

INTELIGENCIA ARTIFICIAL APLICADA AL ENTRENAMIENTO DEPORTIVO



Luis Enríquez & Liliana Sánchez



EDITORIAL
SAGA

Inteligencia artificial aplicada al entrenamiento deportivo



Autor:

*Luis Alexander Enríquez Enríquez
Liliana del Cisne Sánchez Ramírez*



Datos bibliográficos

ISBN:	978-9907-803-74-7
Título del libro:	Inteligencia artificial aplicada al entrenamiento deportivo
Autores:	Enríquez Enríquez, Luis Alexander Sánchez Ramírez, Liliana del Cisne
Editorial:	SAGA
Materia:	796 - Deportes y juegos atléticos y al aire libre
Público objetivo:	Profesional / académico
Publicado:	2026-09-17
Número de edición:	1
Tamaño:	5Mb
Soporte:	Libro digital descargable
Formato:	Pdf (.pdf)
Idioma:	Español
DOI:	https://doi.org/10.63415/saga.2026.128

Hecho En el Ecuador / Made in Ecuador

Autores

Luis Alexander Enríquez Enríquez

Universidad Politécnica Estatal del Carchi (UPEC)

✉ luisal.enriquez@upec.edu.ec

 <https://orcid.org/0009-0000-9636-3962>

Tulcán, Ecuador

Es docente de la Universidad Politécnica Estatal del Carchi (UPEC), donde desarrolla su labor académica vinculada con la formación universitaria y el ámbito deportivo. Su trayectoria profesional reúne preparación pedagógica y conocimientos especializados en ciencias del entrenamiento, elementos que respaldan su participación como autor del libro *Inteligencia artificial aplicada al entrenamiento deportivo*.

Realizó estudios de maestría con especialidad en Ciencia del Entrenamiento de Pedagogía Deportiva en Beijing Sport University, universidad situada en la República Popular China y reconocida por su orientación hacia las ciencias del deporte, la educación física y la formación especializada. Su preparación internacional amplió su perspectiva académica sobre los procesos de entrenamiento y el desarrollo de capacidades físicas desde una visión científica.

Además, obtuvo el título de Licenciado en Educación Física y Deporte en la Escuela Internacional de Educación Física y Deporte, institución ubicada en Cuba. Su formación articula educación, pedagogía y entrenamiento deportivo.

En su actividad docente mantiene una relación permanente con la enseñanza universitaria y la preparación de futuros profesionales. Su aporte a la presente obra vincula la experiencia académica con las posibilidades que brindan las tecnologías de inteligencia artificial para el análisis, la planificación y la innovación dentro del entrenamiento deportivo contemporáneo.

Liliana del Cisne Sánchez Ramírez
Ministerio de Educación, Deporte y Cultura
 liliana.sanchezr@educacion.gob.ec
 <https://orcid.org/0009-0003-6139-5421>
Machala, Ecuador

Es docente de Educación Física del magisterio fiscal y ejerce sus funciones en la Unidad Educativa Nueve de Octubre, ubicada en la ciudad de Machala, Ecuador. Su trayectoria profesional se encuentra vinculada con la educación, la pedagogía y la cultura física, áreas desde las cuales ha desarrollado una labor orientada a fortalecer los procesos de enseñanza y la participación de los estudiantes en experiencias educativas relacionadas con la actividad física.

Posee el grado de Magíster en Educación con mención en Pedagogía, otorgado por la Universidad Tecnológica Empresarial de Guayaquil, Ecuador. También es Licenciada en Ciencias de la Educación con especialización en Cultura Física por la Universidad Técnica de Machala, Ecuador. Ambas titulaciones sustentan una formación que integra conocimientos pedagógicos con saberes propios de la educación física.

Su producción académica aborda temáticas vinculadas con educación, inclusión, diversidad funcional e inteligencia artificial. Entre sus publicaciones figuran Estrategias para Fomentar la Inclusión de Estudiantes con Diversidades Funcionales en Clases de Educación Física e Integración de la Inteligencia Artificial en el Contexto Educativo Latinoamericano: Una Exploración a las Perspectivas Emergentes y los Desafíos Futuros.

Como autora de *Inteligencia artificial aplicada al entrenamiento deportivo*, aporta una perspectiva pedagógica que relaciona la innovación tecnológica y la formación profesional.



El contenido y las ideas expuestas en esta obra se encuentran protegidos por la normativa vigente en materia de propiedad intelectual y constituyen derechos exclusivos de su(s) autor(es)

Todos los derechos reservados © 2026

Sinopsis

Inteligencia artificial aplicada al entrenamiento deportivo presenta una visión académica y aplicada sobre la incorporación de sistemas inteligentes en la planificación, evaluación y regulación del rendimiento físico, articulando conocimientos procedentes de las ciencias del deporte, la informática y el análisis de datos para fortalecer la toma de decisiones profesionales. La obra examina modelos de aprendizaje automático orientados al procesamiento de indicadores fisiológicos, biomecánicos y perceptivos, junto con técnicas de visión artificial capaces de reconocer patrones de movimiento y variaciones relevantes durante la práctica deportiva. Especial atención recibe la predicción de fatiga y recuperación mediante series temporales, registros de carga interna y externa, datos de sueño y respuestas individuales ante diferentes estímulos. El desarrollo temático aborda la personalización algorítmica del volumen, intensidad, densidad y frecuencia, además del empleo de sistemas de recomendación, aprendizaje por refuerzo y gemelos digitales para simular respuestas adaptativas. También analiza asistentes generativos, modelos explicables y mecanismos de trazabilidad destinados a respaldar el criterio del entrenador. La integración responsable de datos, predicciones y experiencia profesional configura una metodología de trabajo orientada a mejorar la precisión de la planificación, interpretar el rendimiento y favorecer decisiones individualizadas, verificables y sustentadas científicamente en entornos deportivos contemporáneos de diversa exigencia competitiva actual.

Palabras clave: inteligencia artificial, reconocimiento de formas, sistema experto, aplicación informática, robótica

Synopsis

Artificial Intelligence Applied to Sports Training presents an academic and applied perspective on the incorporation of intelligent systems into the planning, assessment, and regulation of physical performance, bringing together knowledge from sports science, computer science, and data analysis to strengthen professional decision-making. The book examines machine-learning models designed to process physiological, biomechanical, and perceptual indicators, together with computer-vision techniques capable of identifying movement patterns and relevant variations during sports practice. Particular attention is devoted to predicting fatigue and recovery through time series, internal and external load records, sleep data, and individual responses to different stimuli. The thematic development addresses algorithmic personalization of volume, intensity, density, and frequency, along with recommendation systems, reinforcement learning, and digital twins for simulating adaptive responses. It also analyzes generative assistants, explainable models, and traceability mechanisms designed to support coaches' professional judgment. The responsible integration of data, predictions, and professional experience establishes a working methodology aimed at improving planning accuracy, interpreting performance, and promoting individualized, verifiable, and scientifically supported decisions across contemporary sports environments characterized by varying levels of competitive demand.

Keywords: artificial intelligence, pattern recognition, expert systems, computer applications, robotics

Índice General

Sinopsis.....	vii
Índice General	9
Índice de Tablas	12
Índice de Figuras.....	13
Introducción	15
Capítulo I Arquitecturas de inteligencia artificial para la planificación del entrenamiento deportivo	19
1.1. Modelado algorítmico de la planificación deportiva según objetivos de rendimiento	23
1.2. Periodización dinámica asistida por algoritmos de aprendizaje automático	26
1.3. Integración inteligente de datos fisiológicos, biomecánicos y contextuales	30
1.4. Sistemas predictivos para la distribución temporal de estímulos de entrenamiento	33
1.5. Optimización multiobjetivo de sesiones y microciclos mediante inteligencia artificial.....	37
1.6. Simulación de escenarios de entrenamiento para la toma anticipada de decisiones	40
Capítulo II Analítica inteligente del rendimiento deportivo y extracción de patrones	45
2.1. Aprendizaje automático aplicado a la identificación de patrones de rendimiento	49
2.2. Visión artificial para el análisis técnico y biomecánico del movimiento.....	52
2.3. Analítica multimodal para integrar datos de sensores, video y registros de entrenamiento.....	56

2.4. Detección algorítmica de cambios significativos en indicadores de rendimiento.....	59
2.5. Modelos de inteligencia artificial explicable para interpretar el rendimiento deportivo	62
2.6. Construcción de perfiles digitales longitudinales del deportista.....	66

Capítulo III Predicción de fatiga, recuperación y disponibilidad para entrenar 71

3.1. Modelos predictivos de fatiga a partir de series temporales deportivas	75
3.2. Estimación inteligente de la recuperación mediante indicadores internos y externos	78
3.3. Detección temprana de respuestas atípicas ante las cargas de entrenamiento.....	82
3.4. Predicción individual de disponibilidad para sesiones de diferente exigencia.....	85
3.5. Modelos de carga-respuesta para anticipar variaciones del rendimiento.....	89
3.6. Sistemas de alerta inteligente para apoyar decisiones sobre carga y recuperación	92

Capítulo IV Personalización algorítmica de cargas y prescripción adaptativa 97

4.1. Prescripción individualizada mediante aprendizaje automático	101
4.2. Ajuste dinámico de volumen, intensidad, densidad y frecuencia del entrenamiento	104
4.3. Sistemas de recomendación aplicados a ejercicios y contenidos de entrenamiento	108
4.4. Aprendizaje por refuerzo para la adaptación secuencial de cargas deportivas	111
4.5. Gemelos digitales del deportista para simular respuestas individuales al entrenamiento.....	114

4.6. Personalización en tiempo real mediante datos procedentes de dispositivos portátiles	117
Capítulo V Inteligencia artificial como sistema de apoyo a la decisión del entrenador.....	123
5.1. Sistemas de apoyo a decisiones para la dirección del proceso de entrenamiento	127
5.2. Inteligencia artificial generativa para el diseño y reajuste de sesiones deportivas	130
5.3. Asistentes conversacionales especializados para consulta y seguimiento del entrenamiento.....	134
5.4. Explicabilidad y trazabilidad de recomendaciones algorítmicas en contextos deportivos.....	137
5.5. Interacción entrenador-IA y modelos de decisión con supervisión humana	141
5.6. Gobernanza del dato y validación de sistemas de IA aplicados al entrenamiento deportivo	144
Conclusiones	149
Referencias Bibliográficas.....	153

Índice de Tablas

Tabla 1 <i>Componentes funcionales de la arquitectura de inteligencia artificial para la planificación del entrenamiento deportivo</i>	43
Tabla 2 <i>Componentes de la analítica inteligente aplicados al rendimiento deportivo</i>	69
Tabla 3 <i>Componentes analíticos para la predicción de fatiga, recuperación y disponibilidad para entrenar</i>	95
Tabla 4 <i>Componentes de la personalización algorítmica de cargas y la prescripción adaptativa</i>	121
Tabla 5 <i>Componentes de la inteligencia artificial como sistema de apoyo a la decisión del entrenador</i>	147

Índice de Figuras

Figura 1 <i>Arquitectura inteligente para la planificación deportiva</i>	21
Figura 2 <i>Periodización dinámica mediante aprendizaje automático</i> ...	27
Figura 3 <i>Predicción temporal de estímulos de entrenamiento</i>	35
Figura 4 <i>Arquitectura de la analítica inteligente del rendimiento deportivo</i>	47
Figura 5 <i>Visión artificial aplicada al análisis del movimiento deportivo</i>	53
Figura 6 <i>Detección algorítmica de variaciones del rendimiento</i>	61
Figura 7 <i>Predicción inteligente para la gestión del entrenamiento</i>	73
Figura 8 <i>Integración inteligente de indicadores de recuperación</i>	79
Figura 9 <i>Predicción individual de disponibilidad para entrenar</i>	87
Figura 10 <i>Personalización algorítmica del entrenamiento</i>	99
Figura 11 <i>Ajuste dinámico de la carga deportiva</i>	105
Figura 12 <i>Adaptación secuencial mediante aprendizaje por refuerzo</i>	113
Figura 13 <i>IA como apoyo a la decisión del entrenador</i>	125
Figura 14 <i>Diseño adaptativo de sesiones mediante IA generativa</i>	131
Figura 15 <i>Explicabilidad y trazabilidad de decisiones algorítmicas</i> ..	139

Introducción

La transformación digital del deporte ha modificado de manera profunda la observación, planificación y evaluación del entrenamiento. Durante décadas, entrenadores y científicos interpretaron el rendimiento mediante pruebas periódicas, registros manuales y experiencia acumulada; hoy, sensores, cámaras, plataformas de seguimiento y algoritmos permiten trabajar con flujos continuos de información. Badiola-Bengoa y Mendez-Zorrilla (2021) documentan la expansión de técnicas de estimación de pose humana basadas en cámaras para estudiar ejercicio y deporte, evidenciando una transición hacia mediciones automatizadas del movimiento con creciente utilidad aplicada.

La inteligencia artificial adquiere relevancia dentro de dicha transformación porque permite relacionar grandes cantidades de variables cuya interpretación conjunta resulta difícil mediante procedimientos convencionales. El interés no reside únicamente en acumular datos, sino en convertirlos en conocimiento útil para decidir. Connor et al. (2022) plantean la generación adaptativa de planes de entrenamiento mediante sistemas inteligentes de control, vinculando planificación y respuesta individual. Bajo tal perspectiva, el entrenamiento deja de concebirse como una secuencia rígida y adquiere capacidad de reajuste conforme cambian rendimiento, carga, recuperación y objetivos deportivos.

Una cuestión central radica en comprender al deportista como un sistema dinámico cuya respuesta varía incluso ante cargas aparentemente equivalentes. La fatiga, el sueño, la experiencia previa, el volumen acumulado y numerosos indicadores fisiológicos alteran la disponibilidad diaria. Mandorino et al. (2023) emplearon técnicas de aprendizaje automático para cuantificar la preparación de futbolistas, mostrando el valor de integrar múltiples variables

para respaldar la interpretación profesional. Teixeira et al. (2024), por su parte, aplicaron aprendizaje automático a la clasificación de estados de recuperación en futbolistas jóvenes de distintas categorías competitivas.

La relevancia académica de la obra parte precisamente de la necesidad de vincular ciencias del deporte e inteligencia artificial sin reducir ninguna disciplina a una función instrumental. Los algoritmos requieren datos pertinentes, diseños metodológicos rigurosos y criterios de validación; la práctica deportiva necesita herramientas interpretables que respeten la variabilidad humana. De Leeuw et al. (2022) desarrollaron un enfoque personalizado de aprendizaje automático para monitorizar lesiones en voleibolistas de élite, mientras Majumdar et al. (2024) analizaron durante varias temporadas las relaciones entre carga de entrenamiento y lesiones mediante técnicas computacionales aplicadas al fútbol profesional.

Otro campo de desarrollo corresponde al análisis automatizado del movimiento. La visión artificial permite estimar posiciones corporales, trayectorias articulares y características técnicas a partir de imágenes, ampliando las posibilidades de evaluación fuera de laboratorios altamente instrumentados. Fukushima et al. (2024) evaluaron el potencial de la estimación de pose humana para captura de movimiento deportivo mediante un estudio de validación. Tal línea investigativa abre posibilidades para integrar biomecánica, seguimiento técnico y retroalimentación automatizada, aunque exige valorar precisión, condiciones de registro y pertinencia deportiva antes de trasladar resultados algorítmicos a decisiones de entrenamiento.

El propósito general del libro consiste en analizar las aplicaciones de inteligencia artificial que pueden fortalecer la planificación, el análisis del rendimiento, la predicción de fatiga, la personalización de cargas y el apoyo al entrenador. Desde una perspectiva aplicada, interesa determinar qué datos aportan información relevante, qué modelos permiten reconocer patrones

individuales y qué procedimientos favorecen decisiones comprensibles. Cordeiro et al. (2025) abordaron la predicción de atenuación del rendimiento mediante aprendizaje automático apoyado en datos sintéticos, ejemplo de una línea orientada a anticipar variaciones antes de que resulten evidentes mediante observación convencional.

Varias preguntas orientan el recorrido intelectual de la obra: ¿qué variables permiten construir modelos útiles para planificar y reajustar cargas?, ¿qué capacidad poseen los algoritmos para distinguir fatiga, recuperación y disponibilidad individual?, ¿qué nivel de precisión ofrecen las tecnologías de visión artificial y los dispositivos portátiles?, ¿de qué manera pueden integrarse predicciones y experiencia profesional sin desplazar el juicio del entrenador? Li y Zhang (2022) estudiaron dispositivos portátiles aplicados a la evaluación de enseñanza y entrenamiento en baloncesto, mientras Cui et al. (2023) relacionaron tecnologías vestibles con recuperación física y prevención de lesiones.

La personalización constituye otro eje vertebrador. Frente a prescripciones construidas desde valores promedio, los modelos computacionales permiten aprender de trayectorias individuales y actualizar recomendaciones cuando aparecen nuevos datos. Los gemelos digitales amplían dicha lógica mediante representaciones virtuales destinadas a modelar procesos y ensayar alternativas. Lukač et al. (2022) examinan la transición conceptual del gemelo digital hacia su realización en deporte, y Hliš et al. (2024) desarrollan una clasificación más amplia de sus aplicaciones y posibilidades prácticas. La simulación adquiere, por ello, valor para comparar decisiones antes de intervenir sobre el entrenamiento real.

La organización del libro responde a una secuencia que acompaña el ciclo de decisión deportiva. El primer capítulo aborda arquitecturas de inteligencia artificial destinadas a planificación, periodización y simulación de estímulos; el segundo desarrolla

analítica del rendimiento, visión artificial, integración multimodal y perfiles digitales; el tercero concentra la atención en fatiga, recuperación y disponibilidad. El cuarto estudia prescripción individualizada, sistemas de recomendación, aprendizaje por refuerzo y gemelos digitales. Xia et al. (2025) aportan una referencia reciente al aplicar aprendizaje profundo por refuerzo al control personalizado de cargas para optimizar rendimiento competitivo.

El quinto capítulo sitúa al entrenador en el centro de la relación entre conocimiento deportivo y capacidad computacional, abordando sistemas de apoyo a decisiones, inteligencia artificial generativa, asistentes conversacionales, explicabilidad, trazabilidad, supervisión humana y gobernanza del dato. Pashaie et al. (2026) analizan la evolución de estrategias de entrenamiento vinculadas con inteligencia artificial, mientras Ganaie et al. (2026) sintetizan mediante metaanálisis los efectos del entrenamiento asistido por IA sobre el rendimiento deportivo. La obra busca, en consecuencia, aportar criterios científicos para que datos, algoritmos y experiencia profesional converjan en decisiones individualizadas, verificables y metodológicamente responsables.

Capítulo I

Arquitecturas de inteligencia artificial para la planificación del entrenamiento deportivo

Planificar el entrenamiento deportivo siempre ha implicado interpretar señales incompletas, proyectar adaptaciones y decidir bajo márgenes inevitables de incertidumbre. La inteligencia artificial modifica profundamente dicha labor al incorporar arquitecturas capaces de procesar grandes volúmenes de información y relacionar variables que antes permanecían dispersas. No elimina el juicio profesional ni convierte el entrenamiento en una secuencia automática. Más bien, amplía la capacidad analítica del entrenador y aporta nuevas formas de organizar decisiones orientadas al rendimiento.


La transformación resulta especialmente visible cuando los objetivos deportivos dejan de expresarse únicamente mediante metas generales y pasan a vincularse con estructuras computacionales capaces de representar relaciones entre cargas, respuestas y horizontes temporales. Connor et al. (2022) demostraron que los sistemas inteligentes de control pueden reajustar planes ante desviaciones respecto de una trayectoria programada. Desde tal perspectiva, planificar adquiere un carácter adaptable, donde cada decisión conserva dirección estratégica mientras permanece abierta a nueva evidencia procedente del entrenamiento.

Tal cambio exige reconsiderar la temporalidad de la preparación. Los ciclos deportivos ya no necesitan entenderse como estructuras cerradas cuya validez depende del cumplimiento exacto de una programación previa. La disponibilidad cotidiana del atleta introduce variaciones que merecen interpretación cuidadosa. Mandorino et al. (2023) mostraron que el aprendizaje automático permite construir indicadores individualizados de preparación a partir de relaciones entre carga externa y respuesta neuromuscular, aportando información relevante para ajustar decisiones durante diferentes momentos de la temporada.

A medida que crece la capacidad de registro, la arquitectura de planificación recibe información fisiológica, biomecánica,

perceptiva y ambiental procedente de fuentes diversas. El verdadero avance no reside en acumular mediciones, sino en establecer relaciones que permitan distinguir señales útiles de fluctuaciones carentes de relevancia práctica. Los modelos inteligentes pueden reconocer asociaciones longitudinales y dependencias entre variables, aunque toda inferencia necesita conservar significado deportivo. Los datos adquieren valor cuando ayudan a comprender al atleta como sistema cambiante.

Figura 1
Arquitectura inteligente para la planificación deportiva



Mandorino et al. (2023) evidenciaron también la importancia de individualizar la interpretación de las respuestas, pues una misma carga puede adquirir significados diferentes entre deportistas y momentos competitivos. Tal principio atraviesa buena parte de las arquitecturas contemporáneas. La información deja de operar como registro retrospectivo y comienza a alimentar estimaciones prospectivas. Con ello, la planificación gana una dimensión anticipatoria: interesa conocer lo ocurrido, pero también valorar trayectorias probables antes de decidir dónde ubicar los próximos estímulos.

La anticipación abre una cuestión particularmente delicada. Ningún algoritmo conoce con certeza la respuesta futura de un organismo sometido a entrenamiento, aunque pueda estimar probabilidades mediante patrones históricos. Por esa razón, la predicción resulta valiosa cuando conserva visibles sus márgenes de incertidumbre. El entrenador recibe escenarios probables, no respuestas infalibles. Esa distinción protege la naturaleza deliberativa de la planificación y permite combinar conocimiento profesional, evidencia acumulada y resultados computacionales sin otorgar autoridad absoluta a ninguna fuente aislada.

