enfoque metodológico empleado.
CI2	Artículos que analicen fatiga, sobrecarga o recuperación mediante tecnologías inteligentes.	CE2	Documentos escritos en idiomas distintos al español o inglés.
CI3	Artículos que utilicen análisis biomecánico asistido por inteligencia artificial.	CE3	Publicaciones con una fecha anterior al año 2020.
CI4	Estudios aplicables al fútbol o que, aun siendo de otros deportes, aporten conocimiento transferible.	CE4	Estudios sin disponibilidad completa del contenido para su revisión y análisis.

Como resultado de la estrategia de búsqueda, se identificaron 402 registros en tres bases científicas: Scopus (n = 353), Web of Science (n = 33) y SciELO (n = 16). Tras eliminar 10 duplicados, se evaluaron 392 documentos únicos. En la primera fase de cribado, se excluyeron 322 artículos tras revisar título y resumen, descartando aquellos que no abordaban directamente el uso de tecnologías inteligentes (IA, aprendizaje automático o Big Data) en la prevención de lesiones (CI1) o no se alineaban con los objetivos de la revisión. En la segunda fase, se leyeron las introducciones de los 70 estudios seleccionados, excluyendo aquellos cuyo enfoque no correspondía con la temática central.

Finalmente, se realizó una lectura completa de los 70 estudios restantes, tras la cual se excluyeron 29 artículos por diversos motivos: falta de metodología clara (CE1), idioma no permitido (CE2), año de publicación anterior a 2020 (CE3), inaccesibilidad al texto completo (CE4) o irrelevancia temática (CI4). Así, se seleccionaron 41 estudios para la evaluación exhaustiva en esta Revisión Sistemática.

A continuación, se presenta el diagrama PRISMA, el cual ilustra el proceso de selección de los 41 artículos finales.




Fig. 1. Diagrama de flujo PRISMA del proceso de selección de artículos [7].

III. RESULTADOS

Para la elaboración de la presente fase de resultados, se ha estructurado el apartado en dos secciones principales: datos bibliométricos y datos de contenido.

El análisis bibliométrico describe los estudios seleccionados mediante una tabla de artículos revisados, un gráfico de distribución por año, tipología documental y procedencia según base de datos, lo que permite contextualizar el estado actual de la producción científica sobre IA y Big Data en la prevención de lesiones en el fútbol. Por otro lado, el análisis de contenido responde estructuradamente a las preguntas formuladas con el modelo PICO [6], presentando una síntesis crítica de los hallazgos más relevantes e identificando el impacto concreto de las tecnologías inteligentes en la prevención de lesiones deportivas.

DATOS BIBLIOMETRICOS

La presente Revisión Sistemática de Literatura incluyó un total de 41 estudios científicos seleccionados tras un riguroso proceso de cribado, publicados mayormente entre los años 2020 y 2025, destacando una publicación del año 2009 sobre las directrices del protocolo PRISMA. La distribución temporal evidencia un creciente interés en el uso de Inteligencia Artificial (IA) y Big Data para la prevención de lesiones en futbolistas, particularmente en los últimos tres años.

Se observa una tendencia creciente en el número de publicaciones sobre el uso de IA y Big Data en la prevención de lesiones en fútbol en los últimos años. Destaca particularmente el periodo comprendido entre 2022 y 2025,

donde se concentra la mayoría de los estudios revisados. A continuación, se presenta un gráfico que muestra esta distribución temporal.




Fig. 2. Número de artículos sobre prevención de lesiones en fútbol mediante IA y Big Data, publicados por año.

La distribución de los tipos de documentos seleccionados en esta revisión muestra que un 75.6% corresponde a artículos de investigación en revistas científicas, mientras que un 12.2% son capítulos de libro, y otro 12.2% corresponde a actas de conferencias. Esta tendencia refleja que la mayor parte de la producción científica en el tema está orientada hacia investigaciones empíricas y aplicadas. El gráfico siguiente ilustra esta distribución.




Fig. 3. Distribución de los tipos de documentos seleccionados.

Se observa que la mayoría de los estudios revisados en el contexto de prevención de lesiones en fútbol mediante IA adoptan un enfoque cuantitativo, destacándose por el uso de modelos de aprendizaje automático, análisis biomecánico y tratamiento de grandes volúmenes de datos. En menor medida, se encuentran estudios cualitativos o de enfoque mixto. A continuación, se incluye un gráfico representando esta distribución metodológica.




Fig. 4. Distribución de los tipos de metodologías de los documentos seleccionados.

La distribución geográfica de los artículos incluidos en esta Revisión Sistemática de Literatura evidencia una participación destacada de países como Estados Unidos, Reino Unido, China, Australia, España e Italia, junto con otras naciones como Irlanda, Irán, Nueva Zelanda y Croacia. La figura siguiente detalla dicha distribución.



Fig. 5. Distribución de los países de origen de los documentos seleccionados graficado en mapa.

DATOS DE CONTENIDO

A. ¿Qué características presentan los futbolistas que los hacen más propensos a sufrir lesiones?

El riesgo de lesiones en futbolistas profesionales está condicionado por una interacción compleja entre factores físicos, fisiológicos, biomecánicos, históricos y contextuales. Los enfoques modernos basados en Inteligencia Artificial (IA) y Big Data han permitido una caracterización más precisa y personalizada de estos factores, superando las limitaciones de los métodos tradicionales.