Cuando varias metas coinciden dentro de una sesión o un microciclo, decidir requiere negociar prioridades. Mejorar potencia, desarrollar resistencia, preservar recuperación y llegar en condiciones favorables a la competición pueden demandar soluciones parcialmente contrapuestas. La inteligencia artificial ofrece procedimientos para comparar alternativas bajo múltiples criterios, haciendo visibles intercambios que habitualmente permanecen implícitos. La planificación adquiere entonces una dimensión de optimización razonada, donde la mejor alternativa depende de restricciones, preferencias deportivas y consecuencias esperadas durante periodos posteriores.

La capacidad computacional permite, además, ensayar decisiones antes de aplicarlas sobre el deportista. Hliš et al. (2024) describen los gemelos digitales en el deporte como representaciones con potencial para apoyar entrenamiento, gestión del atleta y búsqueda de soluciones estratégicas. Mediante simulaciones, diferentes cursos de acción pueden contrastarse bajo condiciones variables. El interés radica menos en reproducir perfectamente la realidad que en disponer de un espacio virtual donde evaluar consecuencias plausibles, vulnerabilidades y alternativas previamente.

Por debajo de tales posibilidades permanece una cuestión humana difícil de reducir a parámetros. Entrenar implica

interpretar personas, momentos competitivos, respuestas inesperadas y prioridades que cambian durante una temporada. Connor et al. (2022) conciben sus sistemas inteligentes como herramientas de apoyo a la decisión, orientación especialmente pertinente para delimitar el papel de la tecnología. La arquitectura computacional puede ampliar la mirada del profesional, pero la pertinencia deportiva de una recomendación continúa requiriendo conocimiento, experiencia y responsabilidad en su aplicación.

A lo largo del capítulo, la planificación inteligente será entendida como una arquitectura articulada de aprendizaje, integración, anticipación, optimización y simulación. Cada componente responde a una función particular, aunque su verdadero potencial aparece mediante interacción coordinada. Desde la adaptación de planes hasta los gemelos digitales analizados por Hliš et al. (2024), la evolución tecnológica apunta hacia sistemas capaces de acompañar decisiones cada vez más complejas. El propósito permanece reconocible: planificar mejor sin perder de vista al deportista.

1.1. Modelado algorítmico de la planificación deportiva según objetivos de rendimiento

El modelado algorítmico de la planificación deportiva parte de una premisa: todo objetivo de rendimiento debe traducirse en variables observables, restricciones y criterios de optimización. La meta competitiva deja de funcionar como declaración general y adquiere una representación matemática vinculada con cargas, tiempos de recuperación, capacidades prioritarias y márgenes de tolerancia. Bajo dicha lógica, el algoritmo organiza decisiones, compara estados previstos con respuestas registradas y reajusta la prescripción sin perder la dirección estratégica del proceso.

La formulación del objetivo determina la arquitectura de decisión que gobernará el plan. Un incremento de potencia, la mejora de resistencia específica o la preparación para una secuencia

competitiva requieren funciones de coste diferentes, horizontes temporales y restricciones particulares. Connor et al. (2022) plantean la adaptación de cargas como un problema de control óptimo orientado a reducir la distancia entre la trayectoria deseada y la respuesta observada. Tal enfoque convierte la planificación en regulación dinámica.

Traducir metas deportivas a parámetros computables exige distinguir resultados terminales de indicadores intermedios. Una marca, una posición competitiva o nivel de potencia pueden constituir metas de llegada, mientras carga acumulada, velocidad, percepción de esfuerzo o disponibilidad neuromuscular actúan como señales de seguimiento. La utilidad del modelo depende de relacionar ambos niveles mediante reglas explícitas. De otro modo, una predicción precisa puede carecer de valor para orientar la sesión siguiente o modificar una semana de entrenamiento.

Dentro de esa representación, las restricciones cumplen una función pareja a la optimización. El algoritmo no debería perseguir mejoras ignorando disponibilidad, calendario, exposición, recuperación o límites establecidos por el cuerpo técnico. En computación, planificar implica buscar una solución aceptable dentro de un espacio de posibilidades condicionado. Esa perspectiva evita confundir eficiencia matemática con pertinencia deportiva. Una carga óptima en simulación puede resultar inadecuada cuando altera la secuencia pedagógica, táctica o competitiva prevista para el atleta.

La individualización algorítmica adquiere precisión cuando el sistema aprende relaciones propias de cada deportista, en lugar de depender de promedios grupales. Mandorino et al. (2023) mostraron que técnicas de aprendizaje automático permiten estimar la disposición neuromuscular mediante diferencias individualizadas entre carga prevista y carga registrada. Para la planificación, tal principio resulta fértil: las desviaciones dejan de interpretarse como ruido y pasan a alimentar decisiones sobre

intensidad, volumen, recuperación o distribución semanal según la respuesta observada.

La planificación orientada por objetivos requiere manejar escalas temporales distintas. Una sesión responde a necesidades, un microciclo distribuye estímulos y recuperación, mientras bloques sostienen adaptaciones relacionadas con la temporada. El algoritmo debe preservar relaciones entre dichas escalas para evitar correcciones localmente convenientes que perjudiquen metas posteriores. Por ello, una reducción de carga puede ser adecuada ante fatiga transitoria, pero inconveniente si rompe la progresión necesaria para alcanzar una adaptación prevista antes de una competencia prioritaria.

Otro componente reside en la actualización de decisiones mediante retroalimentación. El plan gana valor cuando compara lo prescrito con lo realizado y utiliza la diferencia para recalcular acciones. Connor et al. (2022) observaron, mediante simulaciones, que un controlador inteligente redujo desviaciones respecto de la meta de planificación más eficazmente que estrategias aleatorias o proporcionales. La enseñanza metodológica es clara: adaptar no equivale a improvisar, sino a corregir dentro de reglas coherentes con el objetivo formalizado.

La función objetivo puede incorporar dimensiones cuando el rendimiento no depende de una capacidad aislada. En deportes conviven demandas físicas, técnicas, tácticas y psicológicas, cuya ponderación cambia durante la temporada. La síntesis de Ganaie et al. (2026) encontró efectos favorables del entrenamiento asistido por inteligencia artificial en dimensiones del rendimiento, con magnitudes diferenciadas entre dominios. Desde la planificación, ello respalda modelos capaces de priorizar componentes sin reducir el rendimiento a una única métrica de carga.

La calidad de una decisión depende de la trazabilidad entre objetivo, datos y prescripción. El entrenador necesita reconocer por

qué una modificación aparece en el plan, qué variable la activa y qué consecuencia busca producir. La interpretabilidad permite contrastar la salida con conocimiento y condiciones de práctica. Cuando esa relación resulta visible, la inteligencia artificial funciona como soporte deliberativo; cuando permanece opaca, aumenta el riesgo de aceptar recomendaciones matemáticamente plausibles, aunque difíciles de justificar deportivamente.

En consecuencia, modelar la planificación según objetivos de rendimiento implica construir arquitectura que conecte metas, indicadores, restricciones, predicciones y mecanismos de ajuste. Su aporte no radica en reemplazar el juicio profesional, sino en formalizar relaciones que suelen gestionarse mediante experiencia. La evidencia revisada por Ganaie et al. (2026) respalda el valor de sistemas asistidos para optimizar decisiones de entrenamiento. El reto consiste en mantener la dirección deportiva mientras el algoritmo aprende, corrige y redistribuye cargas.

1.2. Periodización dinámica asistida por algoritmos de aprendizaje automático

La periodización dinámica asistida por aprendizaje automático transforma la distribución temporal de cargas en un proceso adaptable, capaz de responder a variaciones del rendimiento sin abandonar la orientación prevista. Frente a esquemas rígidos, la secuencia de estímulos puede reajustarse mediante datos acumulados durante sesiones, microciclos y bloques. El interés no reside en modificar continuamente el programa, sino en reconocer cuándo una alteración posee relevancia fisiológica o competitiva para justificar cambios en volumen, intensidad o recuperación.

Una arquitectura dinámica necesita representar la periodización como sucesión de estados vinculados, donde cada decisión condiciona posibilidades posteriores. La carga prescrita deja una huella que modifica la respuesta probable ante estímulos

futuros; por ello, el algoritmo aprende relaciones temporales y estima consecuencias antes de recomendar ajustes. Connor et al. (2022) abordaron dicha lógica mediante un control inteligente, vinculando planificación adaptativa y retroalimentación para reducir desviaciones entre la trayectoria programada y evolución registrada por el deportista.

Figura 2

Periodización dinámica mediante aprendizaje automático



El aprendizaje automático aporta valor cuando identifica patrones que permanecen ocultos bajo lecturas aisladas de los indicadores. Series de carga externa, percepción de esfuerzo, rendimiento neuromuscular y recuperación adquieren significado al observarse conjuntamente durante periodos sucesivos. La periodización puede entonces ajustar sus ritmos con mayor sensibilidad. No se trata de obedecer fluctuación diaria, pues la variabilidad pertenece al entrenamiento normal, sino de distinguir señales persistentes capaces de anticipar una pérdida de disponibilidad o respuesta adaptativa.

La estimación de la disposición diaria constituye una pieza relevante dentro de dicho mecanismo. Mandorino et al. (2023) desarrollaron procedimientos de aprendizaje automático orientados a cuantificar la preparación de futbolistas mediante relaciones individualizadas entre medidas de carga y rendimiento. Trasladada a la periodización, dicha información permite graduar la exigencia sin desarticular el bloque previsto. Una sesión puede desplazarse, reducirse o intensificarse cuando la evidencia acumulada indica que la respuesta probable difiere de la esperada inicialmente.

Los algoritmos de refuerzo amplían la capacidad adaptativa al aprender políticas de decisión mediante interacción con datos del deportista. Cada acción genera una respuesta que alimenta decisiones posteriores, creando una relación entre prescripción y consecuencia. Xia et al. (2025) plantean un control personalizado de carga basado en aprendizaje profundo por refuerzo, orientado a optimizar el rendimiento competitivo. La periodización adquiere, bajo tal enfoque, una estructura que aprende de resultados previos mientras conserva metas definidas temporalmente.

La utilidad de una política adaptativa depende de la función de recompensa utilizada. Si el sistema premia únicamente mejoras inmediatas, puede favorecer cargas incompatibles con procesos de adaptación prolongados. Conviene representar beneficios diferidos, estabilidad del rendimiento, recuperación y proximidad competitiva mediante ponderaciones coherentes. La periodización dinámica requiere equilibrio entre respuesta presente y ganancia futura; de ahí que diseñar recompensas constituya una decisión metodológica central vinculada con la concepción deportiva que orienta el programa de preparación.

Otro nivel de complejidad aparece cuando el calendario introduce competencias, viajes, concentraciones o periodos de recuperación. La periodización algorítmica debe tratar tales eventos como restricciones temporales capaces de modificar

prioridades y márgenes de maniobra. Un modelo sensible a la secuencia competitiva puede redistribuir estímulos sin perder continuidad adaptativa. Connor et al. (2022) muestran que el control inteligente permite reajustar planes ante respuestas divergentes, principio muy útil cuando el tiempo disponible limita correcciones amplias del ciclo.

La personalización gana profundidad cuando los modelos actualizan sus parámetros con información longitudinal del mismo atleta. Dos deportistas expuestos a cargas equivalentes pueden requerir distribuciones temporales diferentes debido a respuestas, ritmos de recuperación y antecedentes de entrenamiento. Mandorino et al. (2023) destacan el valor de modelos individualizados para estimar la preparación deportiva. En periodización, tal perspectiva favorece decisiones independientes de promedios colectivos y más atentas a la trayectoria que cada organismo construye durante la temporada.

Sin embargo, una periodización dinámica necesita límites de intervención para evitar oscilaciones excesivas. Modificar el plan ante cambios puede destruir la continuidad para producir adaptaciones. Resulta preferible establecer umbrales, ventanas de observación y reglas de persistencia que determinen cuándo una señal merece alterar la secuencia. El algoritmo actúa entonces como regulador de la variabilidad, no como generador de novedades. Su calidad se aprecia en la capacidad de cambiar cuando conviene y conservar cuando resulta prudente.

Desde una perspectiva arquitectónica, la periodización asistida por aprendizaje automático articula predicción, actualización y control dentro de una lógica temporal. Los datos informan el estado del atleta, los modelos estiman respuestas probables y una política decide ajustes compatibles con metas futuras. Xia et al. (2025) vinculan el aprendizaje por refuerzo con control personalizado de cargas orientado al rendimiento. La

aportación central reside en convertir la periodización en una estructura adaptable, trazable y disciplinada por objetivos.

1.3. Integración inteligente de datos fisiológicos, biomecánicos y contextuales

La integración inteligente de datos fisiológicos, biomecánicos y ambientales permite representar al deportista mediante señales heterogéneas que adquieren sentido cuando dialogan entre sí. Frecuencia cardíaca, variabilidad autonómica, aceleraciones, fuerzas, patrones cinemáticos, sueño, temperatura o características de la sesión describen dimensiones diferentes de una misma respuesta. La arquitectura computacional debe relacionarlas sin confundir cantidad con relevancia. Integrar datos significa construir vínculos interpretables capaces de convertir registros dispersos en información útil para orientar decisiones de planificación deportiva.

La primera dificultad reside en armonizar señales producidas con frecuencias, unidades y niveles de precisión diferentes. Un sensor registra movimientos por segundo, mientras un cuestionario aporta una observación diaria y una prueba neuromuscular ofrece mediciones puntuales. Antes del aprendizaje algorítmico, tales fuentes requieren sincronización, normalización y control de calidad. La coherencia temporal importa especialmente: asociar una respuesta fisiológica con una carga incorrecta puede generar relaciones estadísticas convincentes, aunque deportivamente carentes de significado para la planificación posterior.

Los dispositivos portátiles amplían la observación fuera del laboratorio y acercan la medición a situaciones habituales de práctica. Cui et al. (2023) relacionan el análisis procedente de tecnologías vestibles con la valoración de recuperación física y prevención de lesiones en enseñanza deportiva. Su interés arquitectónico reside en alimentar modelos mediante registros

continuos. Sin embargo, mayor frecuencia de captura no garantiza mejores inferencias; la selección de variables debe responder a preguntas deportivas bien delimitadas y criterios técnicos previamente establecidos.

La dimensión fisiológica informa acerca de la respuesta interna frente al estímulo, mientras la biomecánica describe características mecánicas del movimiento realizado. Integrarlas permite reconocer situaciones donde una carga externa semejante produce costes internos diferentes o donde cambios cinemáticos acompañan estados de fatiga. Ninguna señal posee significado absoluto. Su interpretación depende de tendencias individuales, momento de medición y relación con otras variables. El valor analítico nace precisamente de las conexiones que el modelo aprende entre dominios previamente separados.

La disponibilidad del deportista constituye un ejemplo fértil de integración multimodal. Mandorino et al. (2023) emplearon técnicas de aprendizaje automático para cuantificar la preparación de futbolistas a partir de relaciones individualizadas entre indicadores de carga y medidas neuromusculares. Tal aproximación desplaza la lectura desde valores aislados hacia configuraciones de señales. Para una arquitectura de planificación, ello permite estimar estados funcionales mediante combinaciones cambiantes, evitando atribuir capacidad explicativa excesiva a un indicador particular observado durante una jornada determinada.

Los datos vinculados con condiciones externas añaden otra capa interpretativa: temperatura, superficie, desplazamientos, horario, densidad competitiva o características de la tarea pueden modificar el significado de respuestas fisiológicas y mecánicas. Una frecuencia cardíaca elevada adquiere lecturas diferentes bajo calor intenso o tras una secuencia exigente de partidos. La inteligencia artificial puede modelar interacciones entre dichas variables, siempre que su registro conserve calidad suficiente. La riqueza

informativa procede de relacionar circunstancias de práctica con respuestas individuales observadas.

La clasificación automatizada de estados de recuperación muestra el potencial de combinar indicadores procedentes de dominios diversos. Teixeira et al. (2024) aplicaron aprendizaje automático para discriminar estados de recuperación en futbolistas adolescentes de distintas categorías, utilizando información derivada del seguimiento deportivo. Una arquitectura semejante puede transformar múltiples mediciones en categorías operativas para apoyar la planificación. Conviene, no obstante, preservar probabilidades e incertidumbre, pues convertir cualquier predicción en etiqueta rígida empobrece la complejidad biológica observada cotidianamente.

La fusión de datos puede realizarse en diferentes niveles arquitectónicos. Algunas estrategias combinan variables antes del entrenamiento del modelo; otras procesan cada fuente mediante componentes especializados y reúnen posteriormente sus representaciones. La elección depende de volumen, calidad, sincronía y naturaleza de los registros. Cuando existen pérdidas frecuentes o sensores con disponibilidad irregular, una arquitectura modular ofrece mayor flexibilidad. El propósito permanece invariable: conservar información complementaria sin permitir que una fuente dominante eclipse señales menos abundantes pero relevantes.

La personalización también exige reconocer que las relaciones entre variables cambian entre atletas y etapas de preparación. Teixeira et al. (2024) analizaron categorías juveniles diferenciadas, mientras Mandorino et al. (2023) resaltaron el valor de procedimientos individualizados para estimar disponibilidad. Tales hallazgos respaldan arquitecturas capaces de actualizar asociaciones conforme crece el historial personal. Un patrón fisiológico o biomecánico útil durante cierto bloque puede perder

capacidad informativa meses después, cuando adaptación, maduración o exposición modifican la respuesta individual.

Integrar información heterogénea adquiere verdadero valor cuando la arquitectura preserva trazabilidad desde la medición hasta la decisión. Sensores, registros subjetivos y variables ambientales alimentan capas de procesamiento; posteriormente, modelos de fusión producen representaciones destinadas a estimar estados relevantes para planificar. La tecnología vestible estudiada por Cui et al. (2023) ilustra la expansión de fuentes disponibles. El paso decisivo consiste en convertir diversidad informativa en conocimiento interpretable, manteniendo calidad, temporalidad e individualización como principios rectores del sistema.

1.4. Sistemas predictivos para la distribución temporal de estímulos de entrenamiento

Los sistemas predictivos amplían la planificación deportiva al estimar respuestas futuras antes de distribuir los estímulos dentro del calendario. Su función consiste en anticipar ventanas de mayor receptividad, posibles descensos del rendimiento y periodos donde conviene moderar la exigencia. A diferencia de la adaptación reactiva, tratada previamente, la predicción introduce una mirada prospectiva. El valor operativo aparece cuando probabilidades calculadas orientan decisiones temporales sin convertir la incertidumbre biológica en una promesa determinista sobre el rendimiento.

La distribución temporal requiere modelos capaces de aprender dependencias entre cargas pasadas, respuestas recientes y rendimiento esperado. Cada sesión aporta información cuya influencia puede prolongarse durante días o semanas, de manera que una lectura instantánea resulta insuficiente. Connor et al. (2022) plantearon la generación adaptativa de planes mediante sistemas de control inteligente, donde la respuesta observada

alimenta decisiones posteriores. Desde una perspectiva predictiva, dicha lógica permite proyectar trayectorias y ubicar estímulos según desviaciones previsibles individuales.


Predecir no equivale a adivinar una marca futura, sino a estimar probabilidades útiles para ordenar decisiones. Un modelo puede calcular riesgo de atenuación del rendimiento, respuesta probable ante determinada carga o necesidad esperada de recuperación. Cordeiro et al. (2025) abordaron la predicción de disminuciones del desempeño mediante aprendizaje automático apoyado en datos sintéticos. Tal enfoque resulta relevante cuando los registros reales son escasos, desequilibrados o insuficientes para representar episodios poco frecuentes con interés deportivo aplicado.

La dimensión temporal obliga a decidir cuánto pasado debe conservar el algoritmo para interpretar una respuesta futura. Ventanas demasiado breves pueden ignorar acumulaciones relevantes; periodos excesivamente largos diluyen cambios recientes. Por ello, la selección del horizonte predictivo debe corresponder con la naturaleza del estímulo y la adaptación perseguida. En fuerza, resistencia o velocidad, las huellas temporales difieren. Una arquitectura competente reconoce dichas diferencias y evita aplicar una memoria uniforme a fenómenos fisiológicos con ritmos particulares.

La predicción de lesiones también aporta información para distribuir cargas, siempre que no se confunda probabilidad con diagnóstico. Majumdar et al. (2024) analizaron durante varias temporadas la relación entre carga de entrenamiento y lesión en fútbol profesional mediante aprendizaje automático. Una lectura útil para la planificación consiste en tratar el riesgo estimado como señal complementaria. Ante probabilidades crecientes, el cuerpo técnico puede reconsiderar densidad, secuencia o magnitud de estímulos sin atribuir causalidad automática al modelo.

Los modelos temporales adquieren mayor utilidad cuando distinguen entre efectos inmediatos y consecuencias diferidas. Una sesión exigente puede reducir transitoriamente el rendimiento y, tras recuperación suficiente, contribuir a una adaptación favorable. El sistema necesita aprender dicha relación para no penalizar toda caída momentánea. Cordeiro et al. (2025) orientaron su trabajo hacia la anticipación de atenuaciones del rendimiento, mostrando el interés de detectar patrones previos. Planificar exige interpretar esas alertas dentro de una secuencia deportiva mayor.

Figura 3
Predicción temporal de estímulos de entrenamiento



La incertidumbre predictiva merece ocupar un lugar visible dentro de la arquitectura. Una probabilidad acompañada por intervalos, niveles de confianza o márgenes de error ofrece mayor utilidad que una recomendación presentada como certeza. La distribución temporal puede entonces graduar decisiones según la robustez de cada pronóstico. Cuando la confianza es baja, conviene preservar alternativas y observar nuevas señales; cuando aumenta, resulta razonable modificar la secuencia prevista. Tal prudencia protege al entrenamiento frente a automatismos innecesarios.