En primer lugar, la historia previa de lesiones es uno de los predictores más robustos del riesgo de futuras lesiones. Estudios recientes [8], [9], [10], [11], [12] evidencian que jugadores con antecedentes de lesiones musculares o ligamentosas presentan alteraciones persistentes en patrones de movimiento y en asimetrías de carga, aumentando su vulnerabilidad.

La fatiga neuromuscular acumulada es otro factor clave. Los trabajos de Mandorino et al. [13] y Teixeira et al. [14] han demostrado que elevados niveles de fatiga, especialmente en contextos de congestión de partidos, comprometen la

capacidad de control motor, incrementando el riesgo tanto de lesiones por sobreuso como de carácter agudo. Xu et al. [39] demostraron que un modelo CNN-LSTM logró anticipar el riesgo de lesión con base en estos cambios, especialmente en fases donde los jugadores experimentaban fatiga acumulada.

Por otro lado, las asimetrías biomecánicas y los patrones de movimiento disfuncionales, identificados a través de análisis de IA en estudios como los de Calderón-Díaz et al. [8] y Mao [12], son características prominentes en jugadores propensos a lesiones. Estas asimetrías pueden ser resultado tanto de déficits de fuerza como de secuelas de lesiones anteriores.

El perfil de entrenamiento también influye de forma determinante. Según Navarro et al. [15] y Leckey et al. [16], los jugadores expuestos a cargas mal periodizadas, con incrementos bruscos semanales, presentan un mayor riesgo de lesión. El monitoreo de métricas como el ratio agudo-crónico mediante IA permite optimizar la progresión de cargas.

De forma complementaria, Jiang et al. [17] señalan que la congestión de partidos a corto plazo aumenta la incidencia de lesiones, mientras que su impacto a largo plazo no es claro. Además, métricas GPS como distancia y aceleraciones no se asocian consistentemente al riesgo, a diferencia del ACWR basado en percepción del esfuerzo, que sí se relaciona con lesiones sin contacto.

Por otro lado, factores como la edad y el perfil posicional modulan el riesgo. Los trabajos de Prys et al. [18] y Tedesco et al. [19] han identificado que jugadores de mayor edad, especialmente en posiciones de alta demanda física como laterales y extremos, presentan tasas de lesión más elevadas, atribuibles a una menor capacidad de recuperación y a la acumulación de micro traumas.

El estado psicológico representa un factor clave en el riesgo de lesiones, como indican Shen et al. [20] y Van Etvelde et al. [21], al mostrar que el estrés elevado y la fatiga mental afectan la atención y el tiempo de reacción, aumentando las lesiones sin contacto. A esto se suman variables contextuales como la superficie de juego y el clima; estudios de Ye et al. [22] y Sun [23] evidencian un mayor riesgo en superficies sintéticas y condiciones extremas, especialmente en jugadores con alta carga de minutos. Más recientemente, factores individuales como el perfil genético y biomarcadores fisiológicos han cobrado relevancia como predictores de lesiones, según Oliver et al. [9], Martins et al. [10] y Robles-Palazón et al. [11], quienes destacan la influencia de variantes genéticas ligadas al colágeno y la respuesta inflamatoria.

En conjunto, los futbolistas con mayor propensión a lesiones suelen presentar una combinación de antecedentes clínicos, asimetrías biomecánicas, sobrecarga, fatiga, edad avanzada, posición exigente, estrés psicológico y exposición ambiental adversa [24]. Los modelos predictivos personalizados basados en IA y Big Data permiten integrar estos factores, mejorando la prevención individualizada, como lo demuestran Tedesco et al. [19], Navarro et al. [15] y Calderón-Díaz et al. [8]. Además, Wei et al. [25] resaltan que técnicas como la reducción de dimensionalidad sobre datos fisiológicos

aumentan la precisión de los modelos, destacando el valor de variables latentes en la caracterización del riesgo.

TABLA V
Factores de riesgo con porcentaje de influencia estimado

Factor de Riesgo	Influencia (%)	Notas
Historial de lesiones previas	25%	Principal predictor
Fatiga neuromuscular acumulada	20%	Relacionado con congestión de partidos
Carga de entrenamiento inadecuada	15%	Aumentos bruscos, mala periodización
Asimetrías biomecánicas	10%	Disfunciones posturales/movimiento
Edad avanzada	10%	Especialmente 30+ años
Perfil posicional de alta demanda	5%	Laterales, extremos
Estrés psicológico/fatiga mental	10%	Afecta atención y tiempo de reacción
Contexto ambiental (clima/superficie)	3%	Sintético, calor extremo
Perfil genético/biomarcadores	2%	En desarrollo, estudios emergentes

B. ¿Qué herramientas de Inteligencia Artificial y Big Data se utilizan para prevenir lesiones deportivas en el fútbol?

El avance de la Inteligencia Artificial (IA) y el Big Data ha revolucionado el campo de la prevención de lesiones en el fútbol, ofreciendo herramientas capaces de analizar grandes volúmenes de datos de manera rápida y precisa. Estas tecnologías permiten modelar complejas relaciones entre múltiples variables fisiológicas, biomecánicas y contextuales, facilitando así la predicción temprana de riesgos y la personalización de estrategias preventivas [8], [9], [10], [12], [13].