Otro aspecto relevante reside en la actualización continua del pronóstico. Las predicciones pierden vigencia cuando nuevas sesiones, viajes, competencias o respuestas individuales alteran la trayectoria prevista. Connor et al. (2022) mostraron que los sistemas de control pueden reajustar planes mediante retroalimentación, principio transferible a arquitecturas predictivas. Cada nueva observación modifica la estimación anterior y redefine el horizonte inmediato. De ese modo, el calendario deja de ser una secuencia cerrada y adquiere capacidad de revisión fundamentada.

La calidad predictiva debe evaluarse por su utilidad para decidir, no únicamente mediante métricas estadísticas. Un modelo con elevada precisión promedio puede fallar precisamente ante episodios que más interesan al entrenador. Majumdar et al. (2024) examinaron relaciones entre carga y lesión mediante datos de múltiples temporadas, perspectiva que resalta la importancia de validar patrones a través del tiempo. Sensibilidad, calibración y estabilidad temporal deben acompañar cualquier valoración destinada a respaldar la distribución de estímulos deportivos.

Dentro de la arquitectura general del capítulo, los sistemas predictivos ocupan el espacio entre integración de datos y prescripción futura. Reciben señales procesadas, estiman trayectorias probables y entregan información temporal a los módulos encargados de organizar cargas. Su aportación reside en anticipar, no en dictar. Cuando predicción, incertidumbre y criterio profesional permanecen vinculados, la planificación gana capacidad para ubicar estímulos con oportunidad, preservar márgenes de ajuste y responder con prudencia ante variaciones esperadas del rendimiento.

1.5. Optimización multiobjetivo de sesiones y microciclos mediante inteligencia artificial

La optimización multiobjetivo aborda una realidad cotidiana del entrenamiento: una sesión rara vez persigue una adaptación aislada. Fuerza, potencia, resistencia, habilidad técnica, recuperación y preparación competitiva conviven bajo restricciones de tiempo y tolerancia individual. La inteligencia artificial permite representar tales propósitos mediante funciones simultáneas, algunas complementarias y otras contrapuestas. El problema deja de consistir en maximizar un indicador particular para orientarse hacia configuraciones equilibradas, donde cada decisión preserve beneficios relevantes sin deteriorar otras prioridades deportivas.

En una sesión, optimizar implica decidir contenidos, orden, volumen, intensidad, pausas y duración considerando efectos concurrentes. Ciertas combinaciones favorecen adaptaciones compatibles; otras generan interferencias que requieren separación temporal. La arquitectura algorítmica puede evaluar numerosas configuraciones y descartar aquellas que incumplen restricciones previamente definidas. Connor et al. (2022) plantean la generación adaptativa de planes como un problema de control, perspectiva que permite entender la prescripción como búsqueda regulada entre metas de rendimiento y respuestas individuales observables.

Cuando el análisis se amplía al microciclo, las decisiones adquieren dependencia secuencial. Una carga elevada modifica las posibilidades de la jornada posterior, mientras una sesión regenerativa puede preparar al atleta para trabajos de mayor exigencia. La optimización debe valorar, por tanto, la arquitectura semanal completa y no cada unidad por separado. Aparece una lógica de compensaciones: ganar estímulo en determinado momento puede reducir capacidad disponible después. El

algoritmo compara alternativas y conserva aquellas con balance deportivo favorable.

La noción de frontera de Pareto resulta útil para representar soluciones donde mejorar un objetivo obliga a sacrificar parcialmente otro. En lugar de producir una prescripción pretendidamente perfecta, el sistema presenta combinaciones eficientes entre carga, recuperación, rendimiento esperado y exposición específica. Tal enfoque reconoce que la decisión deportiva contiene preferencias difíciles de reducir a una cifra. El entrenador puede seleccionar una alternativa según prioridades competitivas, conservando una visión explícita de los intercambios asociados con cada configuración posible.

El aprendizaje por refuerzo ofrece otra vía para resolver decisiones multiobjetivo mediante recompensas compuestas. Xia et al. (2025) desarrollan un algoritmo orientado al control personalizado de cargas para optimizar el rendimiento competitivo, apoyándose en aprendizaje profundo por refuerzo. Trasladado al diseño de microciclos, dicho principio permite valorar consecuencias acumuladas de distintas secuencias. La recompensa puede ponderar rendimiento, recuperación y cumplimiento de cargas, evitando que una ganancia inmediata monopolice el criterio utilizado por el agente inteligente.

Asignar pesos a cada objetivo exige cautela, porque las prioridades deportivas varían durante la temporada y entre atletas. Una ponderación fija puede resultar adecuada durante una fase, pero perder pertinencia ante proximidad competitiva, cambios de disponibilidad o necesidades técnicas. Por ello, los coeficientes deben admitir revisión fundamentada. La inteligencia artificial aporta capacidad de cálculo, aunque la jerarquía entre metas conserva una dimensión profesional. Elegir qué optimizar expresa también una determinada concepción del rendimiento y su preparación.

La evidencia agregada respalda el interés de sistemas inteligentes capaces de intervenir sobre dimensiones diversas del rendimiento. Ganaie et al. (2026), mediante revisión sistemática y metaanálisis, encontraron efectos favorables asociados al entrenamiento asistido por inteligencia artificial, aunque con variación entre dominios evaluados. Tal heterogeneidad resulta pertinente para la optimización multiobjetivo: distintos componentes responden con magnitudes diferentes. Una arquitectura bien diseñada debe reconocer tales asimetrías y evitar distribuir recursos como si todas las adaptaciones progresaran mediante relaciones equivalentes.

Las restricciones prácticas convierten la optimización matemática en una tarea genuinamente deportiva. Disponibilidad de instalaciones, duración de sesiones, número de entrenadores, viajes, partidos y compatibilidad entre tareas delimitan el espacio de soluciones. Un algoritmo útil trabaja dentro de tales fronteras en vez de producir combinaciones ideales pero inviables. Connor et al. (2022) resaltan la utilidad de sistemas adaptativos para ajustar planes frente a respuestas cambiantes. La factibilidad, por tanto, forma parte del propio criterio de calidad.

También conviene incorporar mecanismos que expliquen por qué una alternativa domina a otra. Mostrar que determinada distribución mejora la recuperación prevista a costa de reducir ligeramente el volumen facilita una decisión informada. La optimización multiobjetivo gana legitimidad cuando expone compensaciones, restricciones activas y prioridades utilizadas. De ese modo, el entrenador puede modificar ponderaciones o rechazar una solución por razones deportivas no formalizadas. La inteligencia artificial funciona como espacio de comparación rigurosa, no como autoridad prescriptiva incuestionable.

En la arquitectura general de planificación, la optimización multiobjetivo convierte predicciones y estados estimados en configuraciones operativas de sesiones y microciclos. Su aporte

consiste en negociar simultáneamente metas, restricciones y efectos acumulativos mediante alternativas comparables. Xia et al. (2025) muestran el potencial del aprendizaje por refuerzo para personalizar decisiones de carga. La madurez del sistema dependerá de equilibrar eficiencia computacional, factibilidad deportiva e intervención profesional, preservando siempre la pluralidad de objetivos inherente al rendimiento competitivo.

1.6. Simulación de escenarios de entrenamiento para la toma anticipada de decisiones

La simulación de escenarios introduce una capacidad distinta dentro de la planificación inteligente: ensayar decisiones antes de trasladarlas al entrenamiento real. Mediante representaciones computacionales, pueden compararse secuencias de cargas, pausas, competiciones y respuestas probables bajo condiciones alternativas. El propósito no consiste en predecir un futuro único, sino en observar consecuencias plausibles derivadas de elecciones diferentes. Tal enfoque convierte la planificación en un laboratorio virtual donde anticipar efectos, contrastar opciones y reducir decisiones difícilmente reversibles.

Construir un escenario requiere definir un estado inicial, reglas de transición y resultados esperados. A partir de dicha estructura, el sistema modifica variables y proyecta trayectorias posibles durante sesiones, microciclos o periodos mayores. Connor et al. (2022) utilizaron simulaciones para comparar estrategias de generación adaptativa de planes y evaluar su capacidad para aproximarse a objetivos programados. Tal procedimiento evidencia que simular permite valorar políticas de intervención antes de emplearlas con deportistas en condiciones reales.

Los gemelos digitales amplían dicha lógica mediante representaciones virtuales vinculadas con información procedente del deportista real. Lukač et al. (2022) describen su aplicación deportiva como una arquitectura donde componentes físicos y

digitales intercambian datos para reproducir comportamientos y apoyar decisiones. La réplica computacional puede recibir nuevas observaciones, actualizar parámetros y ejecutar escenarios alternativos. Su interés reside en crear un espacio experimental individualizado, capaz de comparar intervenciones sin exigir exposición física previa a cada alternativa planteada.

La fidelidad del escenario depende del grado en que las relaciones representadas correspondan con fenómenos deportivos relevantes. Un modelo excesivamente simple puede omitir interacciones importantes; otro demasiado complejo puede resultar difícil de calibrar y comprender. La calidad no proviene de reproducir cada detalle, sino de conservar mecanismos necesarios para la pregunta planteada. Simular una semana competitiva requiere variables distintas de aquellas empleadas para estudiar acumulación prolongada de fatiga o adaptación frente a cargas progresivas.

Una ventaja particular aparece al construir escenarios contrafactuales. El sistema puede estimar qué habría ocurrido bajo una distribución diferente de estímulos, mayor recuperación o modificación de determinada sesión. Aunque tales resultados permanecen hipotéticos, permiten examinar decisiones desde perspectivas inaccesibles mediante observación directa. Hliš et al. (2024) analizan el potencial práctico de los gemelos digitales deportivos para apoyar simulación y evaluación. La comparación contrafactual amplía, por tanto, la deliberación sin convertir resultados virtuales en certezas empíricas.

La simulación también permite someter un plan a condiciones adversas antes de ejecutarlo. Cambios de calendario, reducción del tiempo disponible, respuestas inferiores a las previstas o interrupciones pueden incorporarse como perturbaciones deliberadas. Al observar el comportamiento del sistema frente a ellas, el entrenador identifica planes resistentes y alternativas frágiles. La pregunta cambia ligeramente: ya no

interesa únicamente qué opción ofrece mayor rendimiento esperado, sino cuál conserva funcionalidad cuando aparecen variaciones razonablemente probables durante el proceso deportivo real.

Los escenarios adquieren mayor riqueza cuando se actualizan mediante observaciones sucesivas. Un gemelo digital no debería permanecer congelado mientras el deportista cambia. Lukač et al. (2022) vinculan su desarrollo con la comunicación entre entidad física y representación virtual, condición que favorece ajustes progresivos del modelo. Cada medición puede modificar parámetros y alterar simulaciones posteriores. De tal manera, las alternativas ensayadas reflejan una versión renovada del atleta y no una fotografía computacional envejecida por el tiempo.

La comparación entre escenarios exige criterios transparentes. Rendimiento esperado, carga acumulada, estabilidad, recuperación o proximidad a determinados objetivos pueden funcionar como variables de evaluación, siempre que su elección responda a prioridades deportivas explícitas. Hliš et al. (2024) organizan los gemelos digitales mediante conceptos y taxonomías que ayudan a comprender sus posibilidades prácticas. Una simulación gana utilidad cuando permite reconocer por qué una alternativa resulta preferible y qué compromisos acompañan la decisión considerada por el equipo técnico.

Conviene recordar que el escenario virtual no reemplaza la incertidumbre propia del entrenamiento. Los modelos dependen de datos, relaciones estimadas y premisas que pueden fallar ante respuestas poco frecuentes. Por ello, resulta útil trabajar con múltiples trayectorias y análisis de sensibilidad, observando cuánto cambia una conclusión cuando varían parámetros relevantes. La simulación adquiere mayor credibilidad cuando muestra sus márgenes de fragilidad. Un resultado estable ante perturbaciones merece confianza distinta de otro dependiente de condiciones demasiado precisas.

Dentro de la arquitectura de planificación, la simulación funciona como capa de experimentación previa entre conocimiento disponible y acción deportiva. Recibe estados estimados, genera futuros alternativos y devuelve consecuencias comparables para apoyar decisiones anticipadas. Connor et al. (2022) demostraron mediante simulación la posibilidad de contrastar estrategias adaptativas antes de su aplicación. Integrada con gemelos digitales, dicha capacidad permite ensayar, revisar y descartar opciones, conservando al entrenador como intérprete responsable de la elección operativa posterior.

Tabla 1
Componentes funcionales de la arquitectura de inteligencia artificial para la planificación del entrenamiento deportivo

Componente de la arquitectura	Función dentro de la planificación deportiva
Modelado algorítmico según objetivos de rendimiento	Traduce metas deportivas en variables, restricciones y criterios computables, vinculando cargas y respuestas individuales con trayectorias de rendimiento previstas. Facilita una planificación orientada por objetivos verificables y susceptible de reajuste mediante nueva información.
Periodización dinámica asistida por aprendizaje automático	Organiza la distribución temporal de estímulos mediante modelos que aprenden de respuestas sucesivas. Permite modificar volumen, intensidad, recuperación y secuencias de trabajo cuando la evolución observada difiere de la trayectoria programada, preservando la dirección estratégica del proceso.
Integración inteligente de datos multidimensionales	Articula información fisiológica, biomecánica, perceptiva y ambiental mediante procedimientos de fusión de datos. Convierte registros heterogéneos en representaciones funcionales del estado del deportista, favoreciendo interpretaciones individualizadas y trazables para respaldar decisiones de planificación.
Sistemas predictivos de distribución temporal	Estiman respuestas futuras, variaciones del rendimiento y ventanas temporales de intervención mediante patrones longitudinales. Incorporan probabilidades e incertidumbre para orientar la ubicación de estímulos sin transformar las

Componente de la arquitectura	Función dentro de la planificación deportiva
Optimización multiobjetivo de sesiones y microciclos	predicciones algorítmicas en determinaciones rígidas sobre la respuesta del atleta. Compara configuraciones alternativas considerando simultáneamente rendimiento, recuperación, carga, disponibilidad y restricciones operativas. Permite identificar soluciones eficientes y hacer visibles las compensaciones entre objetivos concurrentes, manteniendo la intervención profesional en la selección de la alternativa deportiva pertinente.
Simulación de escenarios de entrenamiento	Genera representaciones virtuales donde pueden ensayarse cargas, secuencias, perturbaciones y decisiones antes de aplicarlas. Los escenarios contrafactuales y gemelos digitales permiten comparar consecuencias plausibles, valorar la robustez de diferentes planes y anticipar cursos de acción frente a condiciones variables.
Retroalimentación y actualización del sistema	Conecta mediciones sucesivas con los módulos predictivos, adaptativos y de optimización. Cada nueva respuesta del deportista puede modificar parámetros, estimaciones y alternativas de planificación, favoreciendo una arquitectura evolutiva que aprende durante el proceso sin desvincularse de los objetivos deportivos establecidos.
Intervención profesional y trazabilidad	Sitúa el criterio del entrenador como instancia interpretativa de las recomendaciones generadas. La arquitectura aporta estimaciones, comparaciones y escenarios, mientras el profesional valora pertinencia, factibilidad y significado deportivo. La trazabilidad permite reconocer qué datos, reglas y prioridades sustentan cada recomendación.

Nota. La arquitectura integra modelado algorítmico, periodización dinámica, fusión de datos, predicción, optimización multiobjetivo y simulación dentro de un sistema de apoyo a la planificación. La relación entre sus componentes favorece decisiones adaptables, individualizadas y prospectivas, manteniendo el criterio profesional como elemento articulador entre procesamiento computacional y práctica deportiva.

Capítulo II

Analítica inteligente del rendimiento deportivo y extracción de patrones

El rendimiento deportivo nunca ha sido una realidad sencilla de leer. Cada sesión deja señales dispersas entre cargas, movimientos, respuestas fisiológicas, percepciones y resultados competitivos que adquieren valor cuando pueden relacionarse en el tiempo. La inteligencia artificial ha ampliado la capacidad para ordenar dicha complejidad mediante procedimientos capaces de reconocer regularidades relevantes. Munoz-Macho et al. (2024) describen una expansión de aplicaciones inteligentes destinadas al análisis del rendimiento y la salud en equipos deportivos de élite.

Durante años, buena parte del análisis se apoyó en estadísticas descriptivas y comparaciones construidas a partir de indicadores aislados. La disponibilidad creciente de registros digitales modificó progresivamente aquella lógica. Ya no basta con conocer cuánto corrió un deportista o qué carga acumuló durante una semana; interesa comprender relaciones entre variables y distinguir comportamientos recurrentes. Mandorino et al. (2023) muestran que técnicas de aprendizaje automático pueden contribuir a cuantificar la preparación individual mediante respuestas observadas frente a valores esperados.

La imagen deportiva también ha dejado de ser únicamente material destinado a la observación técnica. Convertida en fuente cuantificable, permite estudiar posiciones corporales, trayectorias y relaciones articulares con una precisión creciente. Badiola-Bengoia y Mendez-Zorrilla (2021) documentan numerosas aplicaciones de estimación de pose humana basada en cámaras dentro del deporte y el ejercicio físico. Tal evolución amplía la mirada analítica, pues conecta aquello que el entrenador observa con mediciones susceptibles de comparación sistemática durante diferentes momentos de preparación.

Sin embargo, ninguna fuente describe por completo la complejidad del deportista. Sensores corporales, video, pruebas físicas y registros cotidianos ofrecen fragmentos diferentes de una misma realidad dinámica. Li y Zhang (2022) evidencian el valor de

los dispositivos portátiles para obtener información cuantitativa vinculada con procesos de entrenamiento y enseñanza deportiva. Cuando diversas señales dialogan bajo criterios temporales compatibles, la analítica puede avanzar desde colecciones fragmentadas de mediciones hacia interpretaciones capaces de relacionar respuesta, ejecución y carga aplicada.

Figura 4

Arquitectura de la analítica inteligente del rendimiento deportivo



La acumulación de información adquiere verdadera utilidad cuando permite reconocer modificaciones dignas de atención. El rendimiento fluctúa de manera natural, y no toda diferencia merece una intervención. Cordeiro et al. (2025) abordaron la predicción de atenuaciones del rendimiento mediante aprendizaje automático apoyado en datos sintéticos, mostrando posibilidades para anticipar variaciones relevantes. La cuestión analítica cambia entonces de escala: interesa separar ruido, adaptación y alteraciones persistentes, manteniendo prudencia ante resultados probabilísticos que nunca equivalen a certezas deportivas.

Mirar varias temporadas añade otra capa de profundidad. Los patrones pueden cambiar con la edad deportiva, la exposición competitiva, las cargas acumuladas y las adaptaciones desarrolladas durante años. Majumdar et al. (2024) estudiaron mediante aprendizaje automático la relación entre carga de entrenamiento y lesión en fútbol profesional desde una perspectiva multitemporada. Tal orientación recuerda que una medición reciente pertenece a una historia previa, y que interpretar rendimiento requiere preservar memoria suficiente para reconocer continuidad, ruptura y transformación individual.

A medida que los modelos ganan capacidad predictiva, aparece una pregunta inevitable: ¿qué razones sostienen sus resultados? Una cifra producida por un algoritmo puede parecer convincente y, aun con elevada precisión, resultar poco útil cuando nadie comprende qué variables determinaron su salida. Pashaie et al. (2026) examinan la evolución de estrategias de entrenamiento apoyadas por inteligencia artificial y destacan posibilidades asociadas con personalización y apoyo decisional. La transparencia se vuelve, por tanto, parte de la utilidad profesional.

Esa búsqueda de comprensión devuelve protagonismo al criterio humano. Los algoritmos pueden ordenar relaciones, detectar desviaciones y producir estimaciones, pero su interpretación pertenece a un proceso donde conocimiento científico, experiencia y observación permanecen vinculados. Ganaie et al. (2026), al revisar intervenciones de entrenamiento asistidas por inteligencia artificial, examinan su relación con el rendimiento deportivo. La tecnología adquiere mayor sentido cuando amplía la capacidad de juicio del profesional sin transformar una probabilidad matemática en una instrucción automática.

La continuidad temporal conduce hacia una representación digital cada vez más personalizada del deportista. De Leeuw et al. (2022) mostraron el interés de enfoques

individualizados de aprendizaje automático para monitorizar lesiones en voleibolistas de élite. Desde dicha perspectiva, cada nueva medición puede incorporarse a una memoria analítica que conserva antecedentes y reconoce cambios personales. El atleta deja de compararse permanentemente con promedios generales y comienza a ser interpretado también frente a su propia trayectoria cuantificada y evolución deportiva.

Lukač et al. (2022) plantean que el gemelo digital aplicado al deporte puede articular datos y modelos dentro de representaciones dinámicas del atleta. Hacia esa dirección converge la analítica inteligente desarrollada en el capítulo: reconocer patrones, cuantificar movimiento, relacionar fuentes, detectar variaciones, explicar resultados y preservar trayectorias individuales. Más que acumular tecnología, interesa construir conocimiento deportivo verificable y comprensible. El propósito permanece cercano al entrenamiento cotidiano: observar mejor, interpretar con prudencia y decidir con mayor fundamento.

2.1. Aprendizaje automático aplicado a la identificación de patrones de rendimiento

El aprendizaje automático aporta una vía analítica para reconocer regularidades de rendimiento que permanecen ocultas en registros deportivos extensos. Su valor reside en relacionar variables de carga, respuesta fisiológica, producción mecánica y desempeño competitivo mediante modelos capaces de aprender asociaciones a partir de datos históricos. Más que reemplazar el juicio profesional, permite ordenar señales dispersas y convertirlas en patrones interpretables, favoreciendo una lectura longitudinal del deportista y de sus variaciones durante ciclos sucesivos de preparación.

La identificación de patrones requiere datos comparables, trazables y suficientemente representativos de la actividad observada. Mediciones procedentes de GPS, acelerometría, pruebas

físicas, cuestionarios y registros competitivos adquieren mayor valor cuando conservan continuidad temporal y criterios homogéneos. Munoz-Macho et al. (2024) documentan presencia creciente de técnicas basadas en árboles, métodos de potenciación y redes neuronales dentro del deporte de élite. Tal diversidad metodológica permite abordar relaciones no lineales y combinaciones difíciles de advertir mediante análisis convencionales.