Entre las herramientas más utilizadas destacan los modelos de aprendizaje supervisado como Random Forest, Support Vector Machines (SVM) y k-Nearest Neighbors (k-NN) [12], [18], [25], los cuales permiten clasificar eficazmente el riesgo de lesión a partir de variables como carga de entrenamiento, patrones de movimiento y antecedentes. Prys et al. [18] y Pillitteri et al. [26] subrayan que Random Forest ofrece una interpretación clara de la importancia de las variables, facilitando decisiones clínicas y técnicas.

En el ámbito del aprendizaje profundo, las redes neuronales convolucionales (CNN) y recurrentes (RNN) son ampliamente empleadas para analizar secuencias temporales de datos fisiológicos y biomecánicos [20], [22], [27]. Shen et al. [20] y Haller et al. [27] evidencian que estas redes identifican patrones complejos asociados al movimiento y la carga, anticipando riesgos antes de que sean clínicamente evidentes. Xu et al. [28] demostraron que una arquitectura CNN-LSTM puede detectar vulnerabilidades articulares ocultas mediante la integración temporal de datos biomecánicos, lo que refuerza su valor predictivo en contextos deportivos.

Los sensores portátiles y tecnologías IoT permiten recolectar datos fisiológicos y biomecánicos en tiempo real, facilitando un monitoreo continuo del estado del jugador [16], [19]. Leckey et al. [16] y Tedesco et al. [19] destacan el uso de dispositivos GPS, sensores inerciales y monitores de frecuencia cardíaca integrados con IA para análisis dinámico. Además, plataformas Big Data como las descritas por Navarro et al. [15] y Sun [23] permiten integrar múltiples fuentes de información para generar perfiles de riesgo individualizados, ajustados a la evolución de cada futbolista [8], [15], [23].

Por otra parte, técnicas de aprendizaje no supervisado — como el clustering jerárquico — permiten segmentar jugadores según perfiles fisiológicos o biomecánicos específicos, facilitando intervenciones dirigidas [9], [12]. Mao [12] destaca su utilidad para detectar subgrupos con necesidades particulares. Finalmente, modelos de Explainable AI (XAI) aportan transparencia en la toma de decisiones clínicas, como indican Calderón-Díaz et al. [8], mientras que Ferreira et al. [29] subrayan el valor de combinar IA con el enfoque de dinámica ecológica, incorporando el entorno competitivo y social como parte de la prevención integral.

En resumen, las herramientas más destacadas en la prevención de lesiones en el fútbol incluyen:

- Modelos supervisados (Random Forest, SVM, k-NN) [12], [18], [26]
- Redes neuronales profundas (CNN, RNN) [20], [22], [27]
- Sensores portátiles e IoT [16], [19]
- Plataformas Big Data integradas [8], [15], [23]
- Aprendizaje no supervisado (clustering) [9], [12]
- Explainable AI (XAI) [8]

Estas herramientas permiten un abordaje holístico, dinámico y personalizado de la prevención de lesiones, marcando una clara evolución respecto a las estrategias tradicionales basadas en análisis retrospectivo y evaluaciones puntuales.

TABLA VI
Herramientas de Inteligencia Artificial y Big Data aplicadas a la prevención de lesiones en el fútbol

Herramienta	Tipo de tecnología	Aplicación principal
Random Forest, SVM, k-NN	Supervisado	Clasificación de riesgo de lesión
CNN, RNN	Aprendizaje profundo	Análisis de secuencias temporales y movimientos
Clustering, jerárquico	No supervisado	Segmentación de jugadores por perfil de riesgo
GPS, sensores inerciales, FC	IoT/Tecnologías de sensado	Recolección continua de datos fisiológicos
Plataformas Big Data	Integración	Centralización y análisis multifuente
XAI	Interpretabilidad	Transparencia en la toma de decisiones médicas

C. Qué nivel de efectividad han demostrado los modelos basados en IA y Big Data para anticipar o reducir lesiones en futbolistas?

Los modelos de IA y Big Data han demostrado una efectividad notablemente superior a los métodos tradicionales en la predicción y prevención de lesiones en futbolistas, con métricas destacadas como precisión, sensibilidad, especificidad y reducción real de incidencias [8], [9], [13], [24], [30], [31]. Calderón-Díaz et al. [8] reportaron que algoritmos como Random Forest y Gradient Boosting superan el 90 % de precisión, con sensibilidad y especificidad entre 85 % y 95 %.

En línea con ello, Oliver et al. [9] observaron que las redes neuronales recurrentes (RNN) alcanzaron más del 88 % de precisión en futbolistas juveniles. Martins et al. [10] demostraron que al combinar pruebas físicas y composición corporal con IA se logra predecir el riesgo con más del 85 % de exactitud, mientras que Robles-Palazón et al. [11] lograron superar el 90 % al integrar datos biomecánicos y de carga en modelos predictivos aplicados a juveniles.

Abasi et al. [24] demostraron que modelos basados en datos fisiológicos avanzados, como la prueba CPET, permiten predecir el riesgo de re-lesión con una precisión cercana al 92 %, facilitando la personalización de programas de readaptación. De forma complementaria, Duarte Ayala et al. [30] evidenciaron que el uso de sensores portátiles e IA aplicada al análisis de movimiento puede anticipar lesiones con una efectividad de hasta el 93 %.

Mandorino et al. [13] reportaron que la integración de Big Data en sistemas de monitoreo continuo redujo en un 30 % la incidencia de lesiones en clubes profesionales mediante prevención personalizada. Por su parte, Ye et al. [22] alcanzaron precisiones superiores al 95 % en la identificación temprana de riesgos usando redes neuronales convolucionales. Shen et al. [20] y Haller et al. [27] reforzaron estos hallazgos, mostrando que el análisis de series temporales permite anticipar picos de riesgo con semanas de antelación, optimizando la gestión de cargas.

Leckey et al. [16] reportaron que la implementación de sistemas de IA con monitorización en tiempo real redujo en más de un 25 % las lesiones por sobrecarga en clubes de alto rendimiento. Tedesco et al. [19] y Navarro et al. [15] destacaron que el uso de modelos explicables (XAI) no solo ofrece alta precisión, sino que también mejora la confianza clínica al clarificar los factores de riesgo en cada caso. Asimismo, la inclusión de datos contextuales, como condiciones del partido o ambientales, potencia la capacidad predictiva de los modelos, alcanzando entre 95 % y 97 % de precisión según Piłka et al. [32] y Sharma et al. [33], superando ampliamente los métodos estadísticos tradicionales.

Complementariamente, Wei et al. [25] demostraron que la integración de algoritmos supervisados con técnicas de reducción de dimensionalidad mejora la precisión hasta un 97 % en entornos simulados. Por su parte, Guzmán-Alfaro et al. [34] evidenciaron que el análisis biomecánico detallado permite diseñar programas preventivos personalizados,

reduciendo lesiones articulares. Finalmente, revisiones sistemáticas como las de Van Etvelde et al. [21], Nassis et al. [35] y Tedesco et al. [19] confirman que los modelos basados en IA logran precisiones superiores al 90 %–95 %, y que su aplicación práctica ha contribuido a reducir la incidencia de lesiones en contextos profesionales.




Fig. 6. Comparación de precisión/efectividad de modelos IA para predicción de lesiones.

D. ¿En qué aspectos los enfoques basados en IA y Big Data superan a los métodos tradicionales de prevención y monitoreo de lesiones en el fútbol?

Los enfoques basados en Inteligencia Artificial (IA) y Big Data han demostrado una eficacia significativamente mayor que los métodos tradicionales en aspectos clave relacionados con la prevención y el seguimiento de lesiones en el fútbol profesional.

1. Capacidad predictiva avanzada y personalizada

A diferencia de los métodos convencionales, que se basaban en registros clínicos, pruebas físicas o el criterio del cuerpo técnico, los modelos de Inteligencia Artificial permiten identificar patrones ocultos y relaciones complejas entre múltiples variables [8], [9], [10], [11]. Algoritmos como las redes neuronales profundas y los modelos híbridos AI-biomecánicos han demostrado una capacidad superior para predecir riesgos individualizados según el perfil fisiológico y biomecánico del jugador [31], [36]. Además, Wei et al. [25] y Xu et al. [28] evidencian que el uso de datos procesados mediante deep learning —como imágenes de movimiento y patrones temporales— mejora la personalización de las predicciones y aumenta la sensibilidad clínica.

Además, el uso de modelos explicables (Explainable AI) permite no solo predecir, sino también comprender qué factores influyen en cada caso particular [8], [26], [34].

2. Monitoreo continuo en tiempo real

Los sistemas tradicionales ofrecían evaluaciones esporádicas (por ejemplo, test físico mensual). En cambio, con la integración de sensores portátiles, GPS, dispositivos wearables y análisis de datos biométricos, ahora es posible un

monitoreo continuo [16], [27], [37]. Estos dispositivos registran datos en tiempo real que los algoritmos procesan para emitir alertas tempranas sobre cargas excesivas o inadecuadas [13], [19].

Por ejemplo, el uso de sistemas de gestión de carga basados en IA permite identificar umbrales personalizados de tolerancia para cada jugador, evitando el sobre entrenamiento [13], [16].

3. Integración de datos multi fuente y contexto situacional

La IA permite integrar múltiples fuentes de datos: cargas de entrenamiento, variables de recuperación, patrones de sueño, datos nutricionales, condiciones del partido, variables psicológicas y factores contextuales [3], [15], [21], [31], [36].

Este enfoque holístico amplía notablemente la perspectiva ofrecida por los métodos tradicionales, que solían centrarse solo en métricas físicas aisladas (por ejemplo, VO2 max o test de salto) [10], [26], [35].

4. Adaptación dinámica a la evolución del jugador

Mientras que los métodos tradicionales eran estáticos, los modelos de IA permiten una adaptación dinámica. Por ejemplo, sistemas de aprendizaje incremental y continuo (continual learning) ajustan los modelos a medida que el atleta experimenta cambios físicos o tras una lesión. [12], [15], [19], [20].

Esto es clave para el manejo de lesiones recurrentes o para jugadores que retornan tras una lesión grave [24], [39].

5. Mejora de la toma de decisiones y planificación individualizada

El uso de plataformas de visualización avanzada y dashboards personalizados permite a entrenadores, médicos y preparadores físicos tomar decisiones más precisas sobre la gestión de la carga, el descanso y los procesos de readaptación física. [4], [11], [14], [22], [23], [30], [35], [40].