Entre los procedimientos supervisados, la regresión y la clasificación permiten vincular observaciones previas con resultados conocidos, generando estimaciones útiles para reconocer perfiles de rendimiento. Un modelo puede aprender, por ejemplo, qué combinación de volumen, intensidad y respuesta neuromuscular antecede a una disminución funcional. La utilidad práctica no depende únicamente de alcanzar precisión. Importa que las variables empleadas tengan significado deportivo y que la salida del algoritmo se traduzca en decisiones comprensibles para entrenadores y especialistas.

Mandorino et al. (2023) emplearon regresión Random Forest para predecir PlayerLoad en futbolistas de élite y construyeron un índice individual de eficiencia locomotora a partir de la diferencia entre valores predichos y observados. La propuesta muestra una idea central: el patrón útil no siempre procede de una cifra absoluta, sino de la desviación respecto de la respuesta esperada individual. Esa personalización permite distinguir fluctuaciones habituales de cambios que merecen atención dentro del proceso de entrenamiento.

Los métodos no supervisados amplían la identificación cuando no existen etiquetas previas que indiquen estados de rendimiento. Técnicas de agrupamiento pueden reunir sesiones, jugadores o periodos con rasgos semejantes y revelar estructuras. Un grupo puede concentrar respuestas asociadas con elevada eficiencia, mientras otro reúne perfiles compatibles con

acumulación de carga. El interés radica en descubrir configuraciones recurrentes sin categorías rígidas desde el inicio, preservando matices propios de cada disciplina deportiva y de sus demandas competitivas particulares.

La dimensión temporal añade profundidad al reconocimiento de patrones, porque una misma medición adquiere significado distinto según su posición dentro de la secuencia de entrenamiento. Cambios graduales, oscilaciones semanales o rupturas repentinas pueden aportar más información que un valor aislado. Mandorino et al. (2023) observaron variaciones del índice de eficiencia locomotora vinculadas con momentos de la temporada, días próximos al partido y carga semanal. Tales hallazgos respaldan modelos sensibles a trayectorias individuales y ritmos competitivos.

Una dificultad frecuente aparece cuando el volumen de datos disponibles resulta reducido frente a la complejidad del fenómeno. Cordeiro et al. (2025) evaluaron datos sintéticos generados mediante autoencoders variacionales tabulares para predecir atenuación del rendimiento en jugadores de fútbol gaélico. Su trabajo evidencia que la generación artificial puede ampliar escenarios de entrenamiento algorítmico cuando las muestras reales son limitadas, aunque exige comprobar la fidelidad distributiva y la capacidad de generalización sobre observaciones auténticas e independientes.

Reconocer un patrón estadístico no equivale a demostrar relación causal. Una asociación entre carga acumulada y descenso del rendimiento puede estar mediada por sueño, calendario competitivo, viajes, recuperación o características individuales que el modelo no registra. La interpretación necesita integrar conocimiento deportivo, evaluación metodológica y variables de confusión. Munoz-Macho et al. (2024) muestran que las aplicaciones de inteligencia artificial abarcan rendimiento y salud,

reforzando la necesidad de integrar fuentes diversas sin confundir predicción con explicación.

La evaluación de modelos debe considerar estabilidad, sensibilidad ante datos y utilidad fuera de la muestra empleada para entrenarlos. Validaciones temporales, particiones por deportista y pruebas con temporadas diferentes ayudan a detectar modelos que memorizan particularidades sin captar regularidades transferibles. Conviene revisar la importancia de variables y los errores por subgrupos, pues una precisión promedio aceptable puede ocultar fallos relevantes. En la práctica, un patrón adquiere valor cuando permanece consistente y puede ser interpretado responsablemente.

Desde una perspectiva operativa, el aprendizaje automático convierte series de datos deportivos en representaciones capaces de apoyar la vigilancia del rendimiento sin reducir al atleta a una puntuación. Los patrones deben funcionar como señales para orientar preguntas, contrastar percepciones del cuerpo técnico y ajustar hipótesis de trabajo. La aportación más fértil aparece cuando algoritmo y experiencia profesional dialogan continuamente. Bajo tal enfoque, la analítica inteligente fortalece decisiones individualizadas y prepara bases rigurosas para procesos predictivos.


2.2. Visión artificial para el análisis técnico y biomecánico del movimiento

La visión artificial ha ampliado las posibilidades del análisis técnico al transformar imágenes en información cuantificable sobre el movimiento deportivo. Mediante algoritmos capaces de localizar segmentos corporales, articulaciones y trayectorias, una grabación convencional puede convertirse en una representación cinemática susceptible de comparación. Tal capacidad acerca la evaluación biomecánica a escenarios cotidianos de entrenamiento, donde interesa observar gestos repetidos sin alterar su ejecución mediante

instrumentación invasiva ni depender de laboratorios altamente especializados para obtener mediciones relevantes.

Figura 5

Visión artificial aplicada al análisis del movimiento deportivo



Dentro de ese marco, la estimación de la pose humana ocupa un lugar central, pues permite reconstruir configuraciones corporales mediante puntos anatómicos detectados en imágenes bidimensionales o tridimensionales. Badiola-Bengoia y Mendez-Zorrilla (2021) describen una expansión de aplicaciones deportivas basadas en cámaras, vinculadas con reconocimiento de acciones, evaluación técnica y seguimiento corporal. La ventaja reside en convertir material visual accesible en datos estructurados, preservando relación directa entre la medición obtenida y el gesto deportivo ejecutado directamente.

El análisis biomecánico derivado de imágenes requiere pasar de la detección corporal a variables con significado funcional. Ángulos articulares, desplazamientos, velocidades y secuencias de coordinación permiten describir la mecánica de una acción. En un salto, lanzamiento o cambio de dirección, diferencias temporales

pueden modificar la eficacia. La lectura técnica gana profundidad cuando las trayectorias dejan de contemplarse como formas aisladas y pasan a interpretarse como relaciones dinámicas entre segmentos durante cada fase del movimiento deportivo.

La precisión de las mediciones depende de factores de captura, entre ellos la posición de la cámara, la iluminación, las oclusiones y la velocidad del gesto. Fukushima et al. (2024) validaron sistemas de pose humana para captura del movimiento deportivo y encontraron diferencias de rendimiento según condiciones analizadas. Por ello, utilizar visión artificial con criterio biomecánico exige conocer los márgenes de error y distinguir entre mediciones apropiadas para orientación práctica y análisis de mayor exigencia.

Las configuraciones monoculares ofrecen especial interés por su sencillez operativa: una cámara puede registrar sesiones completas sin desplegar infraestructura compleja. Sin embargo, la pérdida de profundidad introduce incertidumbre cuando segmentos corporales se superponen o abandonan el plano dominante. Los sistemas multicámara reducen tales limitaciones mediante reconstrucciones espaciales más detalladas. La elección tecnológica debe responder al gesto estudiado, al nivel de precisión requerido y a las condiciones reales donde ocurre la práctica deportiva cotidiana y habitual.

Otra aportación relevante aparece en la comparación técnica entre ejecuciones sucesivas. Las trayectorias articulares pueden alinearse temporalmente para detectar cambios en amplitud, ritmo o coordinación, evitando que la valoración dependa únicamente de impresiones visuales. Badiola-Bengoia y Mendez-Zorrilla (2021) señalan que la estimación de pose basada en cámaras facilita aplicaciones orientadas al análisis del ejercicio y del deporte. La comparación adquiere mayor utilidad cuando respeta diferencias antropométricas y variabilidad natural entre intentos de un mismo atleta.

La combinación de visión artificial con sensores corporales amplía la lectura del movimiento al reunir información externa e interna de la ejecución. Li y Zhang (2022), al estudiar entrenamiento de baloncesto mediante dispositivos portátiles, evidencian el valor de registros cuantitativos para evaluar efectos de enseñanza. Cuando datos inerciales, fisiológicos o posicionales acompañan las imágenes, el análisis puede relacionar la apariencia del gesto con respuestas corporales que una cámara no registra durante numerosas acciones deportivas complejas.

En deportes colectivos, la utilidad trasciende el examen articular aislado. El seguimiento simultáneo de varios jugadores permite estudiar distancias interpersonales, orientaciones corporales, sincronización y ocupación espacial durante acciones técnicas. Aun cuando el interés principal recaiga en biomecánica individual, la ejecución cambia frente a oposición, presión temporal o interacción con compañeros. La visión artificial ofrece una vía que conserva tales relaciones dentro del registro, acercando el análisis técnico a condiciones representativas de competición y entrenamiento habitual.

La interpretación profesional continúa siendo necesaria cuando un algoritmo detecta una desviación mecánica. Una diferencia angular puede reflejar fatiga, adaptación técnica, estrategia motriz o variación normal, y ninguna lectura adquiere significado pleno fuera de la tarea realizada. Fukushima et al. (2024) resaltan mediante su validación que el rendimiento de la estimación de pose varía entre movimientos y configuraciones. En consecuencia, conviene vincular cada indicador visual con criterios biomecánicos definidos y con preguntas específicas del entrenamiento.

Integrada en la analítica inteligente, la visión artificial convierte el movimiento observable en evidencia sistemática para orientar ajustes técnicos. Su mayor aportación aparece cuando las mediciones se incorporan a procesos longitudinales, para reconocer

modificaciones en la ejecución y valorar su permanencia. El propósito no consiste en perseguir una geometría corporal ideal, sino en comprender relaciones entre técnica y respuesta individual. Desde esa perspectiva, movimiento digitalizado adquiere sentido cuando mejora la conversación entre datos y entrenamiento.

2.3. Analítica multimodal para integrar datos de sensores, video y registros de entrenamiento

La analítica multimodal permite reunir señales que describen dimensiones diferentes del rendimiento deportivo dentro de una misma arquitectura interpretativa. Datos procedentes de sensores, secuencias de video y registros de entrenamiento dejan de funcionar como fuentes separadas para formar representaciones complementarias del deportista. La integración aporta profundidad porque relaciona carga externa, respuesta corporal, ejecución motriz y planificación realizada. El interés analítico reside en conectar mediciones heterogéneas sin borrar la especificidad informativa propia de cada fuente disponible.

Integrar modalidades exige resolver diferencias de escala, frecuencia y estructura antes de cualquier modelado. Un acelerómetro produce numerosas observaciones por segundo, mientras una sesión registrada por el cuerpo técnico puede resumirse mediante pocas variables. El video añade secuencias espaciales y temporales de mayor complejidad. La sincronización permite ubicar cada señal dentro de una referencia temporal compartida, condición necesaria para relacionar un cambio fisiológico con una acción motriz, una carga determinada o una fase del entrenamiento.

Los dispositivos portátiles aportan continuidad a la observación al registrar movimiento, frecuencia cardíaca y otras respuestas durante la práctica. Cui et al. (2023) vinculan el uso de dispositivos vestibles con análisis orientados a recuperación física y

prevención de lesiones en enseñanza deportiva. Su aportación resulta especialmente valiosa cuando tales mediciones se combinan con información visual y registros de carga, pues la señal corporal puede interpretarse junto con la tarea realizada y su exigencia observable cotidiana.

El video incorpora una capa descriptiva que los sensores corporales no capturan por completo. Trayectorias, posturas, interacciones y secuencias técnicas permiten asociar cambios cuantitativos con acciones reconocibles para entrenadores y deportistas. Una elevación de la carga mecánica adquiere mayor significado cuando puede vincularse con aceleraciones, saltos, contactos o desplazamientos específicos. La fusión entre imagen y telemetría favorece análisis donde el dato conserva una referencia motriz concreta, evitando interpretaciones desprendidas de la práctica deportiva habitual registrada.

Los registros de entrenamiento aportan otra dimensión: intención, contenido y organización de la carga planificada. Series, repeticiones, duración, percepción del esfuerzo y objetivos de sesión permiten contrastar aquello que fue prescrito con la respuesta observada. Li y Zhang (2022) muestran el valor de dispositivos portátiles para evaluar efectos del entrenamiento y la enseñanza en baloncesto. Vincular registros planificados con mediciones instrumentales facilita valorar correspondencias, discrepancias y adaptaciones individuales durante periodos sucesivos de trabajo planificado cotidiano.

La fusión multimodal puede realizarse en distintos niveles del procesamiento. Una estrategia combina variables previamente extraídas de cada fuente; otra integra representaciones aprendidas por modelos capaces de relacionar señales complejas. También es posible fusionar resultados producidos por modelos independientes. La elección depende de la calidad, sincronía y volumen de información disponible. Cuanto mayor sea la heterogeneidad, mayor cuidado requiere preservar relaciones

temporales y evitar que una modalidad domine artificialmente la interpretación del rendimiento observado global.

La recuperación ofrece un ejemplo especialmente fértil para integrar fuentes diversas. Teixeira et al. (2024) emplearon aprendizaje automático para clasificar estados de recuperación en futbolistas juveniles de categorías U15, U17 y U19 mediante variables asociadas con carga y bienestar. Desde una perspectiva multimodal, tal aproximación puede enriquecerse al incorporar señales fisiológicas, evidencia visual y antecedentes de entrenamiento. La convergencia entre fuentes permite caracterizar estados individuales mediante relaciones que difícilmente aparecen en una medición aislada convencional.

La ausencia de datos representa un problema habitual en sistemas multimodales. Sensores desconectados, grabaciones incompletas o registros manuales omitidos generan vacíos que pueden alterar asociaciones aprendidas. No conviene tratar toda pérdida informativa del mismo modo: falta una señal por fallo técnico, por decisión metodológica o por condiciones propias de la sesión. Procedimientos de imputación, indicadores de calidad y modelos tolerantes a modalidades ausentes ayudan a conservar utilidad analítica sin presentar estimaciones inciertas como observaciones directas.

La interpretación gana valor cuando los resultados integrados pueden regresar al cuerpo técnico mediante representaciones comprensibles. Paneles temporales, perfiles individuales y alertas fundamentadas permiten revisar simultáneamente carga, respuesta y ejecución. Teixeira et al. (2024) evidencian que técnicas de aprendizaje automático pueden discriminar estados de recuperación en poblaciones juveniles por edad competitiva. Trasladar tales resultados a la práctica requiere mostrar relaciones, márgenes de incertidumbre y cambios longitudinales sin convertir el análisis en una acumulación de indicadores.

La analítica multimodal amplía la comprensión del rendimiento al articular evidencias que antes permanecían distribuidas entre dispositivos, imágenes y anotaciones profesionales. Su valor no procede de acumular datos, sino de establecer relaciones pertinentes entre fuentes y momentos de la preparación. Una arquitectura bien diseñada permite pasar de mediciones fragmentadas a perfiles dinámicos, conservando trazabilidad y significado deportivo. De tal manera, la extracción de patrones gana profundidad y prepara modelos capaces de apoyar decisiones individualizadas con mayor riqueza informativa.

2.4. Detección algorítmica de cambios significativos en indicadores de rendimiento

La detección algorítmica de cambios significativos permite distinguir variaciones habituales de modificaciones que pueden alterar la lectura del rendimiento deportivo. Frente a indicadores sometidos a fluctuaciones diarias, los modelos computacionales comparan tendencias, dispersión y comportamiento individual para reconocer desviaciones relevantes. El interés no radica en reaccionar ante cada diferencia numérica, sino en determinar cuándo una señal abandona su rango esperado. Esa distinción favorece decisiones más prudentes y reduce interpretaciones precipitadas durante la preparación competitiva actual.

Un cambio adquiere significado cuando se interpreta respecto de una referencia individual y temporal. Promedios grupales pueden ocultar respuestas particulares, especialmente en plantillas con perfiles físicos y cargas competitivas diferentes. Mandorino et al. (2023) desarrollaron una aproximación basada en aprendizaje automático para cuantificar la preparación de futbolistas mediante diferencias entre respuestas previstas y observadas. Tal lógica permite valorar desviaciones personales frente a comportamientos esperados, ofreciendo una lectura más sensible que los umbrales generales aplicados indistintamente.

Los algoritmos de detección pueden trabajar con ventanas móviles, límites adaptativos y métodos orientados a localizar puntos de cambio. Cada procedimiento responde a una pregunta distinta. Una ventana móvil permite observar desplazamientos progresivos; un límite adaptativo identifica valores alejados de la dinámica reciente; un punto de cambio marca transiciones entre regímenes estadísticos. La elección metodológica debe considerar frecuencia de medición, variabilidad natural y duración del fenómeno, evitando convertir fluctuaciones breves en señales de alarma injustificadas.

La temporalidad resulta determinante porque el rendimiento rara vez cambia mediante saltos perfectamente definidos. En ocasiones aparece una deriva gradual, perceptible tras varias sesiones; en otras, una modificación abrupta concentra la atención inmediata. Mandorino et al. (2023) observaron variaciones individuales en indicadores de eficiencia locomotora relacionadas con momentos de la temporada y distribución semanal de cargas. Tales resultados respaldan el seguimiento continuo de trayectorias personales, donde dirección, magnitud y persistencia adquieren relevancia analítica conjunta actual.


Distinguir señal y ruido exige considerar la fiabilidad de cada indicador. Una modificación puede proceder del deportista, pero también de errores instrumentales, cambios de dispositivo, condiciones de medición o registros incompletos. Antes de atribuir significado deportivo a una anomalía, conviene verificar la calidad del dato y su consistencia histórica. Los algoritmos pueden incorporar filtros y criterios de estabilidad, aunque la depuración metodológica continúa siendo necesaria para impedir que artefactos técnicos generen decisiones innecesarias en campo.

La predicción de atenuaciones amplía el análisis desde la identificación retrospectiva hacia la anticipación de posibles descensos. Cordeiro et al. (2025) estudiaron un enfoque de aprendizaje automático apoyado en datos sintéticos para predecir

reducción del rendimiento deportivo. La propuesta muestra el interés de entrenar modelos capaces de reconocer combinaciones previas asociadas con deterioro posterior. Sin embargo, una probabilidad elevada debe entenderse como señal para revisar información complementaria, no como certeza sobre la respuesta futura individual.

Figura 6

Detección algorítmica de variaciones del rendimiento



Cuando se analizan cargas e incidencias físicas durante varias temporadas, las relaciones pueden cambiar con el tiempo. Majumdar et al. (2024) abordaron mediante aprendizaje automático la relación entre carga de entrenamiento y lesión en fútbol desde una perspectiva multitemporada. Trabajar con periodos permite examinar estabilidad y variaciones de los patrones, además de reducir dependencia de episodios puntuales. La vigilancia algorítmica gana valor cuando reconoce que las referencias del deportista pueden modificarse conforme avanza la preparación.

La magnitud estadística de un cambio no garantiza relevancia deportiva. Una variación pequeña puede resultar importante en indicadores muy estables, mientras una diferencia amplia quizá pertenezca a la variabilidad habitual de una medida.

Por ello, los sistemas de detección deberían combinar criterios matemáticos con umbrales derivados de conocimiento fisiológico, técnico y competitivo. La interpretación mejora cuando el algoritmo comunica tamaño del cambio, duración, incertidumbre y antecedentes, en lugar de producir alertas binarias carentes de matices.

Las alertas requieren una arquitectura que priorice información y limite la fatiga decisional del cuerpo técnico. Si cada desviación genera una advertencia, el sistema pierde credibilidad y aumenta la posibilidad de ignorar señales verdaderamente relevantes. Conviene establecer niveles de atención según persistencia, magnitud y convergencia entre indicadores. Una alerta útil dirige la mirada hacia un fenómeno verificable, facilita contrastar observaciones y deja espacio para que entrenadores y especialistas valoren causas antes de modificar la planificación.

Dentro de la analítica inteligente, detectar cambios significativos permite convertir el seguimiento longitudinal en una herramienta de interpretación activa. El algoritmo compara al deportista con su historia, reconoce transiciones y aporta evidencia para decidir cuándo investigar una variación con profundidad. Su utilidad depende de mantener trazabilidad, validación y prudencia interpretativa. Bajo esa orientación, las anomalías dejan de ser cifras aisladas y pasan a funcionar como indicios que enriquecen el diálogo entre medición y criterio profesional.

2.5. Modelos de inteligencia artificial explicable para interpretar el rendimiento deportivo

La inteligencia artificial explicable responde a una necesidad creciente dentro del análisis deportivo: comprender las razones que conducen a una predicción, clasificación o alerta algorítmica. Conocer el resultado carece de suficiente valor práctico cuando entrenadores y especialistas desconocen qué variables orientaron la decisión del modelo. La explicabilidad procura

traducir relaciones matemáticas complejas en argumentos interpretables, vinculando cada salida con factores reconocibles del rendimiento y facilitando una valoración profesional informada antes de intervenir sobre la preparación deportiva.

La necesidad de explicación aumenta conforme los modelos incorporan mayor complejidad y número de variables. Munoz-Macho et al. (2024) describen una presencia creciente de aplicaciones de inteligencia artificial dirigidas al rendimiento y la salud en equipos deportivos de élite. Frente a tal diversidad, interpretar las contribuciones de carga, recuperación, condición física o indicadores técnicos permite distinguir asociaciones relevantes de relaciones circunstanciales. La transparencia analítica favorece además una comunicación más precisa entre científicos, entrenadores y deportistas implicados.

Existen modelos interpretables por diseño, como árboles de decisión y ciertas regresiones, cuya estructura permite seguir con relativa facilidad la relación entre variables y resultados. Otros procedimientos requieren técnicas explicativas posteriores que estiman la contribución de cada característica a una predicción determinada. La elección entre ambas vías depende del problema deportivo y del equilibrio buscado entre precisión y comprensión. Una arquitectura compleja carece de ventaja práctica cuando sus resultados no pueden examinarse con criterio profesional.

Entre los recursos explicativos disponibles, la importancia de variables permite reconocer qué factores ejercen mayor influencia dentro del modelo. Métodos de atribución local pueden mostrar, además, por qué una predicción cambia para un deportista determinado. Pashaie et al. (2026) analizan la evolución de estrategias de entrenamiento apoyadas por inteligencia artificial, destacando oportunidades relacionadas con personalización y apoyo decisional. La explicación individual adquiere relevancia cuando deportistas con cargas semejantes presentan respuestas diferentes durante su preparación habitual.