Por ejemplo, se ha demostrado que sistemas como los propuestos en [15], [16], [36], [39] permiten planificar microciclos y macrociclos más ajustados al estado real de cada jugador.

6. Reducción del riesgo en poblaciones específicas

Los enfoques IA han mostrado ser especialmente eficaces en poblaciones de alto riesgo, como:

- Jugadores jóvenes en desarrollo [14], [32], [33].
- Jugadoras femeninas con biomecánicas específicas [38]. Croock et al. [41] subrayan la necesidad de modelos especializados para futbolistas femeninas, debido a diferencias biomecánicas y hormonales que afectan el riesgo de lesiones, especialmente del LCA.
- Jugadores con antecedentes de lesiones recurrentes [18], [24], [31].
- Estos grupos solían estar menos contemplados por los modelos tradicionales de prevención.

7. Automatización y escalabilidad

Los sistemas basados en IA permiten una automatización completa de la captura, análisis y retroalimentación de datos,

haciendo viable su implementación tanto en clubes profesionales como en academias formativas. [1], [37].

TABLA VII
Comparativa entre enfoques tradicionales y basados en IA/Big Data para la prevención de lesiones.

Aspecto	Métodos tradicionales	IA y Big Data
Capacidad predictiva	Basada en observación, test físicos y experiencia técnica	Modelos personalizados, detección de patrones complejos con IA
Monitoreo	Evaluaciones periódicas (mensuales o semanales)	Monitoreo continuo en tiempo real con sensores y wearables
Fuentes de datos	Métricas físicas aisladas (e.g., fuerza, resistencia)	Integración de datos fisiológicos, psicológicos, contextuales y ambientales
Adaptabilidad	Evaluaciones estáticas, poco actualizables	Modelos dinámicos que evolucionan con el jugador (learning continuo)
Toma de decisiones	Basada en criterios subjetivos o generales	Dashboards individualizados con sugerencias específicas basadas en datos
Grupos vulnerables	Menor precisión en jóvenes, mujeres o casos complejos	Modelos específicos para poblaciones con riesgos diferenciados
Escalabilidad	Limitada a recursos humanos y tiempo	Alta, gracias a automatización y análisis masivo de datos en tiempo real

IV. DISCUSIÓN

La integración de herramientas basadas en Inteligencia Artificial (IA) y Big Data ha demostrado ser significativamente más eficaz que los métodos tradicionales en la predicción y prevención de lesiones en futbolistas, destacando por su precisión y capacidad de personalización [8], [9], [13], [15], [16], [19], [25], [30]. Modelos de aprendizaje supervisado como Random Forest, SVM y k-NN han alcanzado más del 90 % de precisión en la identificación de jugadores con alto riesgo [8], [13], [18], [24], [25], [26], destacando Wei et al. [25] por mejorar la exactitud hasta el 97 % mediante reducción de dimensionalidad. En el ámbito del aprendizaje profundo, redes como CNN, LSTM y RNN se han utilizado eficazmente para procesar datos temporales obtenidos por sensores, logrando detectar riesgos como desequilibrios que predisponen a lesiones graves, con sensibilidad superior al 95 % [20], [22], [27], [28], [39].

A nivel individual, el historial de lesiones sigue siendo el predictor más sólido [8], [9], [10], [11], [24], mientras que factores como edad avanzada, asimetrías biomecánicas, fatiga y perfil posicional también influyen en el riesgo [13], [14], [15], [22]. Estos factores, que antes se analizaban por separado, ahora pueden integrarse en modelos personalizados y multifuente. En cuanto al contexto, la congestión de partidos, variaciones bruscas de carga y condiciones externas (clima, superficie sintética) han sido vinculadas con mayor incidencia de lesiones [15], [16], [17], [22], [23], [37]. Jiang et

al. [17] destacan que el ratio agudo-crónico percibido (s-RPE) supera en precisión a métricas objetivas como la distancia recorrida. Además, sistemas de monitoreo en tiempo real con sensores IoT permiten una vigilancia continua, logrando reducciones del 25 % al 30 % en lesiones de sobrecarga según Leckey et al. [16] y Mandorino et al. [13].

Técnicas de aprendizaje no supervisado también han sido útiles para segmentar perfiles fisiológicos y biomecánicos, permitiendo intervenciones diferenciadas en grupos específicos como juveniles o mujeres [12], [14], [29], [32], [33], [38], [41]. Los modelos explicables (XAI) fortalecen la adopción clínica al facilitar la interpretación de riesgos, como proponen Calderón-Díaz et al. [8] y Pillitteri et al. [26]. No obstante, algunos estudios aún carecen de validez externa, al estar basados en contextos juveniles, de laboratorio o simulados [9], [11], [12]. Además, se reporta escasa información sobre calidad, frecuencia y contexto de recolección de datos, limitando la reproducibilidad.

Existen vacíos en la literatura respecto a poblaciones específicas como futbolistas con discapacidad, ligas femeninas no profesionales o clubes con bajos recursos tecnológicos. También se requiere mayor exploración sobre el impacto ético y psicológico de la IA, especialmente en relación con la confianza del jugador o la autonomía del cuerpo técnico. Aunque los modelos explicables representan un avance, aún persisten dudas sobre su comprensión por parte del personal clínico [8]. Por tanto, su adopción efectiva dependerá no solo de la validación técnica, sino también de marcos éticos e institucionales adecuados.