Las explicaciones globales y locales responden a necesidades complementarias. Una explicación global describe relaciones generales aprendidas por el modelo, mientras la interpretación local examina una observación particular. En rendimiento deportivo, ambas escalas deben dialogar. Conocer que determinada variable posee gran peso general no implica que resulte decisiva para cada atleta. La lectura individual permite reconocer combinaciones específicas y evita trasladar mecánicamente tendencias colectivas hacia decisiones personales, especialmente cuando existen perfiles fisiológicos, técnicos y competitivos heterogéneos.

La utilidad de una explicación depende también de su estabilidad. Si pequeñas modificaciones en los datos producen argumentos radicalmente diferentes, la confianza profesional puede verse comprometida. Conviene evaluar si las variables destacadas mantienen relaciones coherentes entre sesiones, deportistas y periodos competitivos. Munoz-Macho et al. (2024) advierten una notable heterogeneidad metodológica en aplicaciones deportivas de inteligencia artificial. Tal diversidad refuerza la necesidad de validar no únicamente predicciones, sino también explicaciones derivadas de ellas con rigor.

Explicar una predicción tampoco equivale a demostrar causalidad. Que una variable contribuya intensamente a la salida de un algoritmo indica una relación aprendida dentro de los datos disponibles, pero no confirma que modificarla produzca necesariamente el efecto esperado. La distinción resulta especialmente importante al ajustar cargas o estrategias de recuperación. Una interpretación responsable combina evidencia algorítmica con conocimiento fisiológico, experiencia profesional y seguimiento longitudinal, evitando convertir asociaciones computacionales en prescripciones automáticas para cada deportista evaluado.

La explicabilidad adquiere una dimensión comunicativa cuando los resultados llegan al entrenador. Ganaie et al. (2026), mediante revisión sistemática y metaanálisis, examinan efectos del entrenamiento asistido por inteligencia artificial sobre el rendimiento, reflejando el creciente interés por integrar herramientas algorítmicas en la práctica profesional. Para favorecer tal integración, las explicaciones deben presentarse mediante lenguaje comprensible, visualizaciones pertinentes y jerarquías informativas claras. Una explicación técnicamente correcta pierde utilidad cuando exige conocimientos inaccesibles para quien decide cotidianamente.

También resulta necesario examinar sesgos mediante herramientas explicativas. Si un modelo concede peso excesivo a variables asociadas con una categoría, posición deportiva o grupo determinado, la interpretación puede revelar dependencias que permanecerían ocultas al observar únicamente métricas de precisión. Revisar contribuciones individuales ayuda a identificar decisiones sistemáticamente desequilibradas y orienta nuevas validaciones. La transparencia, por tanto, no constituye un añadido decorativo, sino un mecanismo de auditoría que fortalece el uso responsable de sistemas inteligentes deportivos.

La inteligencia artificial explicable completa la extracción de patrones al convertir resultados computacionales en conocimiento susceptible de discusión profesional. Su aporte reside en mostrar qué factores intervienen, cuánto pesan y bajo qué relaciones aparece una predicción, manteniendo visibles los márgenes de incertidumbre. El entrenador puede entonces contrastar la evidencia con observación, experiencia y objetivos de preparación. La analítica adquiere madurez cuando no entrega respuestas cerradas, sino argumentos examinables que enriquecen decisiones deportivas razonadas y personalizadas.

2.6. Construcción de perfiles digitales longitudinales del deportista

La construcción de perfiles digitales longitudinales permite representar la evolución del deportista mediante datos acumulados durante periodos prolongados. A diferencia de una fotografía puntual del rendimiento, el perfil conserva cambios, respuestas y antecedentes relevantes para interpretar cada nueva observación. Su propósito consiste en organizar la historia deportiva como una secuencia dinámica, donde cargas, capacidades físicas, disponibilidad y resultados adquieren significado al compararse con referencias personales generadas durante temporadas, ciclos de preparación y etapas competitivas sucesivas.

Un perfil longitudinal requiere continuidad en la captura y criterios uniformes para registrar información. Las variaciones en dispositivos, protocolos o definiciones pueden producir discontinuidades difíciles de separar de cambios reales del atleta. Por ello, la trazabilidad adquiere especial importancia: cada dato necesita fecha, procedencia, unidad y condiciones de obtención. Cuando la información mantiene coherencia metodológica, resulta posible reconocer tendencias personales y estudiar la relación entre experiencias previas, respuestas recientes y evolución futura del rendimiento deportivo.

La personalización constituye uno de los rasgos distintivos de tales perfiles. De Leeuw et al. (2022) desarrollaron un enfoque personalizado de aprendizaje automático para monitorizar lesiones en voleibolistas de élite, mostrando el interés de adaptar el análisis a características individuales. Desde una perspectiva longitudinal, cada deportista funciona como referencia de su propia evolución. Tal orientación reduce la dependencia de promedios grupales y permite valorar cambios relativos respecto de antecedentes acumulados durante periodos previos suficientemente representativos.

La dimensión multitemporada amplía la capacidad para diferenciar fluctuaciones pasajeras de transformaciones persistentes. Majumdar et al. (2024) analizaron mediante aprendizaje automático relaciones entre carga de entrenamiento y lesión en fútbol profesional considerando varias temporadas. Una mirada prolongada permite observar modificaciones asociadas con calendarios, participación competitiva y exposición acumulada. También facilita revisar si determinados patrones reaparecen bajo condiciones semejantes, aportando memoria analítica al seguimiento y evitando interpretar cada temporada como una unidad completamente independiente del historial.

Construir una representación longitudinal no implica almacenar indiscriminadamente cualquier medición disponible. La selección debe responder a preguntas deportivas definidas y conservar variables con valor interpretativo a través del tiempo. Datos antropométricos, cargas, pruebas físicas, indicadores técnicos y registros de disponibilidad pueden adquirir relevancia cuando mantienen continuidad. Una arquitectura bien organizada permite relacionar capas temporales diferentes sin convertir el perfil en un repositorio saturado, donde la abundancia de información termine dificultando la lectura profesional del deportista.

El concepto de gemelo digital lleva la representación longitudinal hacia modelos capaces de reproducir virtualmente aspectos relevantes del atleta. Lukač et al. (2022) plantean su aplicación deportiva como una vía para conectar datos, modelado y simulación dentro de representaciones digitales dinámicas. Bajo dicha perspectiva, el perfil deja de actuar como archivo histórico y adquiere capacidad para actualizarse conforme llegan nuevas mediciones, ofreciendo una base individual sobre la cual contrastar escenarios y respuestas deportivas individuales potenciales.

La actualización del perfil requiere mecanismos que reconozcan que el deportista cambia con entrenamiento, edad,

experiencia y exposición competitiva. Un valor considerado habitual durante una temporada puede perder representatividad meses después. Los modelos deben ponderar información reciente sin borrar antecedentes valiosos, manteniendo equilibrio entre memoria y adaptación. Tal principio evita referencias rígidas y permite que los rangos personales evolucionen. La identidad analítica del atleta se entiende entonces como una construcción temporal, revisable y permanentemente enriquecida.

Los perfiles longitudinales también permiten estudiar relaciones entre carga y disponibilidad desde una perspectiva individual. De Leeuw et al. (2022) mostraron que los enfoques personalizados pueden ofrecer ventajas al modelar información vinculada con lesiones en deportistas de élite. Majumdar et al. (2024), por otra parte, abordaron patrones de carga durante múltiples temporadas. Ambas líneas refuerzan el valor de conservar historia suficiente para interpretar asociaciones sin desprenderlas de la trayectoria particular de cada atleta evaluado individualmente.

La gobernanza de datos adquiere especial relevancia porque un perfil longitudinal concentra información personal durante años. Resulta necesario definir permisos, responsabilidades, periodos de conservación y criterios para compartir resultados entre profesionales. La calidad ética del sistema depende también de limitar usos ajenos al propósito deportivo acordado. Además, cualquier inferencia generada debe conservar vínculos con los datos que la originaron, permitiendo revisar decisiones y corregir interpretaciones cuando aparezcan nuevas evidencias o cambien las condiciones del seguimiento.

Concebido de manera rigurosa, el perfil digital longitudinal funciona como memoria analítica del proceso deportivo y como puente entre observaciones separadas en el tiempo. Lukač et al. (2022) vinculan la noción de gemelo digital con representaciones dinámicas capaces de acompañar procesos deportivos mediante

información actualizable. La utilidad práctica reside en preservar continuidad sin congelar al atleta en categorías permanentes. Cada nueva medición amplía una historia cuantificada que debe permanecer abierta a revisión, interpretación y aprendizaje.

Tabla 2
Componentes de la analítica inteligente aplicados al rendimiento deportivo

Componente analítico	Aporte al análisis del rendimiento deportivo
Aprendizaje automático e identificación de patrones	Reconoce regularidades, relaciones no lineales y variaciones individuales en datos históricos de entrenamiento y competición, favoreciendo la caracterización de respuestas deportivas y la identificación de comportamientos relevantes para la toma de decisiones.
Visión artificial y análisis biomecánico	Transforma imágenes y secuencias de video en información cuantificable sobre posiciones corporales, trayectorias, ángulos articulares y coordinación, facilitando una valoración técnica del movimiento vinculada con las condiciones reales de entrenamiento.
Analítica multimodal	Integra datos procedentes de sensores, video y registros de entrenamiento mediante referencias temporales compatibles, relacionando carga, respuesta fisiológica, ejecución motriz y planificación para construir interpretaciones más amplias del rendimiento individual.
Detección algorítmica de cambios	Identifica desviaciones, tendencias y transiciones significativas en indicadores longitudinales, diferenciando fluctuaciones habituales de modificaciones persistentes que requieren atención, comprobación profesional o ajustes en el proceso de preparación.
Inteligencia artificial explicable	Facilita la interpretación de predicciones y clasificaciones mediante la identificación del peso y la contribución de las variables, promoviendo transparencia, trazabilidad y

	una valoración crítica de las salidas algorítmicas antes de trasladarlas a decisiones deportivas.
Perfiles digitales longitudinales	Organiza la evolución individual mediante información acumulada durante temporadas y ciclos de preparación, generando referencias personales dinámicas que permiten relacionar antecedentes, respuestas recientes y cambios progresivos dentro de una trayectoria deportiva cuantificada.

Nota. Los componentes mantienen una relación progresiva: la identificación de patrones proporciona regularidades relevantes; la visión artificial cuantifica el movimiento; la integración multimodal relaciona fuentes heterogéneas; la detección algorítmica reconoce variaciones significativas; la explicabilidad favorece su interpretación profesional; y los perfiles longitudinales preservan la evolución individual a través del tiempo.

Capítulo III

Predicción de fatiga, recuperación y disponibilidad para entrenar

Entrenar implica convivir con una variabilidad que rara vez responde de manera lineal a lo planificado. La carga prescrita representa una intención; la respuesta del deportista, en cambio, refleja procesos fisiológicos, perceptivos y mecánicos que cambian entre jornadas. Bajo dicha perspectiva, anticipar fatiga, recuperación y disponibilidad adquiere interés para una planificación sensible al individuo. La inteligencia artificial ofrece recursos para reconocer regularidades en registros acumulados y convertirlas en estimaciones capaces de acompañar decisiones profesionales con mayor oportunidad.

Durante años, buena parte del seguimiento deportivo descansó en indicadores examinados por separado y comparaciones respecto de valores de referencia. Aquella práctica aportó conocimiento valioso, aunque resultaba limitada frente a relaciones dinámicas entre carga y respuesta. Mandorino et al. (2023) mostraron que técnicas de aprendizaje automático pueden aprovechar información locomotora para cuantificar la preparación de futbolistas. La mirada predictiva amplía, por tanto, la lectura retrospectiva y permite trabajar con probabilidades asociadas al estado funcional futuro.

La fatiga merece una lectura temporal porque sus manifestaciones dependen tanto del estímulo reciente como de la acumulación producida durante jornadas anteriores. Un registro aislado puede parecer normal y, aun con ello, formar parte de una trayectoria desfavorable. El análisis de series deportivas permite conservar dicha secuencia y buscar patrones que anteceden modificaciones relevantes. La cuestión ya no consiste meramente en medir cuánto entrenó una persona, sino en comprender qué dirección está tomando su respuesta individual.

Recuperarse tampoco representa un fenómeno binario. Entre una respuesta favorable y una condición claramente comprometida existen numerosos estados intermedios, difíciles de reducir a una cifra universal. Teixeira et al. (2024) comprobaron que

diversos algoritmos podían clasificar estados de recuperación en futbolistas jóvenes mediante variables procedentes de carga, GPS y percepción del esfuerzo. Dicha evidencia refuerza una visión multidimensional, donde señales internas y externas dialogan para caracterizar con mayor precisión la disposición funcional de cada atleta.

Figura 7

Predicción inteligente para la gestión del entrenamiento



La disponibilidad para entrenar introduce una pregunta todavía más cercana a la práctica: qué exigencia puede afrontar razonablemente un deportista en un momento determinado. Estar recuperado no garantiza idéntica preparación para velocidad máxima, trabajo técnico, fuerza o esfuerzos intermitentes. Por ello, la predicción necesita vincular el estado individual con las demandas previstas. La utilidad de un modelo reside entonces en discriminar posibilidades de participación y orientar ajustes proporcionados, sin convertir una estimación algorítmica en mandato operativo.

Otro frente relevante aparece cuando la respuesta observada se aparta del patrón habitual. No toda desviación merece alarma, pero ciertas combinaciones pueden advertir cambios que conviene revisar. de Leeuw et al. (2022) demostraron el interés de enfoques personalizados de aprendizaje automático para la monitorización de lesiones en voleibolistas de élite. La personalización cobra especial valor cuando cada atleta posee tolerancias, ritmos de adaptación y perfiles de respuesta que difícilmente pueden representarse mediante umbrales idénticos para todo un grupo.

La relación entre carga y rendimiento añade una capa de complejidad. El entrenamiento puede generar fatiga transitoria y, posteriormente, adaptación favorable; ambos efectos conviven con escalas temporales diferentes. Connor et al. (2022) plantearon un sistema inteligente de control capaz de reajustar planes futuros cuando aparecen desviaciones respecto de objetivos previstos. Desde dicha lógica, predecir no significa adivinar resultados, sino actualizar decisiones conforme nueva información modifica la comprensión de la respuesta producida por el programa aplicado.

La disponibilidad creciente de sensores y dispositivos portátiles ha transformado también la observación cotidiana. Distancias, aceleraciones, respuestas fisiológicas y percepciones pueden reunirse con una continuidad antes difícil de alcanzar. Cui et al. (2023) destacaron el potencial de tecnologías vestibles para analizar recuperación física y apoyar estrategias relacionadas con prevención. Sin embargo, acumular registros carece de valor cuando la información no conduce a interpretaciones comprensibles. El verdadero avance aparece al convertir datos abundantes en conocimiento accionable y prudente.

En ese tránsito, los sistemas de alerta representan un puente entre predicción y práctica. Su propósito no consiste en sustituir al entrenador, sino en dirigir la atención hacia variaciones que merecen examen. Majumdar et al. (2024) estudiaron mediante

aprendizaje automático relaciones entre carga e incidencia lesional a lo largo de varias temporadas de fútbol profesional, evidenciando el valor de registros longitudinales para captar asociaciones complejas. Una alerta gana sentido cuando comunica incertidumbre y favorece una revisión profesional proporcionada.

A lo largo del capítulo, la inteligencia artificial será entendida como una herramienta de apoyo para leer procesos deportivos cambiantes, no como autoridad independiente. Fatiga, recuperación, respuestas atípicas, disponibilidad y variaciones del rendimiento forman partes conectadas de una misma dinámica adaptativa. La predicción adquiere relevancia cuando ayuda a intervenir con anticipación y aprender de la respuesta posterior. En esa relación entre evidencia, experiencia y decisión reside una vía prometedora para construir entrenamientos más individualizados, adaptativos y responsables.

3.1. Modelos predictivos de fatiga a partir de series temporales deportivas

Los modelos predictivos de fatiga basados en series temporales convierten registros sucesivos de entrenamiento en estimaciones sobre el estado funcional del deportista. Su valor reside en conservar el orden de las observaciones, pues una misma carga adquiere significados distintos según lo ocurrido durante jornadas previas. Distancias, aceleraciones, frecuencia cardiaca, percepción del esfuerzo y recuperación forman secuencias donde persisten huellas de carga acumulada. El aprendizaje automático puede reconocer patrones temporales difíciles de advertir mediante análisis aislados.

La construcción de una serie temporal exige definir una unidad de observación coherente con la dinámica deportiva. Sesiones, días o microciclos pueden funcionar como intervalos, siempre que la frecuencia de registro permita representar cambios relevantes. Mandorino et al. (2023) integraron información de

disponibilidad mediante técnicas de aprendizaje automático, mostrando que la preparación del futbolista puede abordarse mediante indicadores relacionados. Desde una perspectiva temporal, esa integración favorece estimaciones sensibles a variaciones sucesivas del proceso de entrenamiento.

Decisión metodológica importante consiste en determinar cuánto pasado necesita el algoritmo para anticipar fatiga. Ventanas demasiado breves pueden omitir acumulaciones relevantes; ventanas extensas, en cambio, pueden incorporar información que ya perdió valor fisiológico. Por ello, la longitud temporal debe relacionarse con la disciplina, densidad competitiva y frecuencia de entrenamiento. El objetivo no consiste en almacenar datos indefinidamente, sino en representar una memoria útil, capaz de distinguir carga reciente, carga persistente y recuperación entre sesiones consecutivas.

Antes del modelado, las series requieren depuración. Los dispositivos portátiles generan pérdidas, valores atípicos y cambios de escala que alteran la continuidad de los registros. Aparecen sesiones ausentes por descanso, viaje, lesión o decisiones técnicas, y cada ausencia posee un significado diferente. Teixeira et al. (2024) aplicaron tratamiento de valores faltantes, normalización y selección de variables antes de clasificar estados de recuperación. Tal preparación reduce ruido y evita atribuir significado fisiológico a irregularidades meramente instrumentales.

La ingeniería de variables temporales permite transformar registros brutos en representaciones informativas. Promedios móviles, pendientes, variabilidad entre sesiones, razones entre periodos y retardos de una señal pueden describir tendencias que una observación puntual no revela. Sin embargo, acumular transformaciones aumenta redundancia y riesgo de sobreajuste. Conviene seleccionar atributos que mantengan una relación interpretable con fatiga y recuperación, preservando además la secuencia original cuando el algoritmo pueda aprender

dependencias temporales directamente a partir de datos longitudinales.

La elección del algoritmo depende del volumen de datos, la frecuencia de muestreo y el propósito de la predicción. Métodos basados en árboles ofrecen interpretabilidad y toleran relaciones no lineales, mientras arquitecturas recurrentes o mecanismos de atención pueden aprender dependencias prolongadas cuando existen suficientes observaciones. En deporte aplicado, mayor complejidad no garantiza mejor utilidad. Un modelo parsimonioso, estable entre semanas y comprensible para el cuerpo técnico puede aportar más valor que otro preciso pero opaco.

La escasez de observaciones representa una limitación frecuente, porque las plantillas deportivas son pequeñas y los periodos de seguimiento suelen interrumpirse. Cordeiro et al. (2025) evaluaron datos sintéticos generados mediante autoencoders variacionales tabulares para ampliar conjuntos destinados a predecir atenuación del rendimiento. La estrategia resulta pertinente cuando se preservan distribuciones y relaciones relevantes sin confundir datos artificiales con evidencia observada. En series temporales, además, cualquier generación sintética debe respetar dependencia secuencial y variabilidad individual real.

La validación merece atención especial porque dividir registros aleatoriamente puede introducir información futura en el entrenamiento del modelo. Una evaluación temporal rigurosa entrena con periodos anteriores y prueba con periodos posteriores, reproduciendo el uso del sistema. Conviene separar deportistas cuando se pretende generalizar hacia integrantes no observados. Teixeira et al. (2024) recurrieron a validación cruzada para examinar el desempeño clasificatorio; en aplicaciones longitudinales, la lógica debe adaptarse para conservar la dirección temporal de los datos.

El rendimiento predictivo no debería juzgarse únicamente mediante exactitud global. En fatiga deportiva importa conocer sensibilidad ante estados comprometidos, falsos negativos, calibración de probabilidades y estabilidad entre deportistas. Una alerta que cambia bruscamente sin respaldo en la tendencia reciente puede generar desconfianza, aunque alcance buenas métricas agregadas. Mandorino et al. (2023) plantearon la preparación como una estimación derivada de información multidimensional, perspectiva compatible con salidas probabilísticas que apoyen decisiones graduadas en lugar de etiquetas rígidas.


La utilidad aparece cuando la predicción se incorpora al diálogo entre datos, observación profesional y respuesta individual del atleta. El modelo puede anticipar una trayectoria desfavorable, pero la decisión sobre modificar volumen, intensidad o recuperación requiere interpretación humana y conocimiento del proceso de entrenamiento. Por tanto, conviene presentar tendencias, incertidumbre y variables influyentes de manera accesible. La predicción adquiere valor cuando permite actuar con anticipación, revisar la respuesta posterior y actualizar el sistema con información.

3.2. Estimación inteligente de la recuperación mediante indicadores internos y externos

La estimación inteligente de la recuperación parte de una idea sencilla: el organismo responde a la carga mediante señales que no avanzan siempre al mismo ritmo. Algunas reflejan percepción, otras describen respuestas fisiológicas o mecánicas. Integrarlas permite aproximarse al grado de preparación con mayor precisión que una lectura fragmentada. El interés analítico reside en reconocer relaciones entre señales internas y externas, respetando diferencias individuales y evitando convertir una cifra aislada en diagnóstico automático del deportista.