Finalmente, la evidencia sugiere que estas tecnologías no solo predicen lesiones, sino que permiten planificaciones personalizadas de entrenamiento, recuperación y prevención de re-lesiones [11], [14], [22], [30], [35], [39]. Ejemplos como Abasi et al. [24] y Duarte Ayala et al. [30] muestran tasas de precisión superiores al 90 % en predicción de re-lesión y anticipación de lesiones mediante sensores y deep learning. En síntesis, la combinación de IA, Big Data, sensores portátiles y modelos explicables ofrece ventajas superiores en detección temprana, personalización y reducción de lesiones. Sin embargo, su adopción sigue enfrentando desafíos en cuanto a acceso tecnológico, capacitación del personal e integración institucional en contextos con menor infraestructura.

V. CONCLUSIÓN

Esta Revisión Sistemática de Literatura consolidó el estado del arte sobre el uso de Inteligencia Artificial (IA) y Big Data en la prevención de lesiones en futbolistas, demostrando su superioridad frente a métodos tradicionales. El análisis de 41 estudios recientes evidenció que los modelos supervisados (como Random Forest y SVM), redes neuronales profundas (CNN, LSTM) y sistemas de monitoreo continuo alcanzan precisiones predictivas superiores al 90 %, reduciendo la incidencia de lesiones hasta en un 30 %.

Los hallazgos revelan factores de riesgo clave como el historial de lesiones, la fatiga neuromuscular, asimetrías

biomecánicas, perfil posicional y psicológico, así como condiciones contextuales (clima o tipo de superficie). La capacidad de estos modelos para integrar variables en tiempo real y generar alertas personalizadas representa un cambio sustancial en medicina deportiva.

Sin embargo, su implementación enfrenta barreras como la falta de infraestructura tecnológica, calidad de datos, personal capacitado y desafíos éticos. En contextos con escasos recursos, como ligas juveniles o amateurs, estas dificultades se acentúan. Por ello, se destaca que la eficacia de estas tecnologías depende no solo del rendimiento técnico, sino de una adopción contextualizada, sostenible y articulada con los equipos técnicos y médicos.

El estudio cumplió su objetivo general de examinar rigurosamente la evidencia científica reciente, identificando herramientas efectivas, limitaciones y oportunidades de mejora. Asimismo, respondió de manera clara a las preguntas del modelo PICO, confirmando la efectividad superior de los modelos basados en IA y Big Data en comparación con enfoques tradicionales.

En conclusión, avanzar hacia un fútbol más seguro y personalizado exige fomentar la explicabilidad de los modelos, su escalabilidad en entornos con pocos recursos y una cultura organizacional abierta a la innovación basada en evidencia.

Se recomienda que futuros estudios exploren la aplicación y adaptación de la metodología basada en IA y Big Data propuesta en esta revisión a otros entornos deportivos y contextos relacionados. Esta transferencia metodológica podría ampliar el impacto y beneficios en la prevención de lesiones, facilitando la personalización y precisión en diferentes disciplinas deportivas.

REFERENCIAS

- [1] C. Tian, J. Liu, M. Chen, and Z. Liu, "The Application of Big Data and Artificial Intelligence Technology in Football Training and Competition," in 2024 International Seminar on Artificial Intelligence, Computer Technology and Control Engineering (ACTCE), IEEE, Sep. 2024, pp. 363–366. doi: 10.1109/ACTCE65085.2024.00079.
- [2] M. Rocchetti, M. Tenace, and G. Cappiello, "Prescient Perspectives on Football Tactics: A Case with Liverpool FC, Comers and AI," 2025, pp. 231–239. doi: 10.1007/978-3-031-78554-2_15.
- [3] Elstak, P. Salmon, and S. McLean, "Artificial intelligence applications in the football codes: A systematic review," Journal of Sports Sciences, vol. 42, no. 13, pp. 1184–1199, Jul. 2024, doi: 10.1080/02640414.2024.2383065.
- [4] J. Almulla and T. Alam, "Machine Learning Models Reveal Key Performance Metrics of Football Players to Win Matches in Qatar Stars League," IEEE Access, vol. 8, pp. 213695–213705, 2020, doi: 10.1109/ACCESS.2020.3038601.
- [5] S. Liao and C. Fu, "The optimization of youth football training using deep learning and artificial intelligence," Scientific Reports, vol. 15, no. 1, p. 8190, Mar. 2025, doi: 10.1038/s41598-025-93159-2.
- [6] A. Nishikawa-Pacher, "Research Questions with PICO: A Universal Mnemonic," Publications, vol. 10, no. 3, p. 21, Jun. 2022, doi: 10.3390/publications10030021.
- [7] D. Moher, A. Liberati, J. Tetzlaff, and D. G. Altman, "Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement," PLoS Medicine, vol. 6, no. 7, p. e1000097, Jul. 2009, doi: 10.1371/journal.pmed.1000097.