Los indicadores internos expresan la respuesta del organismo frente al trabajo realizado. Frecuencia cardiaca, variabilidad cardiaca, percepción de esfuerzo, calidad del sueño, dolor muscular y bienestar aportan información complementaria sobre recuperación. Su interpretación requiere continuidad, porque los valores adquieren significado al compararse con referencias personales. Teixeira et al. (2024) mostraron que variables perceptivas y medidas de carga pueden alimentar algoritmos capaces de clasificar niveles de recuperación en futbolistas jóvenes de diferentes categorías competitivas con resultados.

Figura 8
Integración inteligente de indicadores de recuperación



Los indicadores externos describen el trabajo efectuado sin depender directamente de la respuesta fisiológica percibida. Distancia recorrida, velocidad, aceleraciones, desaceleraciones, impactos, duración y densidad del entrenamiento permiten cuantificar demandas mecánicas. Los dispositivos portátiles han ampliado considerablemente la disponibilidad de tales registros. Cui et al. (2023) relacionaron su utilización con el análisis de

recuperación física y prevención de lesiones, destacando el valor de recopilar información continua para orientar intervenciones deportivas apoyadas por datos individualizados muy relevantes.

La verdadera capacidad informativa aparece al relacionar ambas familias de indicadores. Dos deportistas pueden completar una carga externa semejante y mostrar respuestas internas muy diferentes posteriormente. Esa divergencia resulta valiosa para los sistemas inteligentes, pues permite aprender patrones personales de adaptación. El algoritmo deja de preguntar cuánto trabajo fue realizado y comienza a estimar qué efecto produjo. Tal cambio de perspectiva aproxima la predicción a la realidad biológica, marcada por variabilidad biológica y respuestas individuales.

Para integrar señales heterogéneas, el procesamiento previo necesita preservar significado y comparabilidad. Escalas distintas, frecuencias de muestreo desiguales y registros incompletos pueden distorsionar relaciones relevantes. Normalizar respecto de referencias individuales, sincronizar mediciones y controlar valores anómalos mejora la representación del proceso recuperativo. Teixeira et al. (2024) aplicaron procedimientos de preparación y selección de variables antes de entrenar clasificadores, una decisión metodológica que favorece modelos menos expuestos al ruido procedente de mediciones deportivas y errores instrumentales.

La personalización adquiere importancia porque una misma señal puede representar situaciones diferentes entre atletas. Un descenso determinado en bienestar o una variación cardíaca concreta carecen de interpretación universal. de Leeuw et al. (2022) desarrollaron un enfoque personalizado de aprendizaje automático para monitorizar lesiones en voleibolistas de élite, mostrando el interés de construir modelos sensibles al perfil individual. Trasladado a recuperación, dicho principio permite valorar desviaciones respecto de patrones propios antes que aplicar umbrales poblacionales rígidos.

Los algoritmos pueden combinar relaciones lineales y no lineales entre carga, respuesta y recuperación, pero su elección debe responder al problema práctico. Árboles de decisión, métodos de ensamble y clasificadores probabilísticos resultan útiles cuando interesa explicar qué variables influyen en una predicción. Modelos más complejos pueden captar interacciones, aunque requieren mayor volumen informativo. En cualquier caso, precisión estadística e interpretabilidad deben mantenerse próximas, especialmente cuando la salida orientará ajustes cotidianos dentro de la planificación deportiva.

Una estimación útil debe comunicar incertidumbre. Clasificar a un deportista como recuperado o no recuperado mediante fronteras rígidas puede ocultar transiciones graduales y variaciones normales. Resulta preferible expresar probabilidades, niveles de confianza o zonas de preparación que permitan valorar tendencias. Teixeira et al. (2024) abordaron la recuperación mediante clasificación, evidenciando la viabilidad de distinguir categorías a partir de información disponible. En la práctica, tales categorías ganan sentido cuando acompañan, y no reemplazan, el juicio profesional.

La frecuencia de medición condiciona la calidad de la estimación. Registrar demasiado poco puede perder cambios relevantes; medir de manera excesiva genera carga operativa, fatiga del registro y datos de calidad dudosa persistente. Los dispositivos vestibles reducen parte de dicha fricción al capturar señales durante actividad. Cui et al. (2023) destacaron su utilidad para analizar recuperación física mediante información continua. Aun con automatización, conviene priorizar indicadores accionables, fiables y sostenibles durante periodos largos de seguimiento.

La estimación inteligente de la recuperación alcanza utilidad cuando conduce a decisiones proporcionadas y revisables. Una probabilidad menor de preparación puede motivar ajustes en volumen, intensidad, contenido técnico o estrategias regenerativas,

sin convertir la predicción en orden automática. El entrenador aporta lectura situacional; el deportista, sensaciones corporales; el sistema, capacidad para relacionar múltiples señales. De esa interacción nace una gestión dinámica de la disponibilidad, preparada para enlazar con modelos orientados a decidir cuándo entrenar plenamente.

3.3. Detección temprana de respuestas atípicas ante las cargas de entrenamiento

La detección temprana de respuestas atípicas desplaza la atención desde el valor promedio hacia la desviación individual frente a una carga determinada. Un entrenamiento habitual puede provocar una reacción inesperada en variables fisiológicas, perceptivas o mecánicas, aun cuando la planificación permanece dentro de márgenes conocidos. Los sistemas de inteligencia artificial permiten identificar tales discrepancias mediante patrones personales de referencia, distinguiendo fluctuaciones ordinarias de cambios que merecen observación antes de que afecten rendimiento, recuperación o disponibilidad.

Una respuesta atípica no equivale necesariamente a lesión, fatiga excesiva ni pérdida de rendimiento. Representa una diferencia relevante entre la reacción observada y aquella esperada según el historial del deportista. Tal distinción evita interpretar cualquier variación como señal de alarma. de Leeuw et al. (2022) mostraron que los enfoques personalizados de aprendizaje automático pueden aprovechar perfiles individuales para monitorizar riesgo en voleibolistas de élite, favoreciendo evaluaciones ajustadas a características propias de cada jugador en particular.

La referencia individual constituye, por tanto, el punto de partida para reconocer anomalías con significado deportivo. Promedios grupales pueden ocultar respuestas poco frecuentes en un atleta cuya adaptación habitual difiere de la plantilla. Resulta

más informativo comparar cada registro con rangos personales contruidos mediante observaciones repetidas recientes. Cuando una variable se aparta persistentemente de su comportamiento esperado, el sistema puede elevar su relevancia analítica sin convertir una oscilación ocasional en evidencia automática de deterioro funcional.

El aprendizaje automático amplía dicha vigilancia al examinar interacciones que resultan difíciles de detectar mediante umbrales independientes. Una combinación moderada de carga, menor bienestar y reducción del rendimiento neuromuscular puede adquirir relevancia aunque ninguna variable exceda límites predefinidos. Majumdar et al. (2024) analizaron varias temporadas de fútbol profesional para estudiar relaciones entre carga de entrenamiento y lesión mediante aprendizaje automático, perspectiva que resalta la necesidad de considerar patrones multivariados y longitudinales de entrenamiento en atletas.

Los métodos de detección de anomalías pueden operar con diferentes grados de supervisión. Cuando existen etiquetas fiables, los modelos aprenden respuestas previamente asociadas con estados desfavorables. Cuando tales etiquetas son escasas, técnicas no supervisadas identifican observaciones alejadas del patrón habitual sin exigir categorías previas. Entre ambos extremos, estrategias semisupervisadas aprovechan información parcial. La elección depende de la calidad, del número de atletas y de la frecuencia con que ocurren respuestas verdaderamente inusuales durante el entrenamiento.

La rareza de ciertos episodios plantea un problema estadístico: los modelos reciben abundantes ejemplos de funcionamiento habitual y pocos casos de deterioro marcado. Cordeiro et al. (2025) abordaron la escasez de datos mediante generación sintética orientada a predecir atenuación del rendimiento, mostrando una vía para ampliar conjuntos limitados. Sin embargo, los datos artificiales requieren validación cuidadosa,

pues una anomalía creada matemáticamente puede carecer de plausibilidad fisiológica o representar relaciones inexistentes en deportistas reales con registros.

Detectar una desviación exige considerar también su persistencia. Una noche de sueño deficiente, una sesión percibida como especialmente dura o una reducción puntual del salto pueden responder a variaciones normales. La señal adquiere mayor interés cuando varias alteraciones convergen o permanecen durante mediciones sucesivas. Por ello, los algoritmos deben ponderar magnitud, duración y combinación de cambios. Tal enfoque reduce alertas innecesarias y dirige la atención profesional hacia patrones que modifican la trayectoria habitual del atleta.

La sensibilidad del sistema debe equilibrarse con su capacidad para evitar falsas alarmas. Un detector excesivamente reactivo termina generando avisos frecuentes que pierden credibilidad entre entrenadores y deportistas; uno demasiado conservador puede ignorar cambios relevantes. de Leeuw et al. (2022) evidenciaron el valor de adaptar el modelado al individuo, principio especialmente pertinente al definir umbrales dinámicos. La calibración requiere revisar periódicamente errores, utilidad práctica y consecuencias derivadas de cada alerta dentro del proceso deportivo diario.

La interpretación de una respuesta atípica requiere prudencia, porque el algoritmo identifica discrepancias estadísticas y no causas clínicas. Viajes, cambios tácticos, estrés competitivo, condiciones ambientales o errores de medición pueden modificar los registros sin representar deterioro fisiológico. Majumdar et al. (2024) examinaron la relación entre carga e incidencia lesional mediante datos de múltiples temporadas, recordando que las asociaciones necesitan evaluarse longitudinalmente. Una alerta adquiere valor cuando abre una revisión informada, no cuando dicta decisiones automáticamente.

Integrada en la práctica cotidiana, la detección temprana funciona como mecanismo de vigilancia adaptativa. El sistema compara la respuesta reciente con la trayectoria, identifica desviaciones relevantes y ofrece información para decidir si conviene mantener, ajustar o investigar la carga programada. Su aporte reside en ganar tiempo antes de que una alteración comprometa disponibilidad. La inteligencia artificial actúa entonces como apoyo interpretativo, mientras entrenador y deportista conservan la responsabilidad de valorar la señal y actuar proporcionalmente.

3.4. Predicción individual de disponibilidad para sesiones de diferente exigencia

La disponibilidad para entrenar representa la probabilidad de que un deportista pueda responder adecuadamente a una sesión con demandas determinadas. No equivale a ausencia de fatiga ni a recuperación completa, porque cada tarea exige capacidades distintas. Un jugador puede encontrarse preparado para trabajo técnico moderado y mostrar menor aptitud ante esfuerzos neuromusculares intensos. La inteligencia artificial permite estimar dicha disposición relacionando respuestas, características individuales y exigencias previstas dentro de la planificación diaria del entrenamiento cotidiano.

La predicción individual requiere definir primero qué significa estar disponible para una tarea concreta. Una sesión orientada a velocidad demanda condiciones diferentes de otra centrada en movilidad, resistencia aeróbica o aprendizaje táctico. Por ello, la variable objetivo debe vincular el estado del atleta con requerimientos específicos. Mandorino et al. (2023) abordaron la preparación de futbolistas mediante aprendizaje automático, integrando múltiples dimensiones para obtener una valoración individual que puede orientar decisiones sobre participación y exigencia prevista.

Una arquitectura predictiva útil relaciona información acumulada del deportista con las demandas programadas para la jornada siguiente. Carga reciente, bienestar, sueño, respuestas fisiológicas y rendimiento previo pueden actuar como predictores, mientras el tipo de sesión aporta el marco de la estimación. El modelo aprende asociaciones entre perfiles de preparación y respuestas posteriores. De ese modo, la pregunta deja de centrarse en la recuperación funcional y pasa a valorar para qué esfuerzo presenta mayor disposición funcional.

La personalización resulta especialmente relevante cuando atletas sometidos a programas parecidos responden de manera diferente. Edad, historial de entrenamiento, posición, nivel competitivo y tolerancia habitual modifican la relación entre carga previa y capacidad posterior. de Leeuw et al. (2022) mostraron, en voleibol de élite, que los enfoques personalizados de aprendizaje automático pueden mejorar la monitorización al considerar patrones propios de cada jugador. Tal principio favorece predicciones de disponibilidad menos dependientes de referencias grupales generales competitivas.


La recuperación aporta una pieza importante, aunque no agota la valoración de disponibilidad. Un atleta puede presentar indicadores favorables de bienestar y, pese a ello, carecer de preparación específica para una demanda elevada. Teixeira et al. (2024) emplearon aprendizaje automático para clasificar estados de recuperación en futbolistas, evidenciando que variables pueden contribuir a discriminar niveles recuperativos. Vincular dicha clasificación con exigencias futuras permite transformar una descripción del estado presente en una estimación orientada a decisiones.

Desde una perspectiva operativa, conviene formular la salida predictiva mediante niveles o probabilidades vinculados con categorías de sesión. En lugar de emitir un veredicto binario, el sistema puede estimar alta disponibilidad para trabajo técnico,

disponibilidad moderada para esfuerzos intermitentes y menor preparación para estímulos máximos. Tal gradación refleja la naturaleza continua de la adaptación. También facilita que el cuerpo técnico ajuste contenidos sin interpretar cada señal desfavorable como motivo para retirar al deportista del entrenamiento.

Figura 9

Predicción individual de disponibilidad para entrenar



La calidad predictiva depende de que las etiquetas utilizadas durante el aprendizaje representen resultados relevantes. Completar una sesión no demuestra necesariamente disponibilidad adecuada; importa valorar respuesta fisiológica, ejecución, percepción posterior y capacidad para sostener la tarea prevista. Mandorino et al. (2023) plantearon una cuantificación de la preparación apoyada en técnicas de aprendizaje automático. Bajo una lógica aplicada, las etiquetas deberían reflejar grados de respuesta funcional, evitando confundir presencia en el entrenamiento con aptitud para rendir.

Otro aspecto metodológico reside en actualizar el modelo cuando cambia la condición habitual del deportista. La preparación física evoluciona, las funciones competitivas se modifican y determinadas cargas dejan de producir respuestas equivalentes con el paso del tiempo. Un sistema entrenado con registros antiguos puede perder sensibilidad ante nuevas adaptaciones. Por ello, resulta conveniente recalibrar periódicamente parámetros y referencias individuales, verificando que las probabilidades mantengan correspondencia con respuestas observadas durante ciclos recientes de entrenamiento y competición.

La predicción también debe acompañarse de explicaciones comprensibles para quienes toman decisiones. Conocer que la disponibilidad prevista es reducida aporta menos información que identificar qué señales contribuyeron a dicha estimación. Cambios recientes en bienestar, tolerancia mecánica o respuesta cardiovascular pueden orientar ajustes distintos. de Leeuw et al. (2022) respaldan el valor de aproximaciones personalizadas, donde el patrón individual adquiere protagonismo. La interpretabilidad convierte una probabilidad abstracta en información susceptible de discusión entre profesionales y deportista.

Aplicada con criterio, la predicción individual permite pasar de una planificación uniforme a una prescripción sensible al estado diario y a la exigencia prevista. El propósito no consiste en delegar la sesión al algoritmo, sino en ofrecer una estimación anticipada que dialogue con observación, experiencia y objetivos deportivos. Cada predicción puede contrastarse después con la respuesta real, generando aprendizaje continuo. Esa retroalimentación convierte la disponibilidad en una variable dinámica para ajustar decisiones sin perder coherencia.

3.5. Modelos de carga-respuesta para anticipar variaciones del rendimiento

Los modelos de carga-respuesta buscan representar la relación entre el estímulo de entrenamiento y las variaciones del rendimiento. Su interés radica en reconocer que una misma carga puede producir adaptación, mantenimiento o deterioro según la dosis, la secuencia y la respuesta individual. Frente a lecturas descriptivas, el modelado predictivo intenta estimar la dirección y magnitud del cambio esperado. La carga deja entonces de ser un registro retrospectivo y adquiere valor como variable para anticipar decisiones.

La formulación clásica distingue efectos positivos vinculados con la adaptación y efectos negativos asociados con la fatiga, ambos desarrollados mediante ritmos temporales diferentes. La inteligencia artificial amplía esa lógica al admitir relaciones no lineales, interacciones y respuestas variables entre atletas. Connor et al. (2022) plantearon la generación adaptativa de planes mediante sistemas de control inteligente, donde la información derivada del rendimiento puede alimentar ajustes sucesivos de la prescripción y favorecer una regulación dinámica del entrenamiento.

Definir la respuesta que se desea anticipar resulta tan importante como cuantificar la carga. El rendimiento puede expresarse mediante velocidad, potencia, salto, tiempo de prueba, precisión técnica o indicadores específicos de competición. Cada variable responde a estímulos y escalas temporales particulares. Por ello, un modelo útil necesita vincular cargas pertinentes con resultados comparables. Cuando la variable objetivo carece de sensibilidad, incluso un algoritmo avanzado tendrá dificultades para distinguir adaptación real de fluctuaciones habituales del desempeño.

La individualización vuelve a ocupar un lugar central, aunque ahora orientada hacia la relación entre dosis y efecto. Mandorino et al. (2023) emplearon técnicas de aprendizaje automático para cuantificar la preparación de futbolistas mediante información multidimensional, reforzando la utilidad de integrar respuestas particulares. En modelos de carga-respuesta, tal principio permite estimar curvas propias: algunos atletas toleran incrementos rápidos, mientras otros necesitan progresiones menores para alcanzar mejoras semejantes sin acumular deterioro funcional apreciable durante ciclos exigentes.

Los retardos temporales añaden complejidad al análisis. Una carga aplicada hoy puede disminuir transitoriamente el rendimiento y favorecer una mejora varios días después. Si el modelo relaciona estímulo y resultado sin considerar dicho desfase, puede interpretar una respuesta adaptativa como efecto negativo. Las ventanas temporales deben representar tanto fatiga inmediata como adaptación diferida. La elección puede apoyarse en conocimiento fisiológico, análisis y validación prospectiva, procurando que cada horizonte conserve significado para la planificación deportiva cotidiana.

El aprendizaje automático permite detectar interacciones entre volumen, intensidad, densidad competitiva y características individuales que rara vez siguen relaciones proporcionales. Majumdar et al. (2024) analizaron varias temporadas de fútbol profesional mediante técnicas predictivas para estudiar vínculos entre carga de entrenamiento y lesión. Aunque el desenlace difiere del rendimiento, su enfoque evidencia la utilidad de trabajar con información longitudinal y múltiples variables cuando se buscan asociaciones complejas derivadas de exposiciones acumuladas durante periodos prolongados y cambiantes.

Una dificultad frecuente reside en separar variación auténtica del rendimiento y ruido de medición. Cambios pueden proceder del instrumento, aprendizaje de la prueba, motivación o

condiciones ambientales. Por esa razón, las variables objetivo requieren fiabilidad y protocolos consistentes. El modelo debería aprender modificaciones que tengan relevancia deportiva, no cualquier diferencia numérica. Incorporar estimaciones de error y bandas de incertidumbre ayuda a interpretar predicciones cercanas al margen habitual de variabilidad sin atribuirles significado excesivo o prematuro.

La validación prospectiva resulta especialmente importante cuando el propósito consiste en anticipar rendimiento futuro. Entrenar y evaluar con registros mezclados temporalmente puede inflar las métricas al permitir que información posterior contribuya indirectamente al aprendizaje. Connor et al. (2022) concibieron la planificación adaptativa como un proceso de control donde la respuesta observada retroalimenta decisiones posteriores. Bajo tal lógica, evaluar periodos futuros preserva la secuencia de intervención, observación y reajuste que caracteriza al entrenamiento aplicado en práctica cotidiana.

Una predicción adquiere utilidad cuando permite comparar escenarios de carga antes de ejecutar la sesión. El sistema puede estimar qué variación de rendimiento cabría esperar ante combinaciones de volumen e intensidad, dentro del rango respaldado por los datos disponibles. Tal capacidad no convierte al algoritmo en prescriptor autónomo. Más bien ofrece una herramienta para contrastar alternativas. El entrenador conserva la decisión, incorporando objetivos técnicos, calendario competitivo y observaciones que no siempre quedan registradas digitalmente.

Los modelos de carga-respuesta completan una transición desde vigilar el estado del atleta hacia anticipar las consecuencias probables de una intervención. Fatiga, recuperación, respuestas atípicas y disponibilidad aportan señales que pueden relacionarse con cambios posteriores del rendimiento. Mandorino et al. (2023) muestran el potencial del aprendizaje automático para integrar información diversa sobre preparación. La utilidad práctica crece

cuando cada nueva respuesta observada retroalimenta el modelo, afinando progresivamente la relación entre carga prescrita, adaptación individual y rendimiento.

3.6. Sistemas de alerta inteligente para apoyar decisiones sobre carga y recuperación

Los sistemas de alerta inteligente convierten predicciones y mediciones deportivas en señales orientadas a la toma de decisiones. Su función consiste en advertir cambios que merecen atención antes de modificar la carga o las estrategias de recuperación. Una alerta útil no reemplaza el criterio profesional ni prescribe automáticamente una conducta. Ordena información dispersa, pondera patrones recientes y comunica grados de prioridad, permitiendo que entrenadores y especialistas concentren su atención donde existe mayor necesidad de revisión inmediata.

El diseño comienza por establecer qué acontecimientos justifican una notificación. Superar un umbral de carga puede resultar insuficiente cuando la respuesta individual permanece dentro de márgenes habituales. Por ello, conviene combinar magnitud, tendencia y desviación personal. Majumdar et al. (2024) analizaron mediante aprendizaje automático relaciones entre carga e incidencia lesional durante varias temporadas de fútbol profesional. Tal aproximación respalda una vigilancia basada en múltiples factores, antes que en límites universales aplicados indistintamente a cada deportista.

La recuperación aporta otra dimensión para graduar las alertas. Un incremento de carga acompañado por bienestar estable puede requerir vigilancia menor que una exposición equivalente asociada con deterioro perceptivo persistente. Teixeira et al. (2024) demostraron que algoritmos de clasificación pueden diferenciar estados de recuperación en futbolistas jóvenes utilizando diversas variables. Trasladada a sistemas de alerta, dicha capacidad permite asignar niveles de atención según la combinación de señales,

evitando decisiones sustentadas en una medición aislada o circunstancial.