- [8] M. Calderón-Díaz et al., "Explainable Machine Learning Techniques to Predict Muscle Injuries in Professional Soccer Players through Biomechanical Analysis," *Sensors*, vol. 24, no. 1, p. 119, Dec. 2023, doi: 10.3390/s24010119.
- [9] J. L. Oliver, F. Ayala, M. B. A. de Ste Croix, R. S. Lloyd, G. D. Myer, and P. J. Read, "Using machine learning to improve our understanding of injury risk and prediction in elite male youth football players," *Journal of Science and Medicine in Sport*, vol. 23, no. 11, pp. 1044–1048, Nov. 2020, doi: 10.1016/j.jsams.2020.04.021.
- [10] F. Martins et al., "Predictive Modeling of Injury Risk Based on Body Composition and Selected Physical Fitness Tests for Elite Football Players," *Journal of Clinical Medicine*, vol. 11, no. 16, p. 4923, Aug. 2022, doi: 10.3390/jcm11164923.
- [11] F. J. Robles-Palazón et al., "Predicting injury risk using machine learning in male youth soccer players," *Chaos, Solitons & Fractals*, vol. 167, p. 113079, Feb. 2023, doi: 10.1016/j.chaos.2022.113079.
- [12] C. Mao, "Research on Sports Injury Information Prediction Model Based on Neural Network Technology," in *2021 International Conference on Aviation Safety and Information Technology*, New York, NY, USA: ACM, Dec. 2021, pp. 510–513. doi: 10.1145/3510858.3510998.
- [13] M. Mandorino, T. J. Gabbett, A. Tessitore, C. Leduc, V. Persichetti, and M. Lacombe, "The Interaction of Fitness and Fatigue on Physical and Tactical Performance in Football," *Applied Sciences*, vol. 15, no. 7, p. 3574, Mar. 2025, doi: 10.3390/app15073574.
- [14] J. E. Teixeira et al., "Player Tracking Data and Psychophysiological Features Associated with Mental Fatigue in U15, U17, and U19 Male Football Players: A Machine Learning Approach," *Applied Sciences*, vol. 15, no. 7, p. 3718, Mar. 2025, doi: 10.3390/app15073718.
- [15] L. Navarro, P.-E. Dandrieux, K. Hollander, and P. Edouard, "Digitalization in Professional Football: An Opportunity to Estimate Injury Risk," 2022, pp. 366–375. doi: 10.1007/978-3-031-14844-6_30.
- [16] C. Leckey, N. van Dyk, C. Doherty, A. Lawlor, and E. Delahunt, "Machine learning approaches to injury risk prediction in sport: a scoping review with evidence synthesis," *British Journal of Sports Medicine*, vol. 59, no. 7, pp. 491–500, Apr. 2025, doi: 10.1136/bjsports-2024-108576.
- [17] Z. Jiang, Y. Hao, N. Jin, and Y. Li, "A Systematic Review of the Relationship between Workload and Injury Risk of Professional Male Soccer Players," *International Journal of Environmental Research and Public Health*, vol. 19, no. 20, p. 13237, Oct. 2022, doi: 10.3390/ijerph192013237.
- [18] M. Prys, Ł. Rosiński, R. Buryta, Ł. Radziński, P. Rózewski, and I. Rejer, "Integrating Machine Learning for Football Injury Prediction: A Concept for an Intelligent System," *Procedia Computer Science*, vol. 225, pp. 4139–4147, 2023, doi: 10.1016/j.procs.2023.10.410.
- [19] S. Tedesco, S. Scheurer, K. N. Brown, L. Hennessy, and B. O'Flynn, "A Survey on the Use of Artificial Intelligence for Injury Prediction in Sports," in *2022 IEEE International Workshop on Sport, Technology and Research (STAR)*, IEEE, Jul. 2022, pp. 127–131. doi: 10.1109/STAR53492.2022.9859939.
- [20] B. Shen, M. Y. Shalaginov, and T. H. Zeng, "Injury Risk Prediction in Soccer Using Machine Learning," in *2023 International Conference on Machine Learning and Applications (ICMLA)*, IEEE, Dec. 2023, pp. 2103–2106. doi: 10.1109/ICMLA58977.2023.00317.
- [21] H. van Eetvelde, L. D. Mendonça, C. Ley, R. Seil, and T. Tischer, "Machine learning methods in sport injury prediction and prevention: a systematic review," *Journal of Experimental Orthopaedics*, vol. 8, no. 1, p. 27, Dec. 2021, doi: 10.1186/s40634-021-00346-x.
- [22] X. Ye, Y. Huang, Z. Bai, and Y. Wang, "A novel approach for sports injury risk prediction: based on time-series image encoding and deep learning," *Frontiers in Physiology*, vol. 14, Dec. 2023, doi: 10.3389/fphys.2023.1174525.
- [23] B. Sun, "Comprehensive evaluation of physical education based on personalized training plan generation algorithm and biomechanics," *Molecular & Cellular Biomechanics*, vol. 22, no. 1, p. 477, Jan. 2025, doi: 10.62617/mcb477.
- [24] A. Abasi, A. Nazari, A. Moezy, and S. A. Fatemi Aghda, "Machine learning models for reinjury risk prediction using cardiopulmonary exercise testing (CPET) data: optimizing athlete recovery," *BioData Mining*, vol. 18, no. 1, p. 16, Feb. 2025, doi: 10.1186/s13040-025-00431-2.
- [25] M. Wei et al., "Research Progress of Sports Injury Prediction Model Based on Machine Learning," in *AI in Healthcare*, 2024, pp. 23–41. doi: 10.1007/978-981-97-2898-5_4.
- [26] G. Pillitteri, A. Rossi, C. Simonelli, I. Leale, V. Giustino, and G. Battaglia, "Association between internal load responses and recovery ability in U19 professional soccer players: A machine learning approach," *Heliyon*, vol. 9, no. 4, p. e15454, Apr. 2023, doi: 10.1016/j.heliyon.2023.e15454.
- [27] N. Haller et al., "Predicting Injury and Illness with Machine Learning in Elite Youth Soccer: A Comprehensive Monitoring Approach over 3 Months," *Journal of Sports Science and Medicine*, pp. 475–486, Sep. 2023, doi: 10.52082/jssm.2023.475.
- [28] D. Xu et al., "Accurately and effectively predict the ACL force: Utilizing biomechanical landing pattern before and after-fatigue," *Computer Methods and Programs in Biomedicine*, vol. 241, p. 107761, Nov. 2023, doi: 10.1016/j.cmpb.2023.107761.
- [29] S. Ferreira, D. Carrilho, and D. Araújo, "An Ecological Dynamics Approach to the Use of Artificial Intelligence and Machine Learning to Analyze Performance in Football," in *Artificial Intelligence in Sport*, 2025, pp. 195–213. doi: 10.1007/978-3-031-76047-1_6.
- [30] R. E. D. Ayala, D. P. Granados, C. A. G. Gutiérrez, M. A. O. Ruiz, N. R. Espinosa, and E. C. Heredia, "Novel Study for the Early Identification of Injury Risks in Athletes Using Machine Learning Techniques," *Applied Sciences*, vol. 14, no. 2, p. 570, Jan. 2024, doi: 10.3390/app14020570.
- [31] V. Chang, S. Sajeev, Q. A. Xu, M. Tan, and H. Wang, "Football Analytics: Assessing the Correlation between Workload, Injury and Performance of Football Players in the English Premier League," *Applied Sciences*, vol. 14, no. 16, p. 7217, Aug. 2024, doi: 10.3390/app14167217.
- [32] T. Piłka, B. Grzelak, A. Sadurska, T. Górecki, and K. Dyczkowski, "Predicting Injuries in Football Based on Data Collected from GPS-Based Wearable Sensors," *Sensors*, vol. 23, no. 3, p. 1227, Jan. 2023, doi: 10.3390/s23031227.
- [33] S. U. Sharma, S. Divakaran, T. Kaya, and M. S. Raval, "A Computer Vision Framework on Biomechanical Analysis of Jump Landings," in *Proceedings of the Fifteenth Indian Conference on Computer Vision Graphics and Image Processing*, New York, NY, USA: ACM, Dec. 2024, pp. 1–9. doi: 10.1145/3702250.3702259.
- [34] S. Guzmán-Alfaro et al., "Analysis of the Correct Execution of Free Squats for Injury Prevention: A Genetic Algorithm Approach," 2025, pp. 155–166. doi: 10.1007/978-3-031-83435-6_12.
- [35] G. Nassis, E. Verhagen, J. Brito, P. Figueiredo, and P. Krstrup, "A review of machine learning applications in soccer with an emphasis on injury risk," *Biology of Sport*, vol. 40, no. 1, pp. 233–239, 2023, doi: 10.5114/biolport.2023.114283.
- [36] J. Cui, H. Du, and X. Wu, "Data analysis of physical recovery and injury prevention in sports teaching based on wearable devices," *Preventive Medicine*, vol. 173, p. 107589, Aug. 2023, doi: 10.1016/j.ypmed.2023.107589.
- [37] Y. Zhang, "Artificial Intelligence and Big Data-Based Injury Risk Assessment System for Sports Training," *Mobile Information Systems*, vol. 2022, pp. 1–7, Sep. 2022, doi: 10.1155/2022/7125462.
- [38] J. Sewell, J. G. Chase, and C. Zhou, "Understanding and Addressing ACL Tears in Female Football Athletes: A Comprehensive Analysis," *IFAC-PapersOnLine*, vol. 58, no. 24, pp. 31–36, 2024, doi: 10.1016/j.ifacol.2024.11.007.
- [39] P.-E. Dandrieux et al., "Relationship between a daily injury risk estimation feedback (I-REF) based on machine learning techniques and actual injury risk in athletics (track and field): protocol for a prospective cohort study over an athletics season," *BMJ Open*, vol. 13, no. 5, p. e069423, May 2023, doi: 10.1136/bmjopen-2022-069423.
- [40] X. Huo, "Optimizing physical education movements through biomechanical analysis: A new approach to reducing the risk of sports injuries," *Molecular & Cellular Biomechanics*, vol. 21, no. 4, p. 502, Dec. 2024, doi: 10.62617/mcb502.
- [41] M. S. Croock, A. N. Rashid, and B. M. Merzah, "Intelligent Classifiers for Football Player Performance Based on Machine Learning Models," *International Journal of Electrical and Computer Engineering Systems*, vol. 15, no. 2, pp. 173–183, Feb. 2024. doi: 10.32985/ijees.15.2.6.