Los dispositivos portátiles facilitan alertas cercanas al momento en que ocurren variaciones relevantes. Sensores de movimiento y registros fisiológicos generan flujos continuos capaces de alimentar modelos automatizados. Cui et al. (2023) relacionaron tecnologías vestibles con análisis orientados a recuperación física y prevención de lesiones. Sin embargo, mayor frecuencia de registro no garantiza mejor decisión. La utilidad depende de transformar grandes volúmenes de señales en avisos comprensibles, oportunos y vinculados con acciones profesionales razonables para cada caso.

La arquitectura de alertas puede organizarse mediante niveles graduales de prioridad. Una señal de baja intensidad podría recomendar observación; una combinación persistente de indicadores desfavorables justificaría revisar la sesión prevista; una alteración marcada podría motivar valoración especializada. La graduación reduce respuestas desproporcionadas y favorece decisiones acordes con la incertidumbre disponible. Además, permite comunicar riesgo sin presentar predicciones probabilísticas como certezas, una precaución necesaria cuando las consecuencias afectan planificación, participación deportiva y recuperación del atleta.

Un problema frecuente aparece cuando el sistema produce demasiadas notificaciones. La repetición de avisos poco relevantes genera fatiga de alerta y disminuye la atención del personal, precisamente lo contrario de aquello que se pretende conseguir. Para evitarlo, los algoritmos pueden jerarquizar señales según persistencia, magnitud y concordancia entre variables. La sensibilidad debe calibrarse frente al costo de falsos positivos y falsos negativos, considerando que ambos errores pueden alterar innecesariamente decisiones sobre carga y recuperación diaria.

La explicación que acompaña cada aviso determina buena parte de su utilidad. Informar una categoría de riesgo sin indicar sus principales determinantes dificulta valorar la recomendación. Resulta preferible mostrar qué variables cambiaron, durante cuánto tiempo y con qué intensidad respecto del patrón individual. Teixeira et al. (2024) evidenciaron el potencial de combinar diferentes indicadores para clasificar recuperación. En aplicaciones prácticas, esa integración puede traducirse en mensajes breves que faciliten interpretación sin saturar al cuerpo técnico.

Toda alerta necesita desembocar en una respuesta proporcional, no necesariamente en reducción de entrenamiento. Dependiendo del patrón detectado, puede resultar apropiado modificar volumen, redistribuir intensidad, ampliar recuperación, repetir una medición o mantener la planificación bajo observación. Cui et al. (2023) destacaron el potencial de los dispositivos vestibles para apoyar análisis relacionados con recuperación y prevención. La decisión conserva carácter profesional porque ninguna señal digital reúne por sí misma toda la información relevante del deportista en campo.

El rendimiento del sistema también debe evaluarse mediante utilidad práctica. Exactitud, sensibilidad y especificidad aportan información estadística, pero interesa conocer cuántas alertas condujeron a revisiones pertinentes y cuántas fueron ignoradas por resultar poco informativas. Majumdar et al. (2024) mostraron que las relaciones entre carga y resultados adversos pueden estudiarse mediante modelos desarrollados con registros longitudinales. Una evaluación continuada permite reajustar umbrales y prioridades conforme cambian las respuestas del deportista durante la temporada competitiva.

Integrados con criterio, los sistemas de alerta cierran el ciclo entre medición, predicción y decisión que articula la gestión inteligente de la carga. La información recopilada alimenta modelos, las estimaciones identifican variaciones relevantes y las

alertas trasladan dicha evidencia hacia una acción posible. Después, la respuesta observada permite valorar la pertinencia de la decisión y reajustar reglas predictivas. Se configura, de tal manera, un proceso dinámico donde tecnología y experiencia profesional permanecen vinculadas de manera permanente.

Tabla 3
Componentes analíticos para la predicción de fatiga, recuperación y disponibilidad para entrenar

Componente analítico	Aplicación en la toma de decisiones deportivas
Modelos predictivos de fatiga mediante series temporales	Analizan la evolución secuencial de cargas y respuestas para anticipar patrones compatibles con acumulación de fatiga, considerando la trayectoria individual y el valor temporal de las observaciones.
Estimación inteligente de la recuperación	Integra indicadores internos y externos para estimar el grado de recuperación funcional, relacionando respuestas fisiológicas, perceptivas y mecánicas con referencias propias del deportista.
Detección temprana de respuestas atípicas	Identifica desviaciones respecto del comportamiento habitual y distingue fluctuaciones ordinarias de patrones que requieren observación, revisión profesional o ajustes preventivos de la carga.
Predicción individual de disponibilidad	Estima la capacidad probable del atleta para responder a sesiones con diferentes niveles y tipos de exigencia, favoreciendo decisiones individualizadas sobre participación, volumen e intensidad.
Modelos de carga-respuesta	Relacionan los estímulos aplicados con variaciones posteriores del rendimiento, considerando efectos inmediatos, adaptaciones diferidas, diferencias individuales y relaciones no lineales entre dosis y respuesta.
Sistemas de alerta inteligente	Transforman predicciones y cambios relevantes en avisos graduados e

Componente analítico	Aplicación en la toma de decisiones deportivas
	interpretables que apoyan decisiones sobre carga, recuperación y seguimiento, manteniendo el juicio profesional como instancia decisoria.

Nota. La tabla articula la secuencia analítica desarrollada en el capítulo, desde la identificación anticipada de fatiga hasta la generación de alertas para apoyar decisiones. Los componentes funcionan de manera complementaria dentro de un proceso dinámico de medición, predicción, interpretación, intervención y retroalimentación.

Capítulo IV

Personalización algorítmica de cargas y prescripción adaptativa

La planificación del entrenamiento ha convivido durante décadas con una tensión difícil de resolver: organizar anticipadamente el trabajo y, al mismo tiempo, responder a la variabilidad humana. Ningún deportista atraviesa una temporada de manera lineal. El rendimiento fluctúa, la recuperación cambia y una carga apropiada durante una semana puede resultar excesiva o insuficiente poco después. La inteligencia artificial aporta nuevas herramientas para leer tales variaciones y convertir información acumulada en decisiones progresivamente individualizadas.

Personalizar implica abandonar la idea de que una prescripción promedio representa adecuadamente a todos los integrantes de un grupo. De Leeuw et al. (2022) comprobaron, mediante aprendizaje automático aplicado a voleibol de élite, que las relaciones entre indicadores de carga, bienestar y problemas por sobreuso presentan rasgos particulares entre jugadores. Tal evidencia refuerza una premisa conocida por entrenadores experimentados: compartir programa no significa responder igual. La diferencia reside ahora en poder cuantificar parte de aquella singularidad.

La transformación adquiere mayor profundidad cuando los datos dejan de funcionar como registro retrospectivo y participan activamente en la regulación del entrenamiento. Connor et al. (2022) plantean sistemas inteligentes de control capaces de generar planes adaptativos mediante retroalimentación procedente del propio proceso deportivo. La planificación conserva dirección, pero gana flexibilidad. Cada nueva observación puede confirmar una decisión previa, advertir una desviación o justificar una modificación prudente, siempre dentro de límites definidos por objetivos y criterios profesionales.

A medida que crece la capacidad de procesamiento, la personalización alcanza dimensiones que exceden la simple modificación de una carga numérica. Pashaie et al. (2026) describen una evolución de las estrategias de entrenamiento asistidas por

inteligencia artificial hacia intervenciones cada vez más sensibles a características individuales. Elegir tareas, ordenar contenidos, reconocer preferencias funcionales y relacionar respuestas con decisiones anteriores forman parte de una misma arquitectura. El algoritmo adquiere valor cuando ayuda a discriminar, no cuando multiplica recomendaciones indiscriminadamente.

Figura 10

Personalización algorítmica del entrenamiento



La dimensión temporal introduce otra cuestión relevante. Una decisión de entrenamiento rara vez termina en la sesión donde fue tomada, porque sus efectos condicionan jornadas posteriores. Xia et al. (2025) desarrollan un modelo de aprendizaje por refuerzo profundo orientado al control personalizado de cargas, donde las acciones sucesivas se vinculan con estados del deportista y objetivos de rendimiento. Pensar secuencialmente permite valorar consecuencias diferidas, equilibrando beneficios inmediatos con trayectorias de adaptación que requieren continuidad y prudencia.

Junto con la capacidad de aprender de decisiones anteriores aparece la posibilidad de ensayar virtualmente

alternativas futuras. Lukač et al. (2022) presentan los gemelos digitales deportivos como representaciones capaces de vincular datos del mundo físico con modelos computacionales. Hliš et al. (2024) amplían dicha perspectiva mediante una taxonomía que muestra diferentes grados de integración y potencial práctico. La simulación abre un espacio prometedor para comparar respuestas probables antes de trasladar una intervención al deportista real.

Pero ninguna arquitectura adaptativa puede separarse de la calidad de aquello que observa. Los dispositivos portátiles han ampliado considerablemente la frecuencia con que pueden registrarse variables fisiológicas, mecánicas y conductuales durante la práctica. Cui et al. (2023) relacionan datos obtenidos mediante tecnología vestible con procesos de recuperación física y prevención de lesiones. La disponibilidad continua modifica el ritmo de decisión: determinadas variaciones pueden reconocerse durante la sesión, mientras otras necesitan perspectiva temporal antes de adquirir significado deportivo.

La proximidad entre medición y decisión tampoco convierte cada señal en una orden de cambio. Teixeira et al. (2024) emplearon aprendizaje automático para clasificar estados de recuperación en futbolistas juveniles, mostrando el valor de integrar múltiples indicadores al estimar preparación. La lección metodológica resulta importante: personalizar requiere distinguir información relevante de fluctuaciones ordinarias. Un sistema demasiado reactivo puede fragmentar la planificación; uno excesivamente rígido, en cambio, desaprovecha señales que justificarían una adaptación razonable del trabajo previsto.

La creciente participación algorítmica también obliga a precisar responsabilidades. Ganaie et al. (2026), mediante revisión sistemática y metaanálisis, documentan efectos favorables del entrenamiento asistido por inteligencia artificial sobre el rendimiento deportivo, aunque la diversidad metodológica exige interpretar los hallazgos con cautela. La tecnología puede ampliar

memoria analítica, velocidad de procesamiento y capacidad predictiva, pero la decisión aplicada continúa requiriendo criterio humano. Prescribir implica valorar objetivos, riesgos, experiencia, comunicación y consecuencias que ningún indicador resume plenamente.

Desde tal perspectiva, la personalización algorítmica puede entenderse como una relación dinámica entre datos, modelos, decisiones y respuestas humanas. El capítulo aborda dicha relación desde distintos niveles de intervención: prescripción individual, regulación de variables, recomendación de contenidos, aprendizaje secuencial, simulación digital y adaptación mediante dispositivos portátiles. Cada nivel aporta una pieza diferente. En conjunto, permiten concebir el entrenamiento como un proceso regulable, verificable y sensible a la trayectoria particular de cada deportista sin perder dirección metodológica.

4.1. Prescripción individualizada mediante aprendizaje automático

La prescripción individualizada mediante aprendizaje automático desplaza el diseño de cargas desde esquemas generales hacia decisiones sensibles a la respuesta de cada deportista. El valor del modelo reside en reconocer que una misma dosis externa puede provocar adaptaciones divergentes según historial, estado funcional y tolerancia acumulada. En lugar de fijar progresiones rígidas, el sistema aprende relaciones entre estímulo y respuesta, ofreciendo al entrenador base cuantitativa para ajustar volumen, intensidad, densidad y recuperación con mayor precisión.

Para construir una prescripción útil, los algoritmos requieren series capaces de representar la evolución del atleta. Datos de frecuencia cardíaca, percepción del esfuerzo, potencia, velocidad, sueño, bienestar y carga mecánica adquieren sentido cuando se relacionan longitudinalmente. De Leeuw et al. (2022) mostraron que el análisis personalizado de indicadores de carga y

bienestar permite identificar asociaciones particulares con problemas por sobreuso. La unidad de análisis, por tanto, deja de ser el grupo y pasa al individuo.

El aprendizaje supervisado puede estimar respuestas futuras a partir de patrones observados previamente, siempre que las variables de entrada posean calidad suficiente y relevancia fisiológica. Una predicción de fatiga, rendimiento esperado o tolerancia a determinada sesión puede convertirse en criterio para modificar la dosis programada. Sin embargo, prescribir no equivale a obedecer una salida matemática: la recomendación algorítmica funciona mejor cuando dialoga con la planificación, la observación técnica y el juicio profesional acumulado durante temporadas.

La personalización gana profundidad cuando el modelo incorpora retroalimentación continua. Cada sesión aporta información acerca de relaciones entre dosis, recuperación y desempeño, permitiendo actualizar parámetros y reducir progresivamente errores de estimación. Xia et al. (2025) plantean un enfoque de aprendizaje por refuerzo profundo que integra monitorización fisiológica, características individuales y decisiones adaptativas. Bajo dicha lógica, prescribir se convierte en un proceso dinámico: cada respuesta modifica la elección posterior y redefine la trayectoria de carga prevista.

Un sistema individualizado también debe distinguir entre variabilidad significativa y fluctuaciones cotidianas irrelevantes. No toda caída de rendimiento exige reducir trabajo, ni toda mejora autoriza incrementos. La sensibilidad algorítmica necesita acompañarse de umbrales, ventanas temporales y criterios de cambio que eviten prescripciones erráticas. Cuando la señal se interpreta dentro de tendencias individuales, el modelo puede detectar desviaciones tempranas y proponer ajustes prudentes, preservando continuidad del estímulo sin convertir cada dato en una orden de intervención.

La utilidad depende de formular objetivos compatibles entre sí. Maximizar rendimiento a corto plazo puede entrar en tensión con disponibilidad competitiva, recuperación o prevención de sobrecarga. Los modelos de aprendizaje por refuerzo permiten representar dicha tensión mediante funciones de recompensa que ponderan resultados diversos. Xia et al. (2025) describen una arquitectura orientada a equilibrar mejora de desempeño y gestión del riesgo. La calidad de la prescripción depende de aquello que el sistema aprende a valorar.

La individualización algorítmica adquiere especial relevancia cuando existen respuestas heterogéneas dentro de un mismo equipo. Dos atletas con cargas externas semejantes pueden presentar niveles distintos de fatiga, molestias o preparación para entrenar. De Leeuw et al. (2022) encontraron relaciones específicas por jugador entre variables de carga, bienestar y problemas por sobreuso en voleibol de élite. Tal evidencia respalda una idea operativa importante: los promedios colectivos orientan, pero no reemplazan la lectura longitudinal de cada deportista.

Prescribir mediante aprendizaje automático exige mecanismos de interpretación accesibles para quienes deciden en campo. Una recomendación pierde valor cuando el cuerpo técnico desconoce qué variables impulsaron el ajuste o qué grado de incertidumbre acompaña la predicción. La transparencia favorece revisión, discusión y aprendizaje compartido. En términos aplicados, conviene que el sistema comunique razones, tendencias y márgenes de confianza, en vez de entregar cifras aisladas que aparenten una certeza incompatible con la variabilidad biológica del rendimiento.

La evidencia del entrenamiento asistido por inteligencia artificial refuerza el interés por articular análisis predictivo, retroalimentación y optimización de cargas en la práctica. La revisión de Ganaie et al. (2026) vincula dichas aplicaciones con mejoras del rendimiento y estrategias preventivas, aunque la

transferencia depende de diseño, calidad de datos y supervisión. La prescripción individualizada encuentra valor cuando amplía la capacidad del entrenador para interpretar al atleta, sin desplazar la relación pedagógica que guía el proceso.

En términos metodológicos, una prescripción adaptativa madura requiere ciclos de evaluación, actualización y validación personal. El modelo debe aprender del historial, contrastar sus recomendaciones con respuestas y reconocer cuándo pierde precisión ante cambios temporales, lesión, competencia o preparación. Esa vigilancia evita convertir patrones pasados en reglas permanentes. La meta no consiste en automatizar el entrenamiento, sino en construir decisiones más informadas, trazables y sensibles a la singularidad deportiva, manteniendo al profesional responsable de cada ajuste.

4.2. Ajuste dinámico de volumen, intensidad, densidad y frecuencia del entrenamiento

El ajuste dinámico de volumen, intensidad, densidad y frecuencia permite que la carga deje de concebirse como una estructura invariable y pase a responder al estado funcional observado durante el proceso. Cada componente modifica de manera distinta la exigencia fisiológica y neuromuscular, pero ninguno opera de forma aislada. Variar repeticiones, velocidad, pausas o sesiones semanales altera el estímulo global. La inteligencia artificial facilita coordinar tales cambios sin perder de vista los objetivos deportivos previstos estratégicamente.

La regulación comienza por reconocer que aumentar volumen no equivale necesariamente a mejorar la adaptación. Acumular trabajo puede resultar productivo durante determinadas fases, mientras que en otras conviene preservar calidad reduciendo repeticiones o duración. Connor et al. (2022) plantean sistemas inteligentes capaces de generar planes adaptativos mediante retroalimentación entre desempeño registrado y carga prescrita.

Bajo dicha perspectiva, el volumen adquiere carácter negociable: se modifica conforme aparecen respuestas que confirman o cuestionan la dosis previamente establecida.

Figura 11

Ajuste dinámico de la carga deportiva



La intensidad requiere una lectura particularmente cuidadosa porque pequeñas variaciones pueden transformar la naturaleza del estímulo. En fuerza, velocidad o resistencia, modificar porcentajes, ritmos y zonas fisiológicas cambia las demandas de cada sesión. Un algoritmo puede relacionar rendimiento reciente, percepción de esfuerzo y marcadores de preparación para recomendar incrementos o reducciones graduadas. La ventaja reside en evitar ajustes intuitivos desproporcionados, conservando suficiente exigencia para estimular adaptación mientras se limita la acumulación innecesaria de fatiga residual.

La densidad introduce otra capa de regulación al determinar la relación temporal entre esfuerzo y recuperación. Acortar pausas puede elevar el estrés metabólico aun cuando

volumen e intensidad permanezcan aparentemente estables; ampliarlas, en cambio, favorece calidad mecánica y restauración parcial. Por ello, un sistema adaptativo necesita interpretar las pausas como parte de la dosis. La decisión algorítmica cobra utilidad cuando coordina tiempos de recuperación con respuestas recientes, propósito de la sesión y tolerancia individual observada.

La frecuencia distribuye el estímulo a lo largo del microciclo y condiciona oportunidades de recuperación entre exposiciones. Ajustarla exige considerar disponibilidad, carga acumulada y respuesta ante sesiones previas, evitando interpretar el número semanal como parámetro independiente. Mandorino et al. (2023) emplearon técnicas de aprendizaje automático para cuantificar la preparación de futbolistas mediante información multidimensional. Una estimación semejante puede orientar cuándo mantener una sesión prevista, desplazarla o reducir su demanda para proteger la continuidad del entrenamiento.

El verdadero potencial adaptativo aparece cuando volumen, intensidad, densidad y frecuencia se regulan de manera conjunta. Reducir una variable puede permitir elevar otra sin incrementar excesivamente la carga total; del mismo modo, una sesión intensa quizá requiera menor volumen o mayor recuperación posterior. Xia et al. (2025) desarrollan un enfoque basado en aprendizaje por refuerzo que ajusta cargas mediante interacción entre estado del atleta y decisiones del sistema. La prescripción adquiere entonces una lógica relacional.

La regulación automática necesita límites operativos para impedir cambios excesivos ante oscilaciones pasajeras. Conviene establecer rangos aceptables de modificación, velocidades máximas de progresión y reglas de seguridad vinculadas con la planificación. Tales restricciones no debilitan al algoritmo; por el contrario, delimitan un espacio de decisión compatible con principios del entrenamiento. Cuando una recomendación rebasa dichos márgenes, el entrenador puede revisar causas, contrastar señales y

decidir si existe fundamento suficiente para alterar la carga programada inicialmente.

También importa la escala temporal en que se ejecutan los ajustes. Algunas decisiones pertenecen a la sesión, como prolongar una pausa o reducir series; otras afectan varios días, por ejemplo redistribuir frecuencia o moderar volumen semanal. Connor et al. (2022) destacan el valor de sistemas de control capaces de actualizar planes mediante información obtenida en ejecución. Esa arquitectura permite combinar correcciones inmediatas con modificaciones, evitando que cada respuesta puntual reorganice innecesariamente toda la planificación deportiva.

La calidad del ajuste depende, además, de reconocer la incertidumbre de las estimaciones. Mandorino et al. (2023) muestran que la preparación deportiva puede modelarse mediante múltiples indicadores, aunque cualquier clasificación conserva márgenes de error. Por ello, las decisiones deberían graduarse según confianza predictiva y magnitud del cambio detectado. Una señal ambigua puede justificar vigilancia antes que modificación; una tendencia persistente, acompañada por indicadores convergentes, ofrece mayor fundamento para redistribuir componentes de carga con prudencia profesional.

El ajuste dinámico alcanza madurez cuando funciona como mecanismo de regulación y no como sustituto de la planificación. Los objetivos siguen marcando dirección, mientras los datos permiten modificar la vía utilizada para alcanzarlos. La inteligencia artificial aporta velocidad analítica, memoria longitudinal y capacidad para detectar relaciones difíciles de advertir. El entrenador conserva la responsabilidad de interpretar prioridades, aceptar o rechazar cambios y mantener coherencia entre adaptación inmediata, desarrollo acumulativo y demandas competitivas de cada ciclo.

4.3. Sistemas de recomendación aplicados a ejercicios y contenidos de entrenamiento

Los sistemas de recomendación trasladan al entrenamiento una lógica conocida en otros dominios digitales: seleccionar, entre numerosas alternativas, aquellas con mayor pertinencia para una persona y un propósito determinados. En el ámbito deportivo, dicha selección puede abarcar ejercicios, tareas técnicas, secuencias tácticas, medios de recuperación o contenidos educativos. Su aporte no reside en ampliar indiscriminadamente el repertorio, sino en ordenar opciones según necesidades detectadas, restricciones operativas y objetivos definidos por el cuerpo técnico responsable correspondiente.

A diferencia de la regulación cuantitativa de la carga, recomendar contenidos implica decidir qué tarea conviene ejecutar y con qué prioridad dentro de una sesión. El algoritmo compara atributos del deportista con características de ejercicios previamente descritos, generando correspondencias que pueden cambiar conforme avanza la preparación. Pashaie et al. (2026) describen una evolución del entrenamiento asistido por inteligencia artificial hacia estrategias más personalizadas, donde el análisis de datos amplía las posibilidades de intervención del entrenador.

La arquitectura del recomendador depende de la información disponible. Los enfoques basados en contenido relacionan necesidades individuales con atributos de cada tarea; los modelos colaborativos aprovechan patrones observados entre deportistas con perfiles comparables. También pueden combinarse ambas vías mediante diseños híbridos. En entrenamiento, la elección metodológica requiere cautela, porque similitudes algorítmicas no garantizan respuestas equivalentes. Edad deportiva, nivel técnico, antecedentes de exposición y propósito

competitivo pueden modificar profundamente la pertinencia de una recomendación aparentemente adecuada.

Para que una tarea pueda recomendarse con rigor, necesita una representación informativa suficientemente rica. Etiquetas sobre patrón motor, grupo muscular, demanda energética, complejidad coordinativa, equipamiento, duración, objetivo táctico o nivel de dificultad permiten construir catálogos estructurados. El valor práctico aparece cuando dichas propiedades se conectan con necesidades detectadas en el atleta. Una biblioteca bien descrita convierte al algoritmo en mediador entre diagnóstico y práctica, evitando propuestas genéricas desconectadas de la intención pedagógica de cada sesión.

La recomendación también puede aprender de resultados anteriores. Si determinadas tareas producen respuestas favorables en perfiles específicos, el sistema actualiza la probabilidad de seleccionarlás nuevamente bajo condiciones semejantes. Xia et al. (2025) emplean aprendizaje por refuerzo para adaptar decisiones de entrenamiento mediante retroalimentación derivada de la condición del deportista y del rendimiento observado. Trasladada a la selección de ejercicios, dicha lógica permite valorar consecuencias acumuladas, no meramente preferencias inmediatas o coincidencias descriptivas entre variables disponibles relevantes.

Un recomendador deportivo competente debe preservar variedad sin confundirla con novedad permanente. Repetir tareas facilita aprendizaje técnico, consolidación motriz y comparación longitudinal; variar estímulos, por otra parte, puede atender nuevas necesidades o evitar adaptación. El equilibrio depende del objetivo y del momento de preparación. Por ello, los algoritmos pueden incorporar reglas de diversidad, historial de exposición y progresión de dificultad, manteniendo continuidad suficiente para que cada ejercicio conserve significado dentro del programa deportivo planificado global.

La retroalimentación del deportista añade una dimensión difícil de capturar mediante sensores. Percepción de dificultad, confianza, dolor, disfrute o comprensión de una tarea pueden modificar su utilidad práctica aunque los indicadores externos parezcan favorables. Ganaie et al. (2026), al revisar intervenciones de entrenamiento asistidas por inteligencia artificial, destacan resultados favorables sobre el rendimiento, dentro de una evidencia que demanda atención a diferencias metodológicas. Integrar valoración humana ayuda a evitar recomendaciones técnicamente correctas pero pedagógicamente pobres.

La selección algorítmica adquiere mayor interés en deportes donde una misma capacidad puede entrenarse mediante tareas muy diferentes. Un objetivo de aceleración, por ejemplo, admite ejercicios de fuerza, técnica de carrera, salidas específicas o acciones con oposición. El recomendador puede jerarquizar alternativas atendiendo a transferencia esperada, fatiga asociada, disponibilidad material y experiencia previa. No dicta una receta cerrada; ofrece un repertorio razonado que el entrenador reorganiza según prioridades tácticas, pedagógicas y competitivas del momento actual.

Otro requisito reside en evitar círculos de recomendación que reduzcan progresivamente el repertorio. Cuando un sistema privilegia siempre tareas previamente exitosas, puede reforzar preferencias históricas y limitar oportunidades de aprendizaje. Pashaie et al. (2026) vinculan la inteligencia artificial aplicada al entrenamiento con nuevas posibilidades de análisis y personalización, pero la decisión profesional mantiene un papel rector. Introducir criterios de diversidad, revisión periódica y alternativas justificadas permite conservar apertura metodológica sin renunciar a la precisión individual.

En una estructura adaptativa madura, los sistemas de recomendación conectan evaluación, selección de contenidos y respuesta posterior dentro de un ciclo revisable. Su función consiste

en transformar información dispersa en opciones de entrenamiento pertinentes, explicables y compatibles con la planificación. La calidad no depende de recomendar más, sino de discriminar mejor. Cuando entrenador y algoritmo comparten criterios explícitos, cada ejercicio deja de ocupar un lugar por costumbre y pasa a responder a una intención verificable.

4.4. Aprendizaje por refuerzo para la adaptación secuencial de cargas deportivas

El aprendizaje por refuerzo aporta una lógica para decisiones de carga que se encadenan a lo largo del tiempo. A diferencia de modelos centrados en predecir una respuesta aislada, un agente aprende políticas de actuación mediante consecuencias acumuladas. Cada decisión modifica el estado posterior del deportista y condiciona alternativas futuras. La atención se desplaza, por tanto, desde la dosis inmediata hacia secuencias capaces de equilibrar adaptación, recuperación y rendimiento durante periodos prolongados de preparación deportiva.

Dentro de dicha formulación, el estado representa la información disponible antes de decidir: carga reciente, rendimiento, fatiga, recuperación y otros indicadores pertinentes. La acción corresponde al ajuste elegido, mientras la recompensa expresa el valor atribuido a sus consecuencias. Xia et al. (2025) aplican aprendizaje por refuerzo profundo al control personalizado de cargas competitivas, vinculando decisiones sucesivas con optimización del rendimiento. La utilidad metodológica reside en aprender relaciones temporales que una regla fija difícilmente captaría plenamente.

La función de recompensa merece atención particular porque orienta aquello que el agente aprende a perseguir. Premiar únicamente mejoras inmediatas puede favorecer decisiones agresivas y poco compatibles con una preparación sostenible. Una formulación más rica puede ponderar rendimiento, estabilidad,

recuperación y cumplimiento de objetivos intermedios. En términos prácticos, diseñar recompensas equivale a traducir prioridades deportivas a lenguaje computacional. Esa traducción requiere criterio profesional, pues cualquier ponderación expresa una concepción acerca del progreso deseable del atleta.

La adaptación secuencial también plantea el dilema entre aprovechar decisiones conocidas y probar alternativas mejores. En aprendizaje por refuerzo, dicha tensión se expresa mediante estrategias de explotación y búsqueda controlada. En deporte, experimentar resulta inapropiado cuando puede comprometer salud o preparación competitiva. Por ello, el espacio de acciones necesita límites fisiológicos y metodológicos. El agente puede aprender dentro de márgenes previamente autorizados, preservando capacidad adaptativa sin convertir al deportista en terreno irrestricto de experimentación algorítmica.


Los sistemas de control ofrecen un antecedente conceptual valioso para comprender dicha regulación. Connor et al. (2022) plantean la generación adaptativa de planes mediante un enfoque donde la información obtenida durante el entrenamiento retroalimenta decisiones posteriores. Tal principio encaja con una política secuencial: observar, actuar, evaluar y actualizar. La diferencia radica en que el aprendizaje por refuerzo puede optimizar elecciones considerando recompensas futuras, en vez de responder únicamente al error detectado en el instante presente.

El valor de una política aprendida depende de representar adecuadamente la trayectoria individual. Un mismo estímulo puede producir efectos diferentes según fatiga acumulada, fase de preparación o exposiciones anteriores. Por ello, la memoria temporal del sistema debe conservar información para distinguir estados aparentemente semejantes. Cuando dicha representación falla, el agente corre el riesgo de recomendar acciones idénticas ante necesidades distintas. La personalización secuencial exige,

entonces, datos longitudinales coherentes y una definición cuidadosa de variables relevantes.

Figura 12

Adaptación secuencial mediante aprendizaje por refuerzo



Los gemelos digitales amplían las posibilidades de aprendizaje al ofrecer representaciones actualizables del deportista. Lukač et al. (2022) describen su aplicación deportiva como una vía para conectar datos del mundo físico con modelos virtuales orientados al análisis. En adaptación de cargas, una representación semejante puede servir para evaluar escenarios antes de intervenir directamente. La simulación no elimina incertidumbre, pero permite comparar políticas, anticipar consecuencias plausibles y reducir experimentación innecesaria sobre atletas durante fases sensibles competitivas.

Otra cuestión aparece cuando cambian las condiciones que dieron origen a una política. Lesiones, interrupciones, modificaciones técnicas o nuevas exigencias competitivas pueden alterar relaciones previamente aprendidas. Un agente adaptativo necesita detectar pérdida de desempeño predictivo y revisar su

estrategia sin confundir novedad con deterioro. Xia et al. (2025) muestran el interés de actualizar decisiones mediante información fisiológica y de rendimiento. La capacidad de reaprender resulta tan importante como la precisión alcanzada durante periodos relativamente estables.

La evaluación de una política requiere mirar más allá del rendimiento promedio. Conviene examinar estabilidad de las decisiones, frecuencia de ajustes, exposición a cargas extremas y capacidad para respetar restricciones definidas. Interesa comparar resultados frente a estrategias convencionales y valorar su comportamiento en situaciones frecuentes. Antes de trasladar una política a la práctica cotidiana, las pruebas retrospectivas y simuladas pueden revelar fallos difíciles de detectar durante el entrenamiento real, donde cada decisión tiene consecuencias materiales.

El aprendizaje por refuerzo completa la lógica adaptativa del capítulo al introducir una perspectiva donde cada carga forma parte de una cadena de decisiones. Su aporte distintivo reside en valorar consecuencias diferidas y aprender políticas que evolucionan con la experiencia acumulada. Aun con algoritmos avanzados, la autonomía debe permanecer acotada por criterios fisiológicos, metodológicos y éticos. La prescripción gana inteligencia cuando combina aprendizaje secuencial, supervisión profesional y revisión permanente de aquello que el sistema recompensa.

4.5. Gemelos digitales del deportista para simular respuestas individuales al entrenamiento

El gemelo digital del deportista representa una construcción computacional vinculada con información procedente del atleta real y actualizada durante su preparación. Su propósito no consiste en reproducir cada rasgo biológico, sino en modelar variables relevantes para anticipar respuestas ante

estímulos determinados. Lukač et al. (2022) describen la transición desde la idea conceptual hacia realizaciones deportivas capaces de conectar medición, modelización y simulación. Tal vínculo abre una vía para ensayar decisiones antes de aplicarlas físicamente después.

A diferencia de un perfil estadístico convencional, el gemelo digital mantiene una relación evolutiva con su referente humano. Nuevos registros modifican parámetros y permiten que la representación acompañe cambios producidos por entrenamiento, recuperación, competencia o interrupciones. Hliš et al. (2024) organizan el campo mediante conceptos y taxonomías que distinguen grados de integración entre entidad física y representación virtual. Esa actualización continua resulta indispensable cuando se pretende simular respuestas individuales con utilidad práctica deportiva cotidiana real.

La construcción del gemelo comienza seleccionando variables capaces de describir procesos relevantes para la pregunta planteada. Potencia, velocidad, frecuencia cardíaca, carga mecánica, percepción del esfuerzo o indicadores de recuperación pueden alimentar modelos diferentes según la disciplina. Acumular mediciones carece de valor cuando no existe una arquitectura que relacione datos con mecanismos de adaptación. La representación debe conservar suficiente detalle para discriminar respuestas, pero también una parsimonia que permita interpretarla, calibrarla y actualizarla regularmente después correctamente.

Una vez calibrado, el modelo virtual permite comparar escenarios de entrenamiento sin exponer inmediatamente al deportista a cada alternativa. Pueden evaluarse variaciones de carga, distribución semanal, recuperación o secuencias de estímulos, observando respuestas simuladas antes de elegir una intervención. Lukač et al. (2022) vinculan el gemelo digital deportivo con posibilidades de simulación apoyadas en datos. La ventaja reside en convertir preguntas del entrenador en escenarios

contrastables, manteniendo prudencia frente a cualquier predicción computacional obtenida previamente.

La simulación individual adquiere especial interés cuando varias decisiones parecen razonables desde la planificación. Dos programas pueden compartir objetivos y diferir en distribución, exigencia o recuperación prevista. El gemelo ofrece un espacio para estimar consecuencias probables bajo cada alternativa, sin presentar ninguna proyección como certeza. Hliš et al. (2024) señalan potenciales prácticos de los gemelos digitales en deporte junto con limitaciones todavía abiertas. La utilidad depende, precisamente, de reconocer el carácter probabilístico de sus resultados.

El valor predictivo exige calibración periódica frente a datos observados. Cuando la respuesta real se aparta de la simulada, la discrepancia aporta información para revisar parámetros, relaciones internas o supuestos del modelo. Dicho proceso transforma el error en una fuente de aprendizaje, siempre que quede documentado y sea interpretado con criterio. Un gemelo que nunca confronta sus proyecciones con el atleta termina convertido en una representación estática, atractiva técnicamente, pero pobre para orientar decisiones deportivas.

La integración de inteligencia artificial puede ampliar la capacidad del gemelo para reconocer patrones, actualizar parámetros y comparar escenarios complejos. Pashaie et al. (2026) describen una evolución de las estrategias de entrenamiento apoyadas por inteligencia artificial hacia formas de intervención crecientemente personalizadas. Dentro de un gemelo digital, tales métodos pueden estimar relaciones no lineales entre estímulos y respuestas. Sin embargo, mayor complejidad computacional no garantiza mayor fidelidad si los datos presentan ruido, sesgos o discontinuidades.

Un problema metodológico aparece al decidir cuánto detalle necesita la representación virtual. Modelar demasiadas variables puede aumentar costos, dificultar interpretación y generar una precisión aparente que no mejora las decisiones. Modelar muy pocas puede ocultar procesos relevantes. Hliš et al. (2024) destacan la amplitud y práctica asociada con los gemelos digitales deportivos. Por ello, el diseño debe responder a una pregunta operativa concreta: qué respuesta interesa anticipar y qué información resulta necesaria para estimarla responsablemente.

La simulación tampoco elimina la responsabilidad del entrenador frente a decisiones sensibles. Una proyección favorable puede entrar en conflicto con dolor referido, observación técnica, restricciones competitivas o información clínica que el modelo no representa adecuadamente. El gemelo funciona mejor como espacio de contraste que como autoridad automática. Permite preguntar qué ocurriría bajo determinadas condiciones, comparar trayectorias plausibles y documentar razones de elección, mientras la decisión aplicada permanece sometida a supervisión y comunicación con el deportista.

Dentro de la personalización algorítmica, el gemelo digital aporta una capa prospectiva: permite ensayar virtualmente antes de intervenir y aprender de la distancia entre predicción y respuesta observada. Su madurez dependerá menos del atractivo tecnológico que de la calidad de calibración, actualización y validación. Cuando la representación conserva vínculo verificable con el atleta, la simulación puede apoyar decisiones prudentes, comparar alternativas y enriquecer la prescripción adaptativa sin confundir una proyección computacional con el organismo real.

4.6. Personalización en tiempo real mediante datos procedentes de dispositivos portátiles

La personalización en tiempo real introduce una escala temporal distinta dentro de la prescripción adaptativa. Los

dispositivos portátiles permiten registrar señales mientras el deportista entrena, transformando la sesión en una fuente continua de información fisiológica y mecánica. Frecuencia cardíaca, aceleración, velocidad, desplazamientos o respuestas cinemáticas pueden alimentar decisiones inmediatas cuando existe procesamiento adecuado. El interés no reside en observar más variables, sino en reconocer cambios relevantes con rapidez suficiente para modificar oportunamente la intervención programada.

La continuidad de la medición modifica también la relación entre planificación y ejecución. Una sesión deja de valorarse únicamente después de concluir y puede ajustarse mientras transcurre, siempre que las señales presenten fiabilidad suficiente. Li y Zhang (2022) emplearon tecnología portátil para evaluar efectos del entrenamiento y la enseñanza en baloncesto mediante información cuantificable. Dicha posibilidad acerca la evaluación al momento de práctica, reduciendo la distancia temporal entre respuesta observada y decisión profesional posterior correspondiente.

Sin embargo, transmitir datos de manera continua no equivale a disponer de información útil en tiempo real. Las señales pueden contener ruido, pérdidas de conexión, errores de colocación o variaciones derivadas del propio movimiento. Antes de generar una recomendación, el sistema necesita filtrar anomalías y comprobar coherencia entre fuentes. Una lectura defectuosa interpretada como cambio fisiológico podría provocar ajustes innecesarios. La velocidad analítica adquiere valor cuando viene acompañada por procedimientos rigurosos de control de calidad instrumental.

Los dispositivos portátiles también permiten relacionar carga externa con respuesta interna durante una misma tarea. Una velocidad mantenida puede acompañarse de incremento progresivo del esfuerzo cardiovascular; del mismo modo,

desplazamientos semejantes pueden generar demandas distintas entre deportistas. Cui et al. (2023) vinculan el análisis mediante dispositivos portátiles con la recuperación física y la prevención de lesiones. Integrar ambas dimensiones facilita detectar discrepancias relevantes antes de que la acumulación de fatiga comprometa la calidad del trabajo previsto inicialmente.

La personalización inmediata requiere definir qué variaciones justifican una intervención. Modificar una tarea ante cada oscilación produciría un entrenamiento inestable y difícil de interpretar. Por ello, los algoritmos pueden combinar umbrales individuales, tendencias breves y persistencia de señales antes de recomendar cambios. Una desviación aislada merece comprobación; varias mediciones convergentes ofrecen mayor fundamento. La regulación en tiempo real funciona mejor cuando distingue fluctuaciones normales de alteraciones con significado práctico para el objetivo de la sesión en curso.

La recuperación aporta otra fuente de información para decidir el grado de preparación antes de iniciar trabajo exigente. Teixeira et al. (2024) utilizaron aprendizaje automático para clasificar estados de recuperación en futbolistas juveniles a partir de indicadores relevantes. Trasladar dicha lógica a sistemas portátiles permite actualizar la estimación conforme llegan nuevas mediciones. El resultado puede orientar calentamiento, duración, pausas o exigencia, siempre bajo criterios previamente definidos y con atención particular a diferencias madurativas entre deportistas jóvenes.

La latencia constituye un aspecto técnico con consecuencias metodológicas. Cuando una señal tarda demasiado en capturarse, transmitirse, procesarse y convertirse en recomendación, puede perder utilidad para la tarea que pretendía regular. No todas las decisiones requieren respuesta instantánea: algunas admiten segundos, otras minutos y varias pueden esperar hasta terminar un bloque. Diseñar sistemas eficientes exige asociar

cada indicador con una ventana temporal pertinente, evitando confundir disponibilidad inmediata de datos con necesidad permanente de intervención operativa.

La interfaz mediante la cual entrenador y deportista reciben información condiciona también su aprovechamiento. Durante una sesión intensa, gráficos complejos o múltiples alertas pueden distraer más de lo que ayudan. Conviene priorizar mensajes breves, jerarquizados y vinculados con acciones comprensibles. Li y Zhang (2022) muestran el potencial de los dispositivos portátiles para apoyar la evaluación del entrenamiento. Convertir mediciones en comunicación operativa exige seleccionar qué información merece atención inmediata y cuál debe reservarse para análisis posterior.

La personalización basada en dispositivos portátiles plantea además cuestiones relacionadas con privacidad, consentimiento y gobernanza de datos. Las mediciones fisiológicas acompañan al deportista durante periodos extensos y pueden revelar información que excede las necesidades inmediatas del entrenamiento. Resulta necesario establecer quién accede, durante cuánto tiempo se conserva y para qué decisiones puede utilizarse. La confianza entre atleta y cuerpo técnico depende también de que la vigilancia tecnológica mantenga límites transparentes, proporcionales y previamente acordados institucionalmente.

La personalización en tiempo real alcanza sentido cuando la velocidad de los datos mejora decisiones sin fragmentar la lógica del entrenamiento. Los dispositivos portátiles aportan continuidad observacional; el aprendizaje automático convierte señales en estimaciones y el entrenador determina cuándo intervenir. La combinación permite ajustar tareas ante respuestas relevantes mientras conserva objetivos previamente trazados. Más que perseguir una adaptación permanente, interesa construir una regulación selectiva, capaz de actuar oportunamente y permanecer silenciosa cuando la variación observada no lo requiere.

Tabla 4
Componentes de la personalización algorítmica de cargas y la prescripción adaptativa

Componente	Aplicación en la personalización del entrenamiento deportivo
Prescripción individualizada mediante aprendizaje automático	Emplea datos longitudinales del deportista para identificar patrones individuales de respuesta y orientar decisiones sobre la carga, considerando variabilidad fisiológica, rendimiento y tolerancia acumulada.
Ajuste dinámico de variables de entrenamiento	Regula volumen, intensidad, densidad y frecuencia mediante información actualizada, procurando mantener correspondencia entre exigencia programada, respuesta observada, recuperación y objetivos de preparación.
Sistemas de recomendación	Jerarquizan ejercicios, tareas y contenidos según necesidades individuales, características de las actividades, experiencia previa y propósitos deportivos, facilitando una selección metodológica pertinente.
Aprendizaje por refuerzo	Organiza la adaptación como una secuencia de decisiones relacionadas, donde las consecuencias de cada acción contribuyen al aprendizaje de políticas orientadas al rendimiento, la recuperación y la continuidad deportiva.
Gemelos digitales del deportista	Construyen representaciones computacionales actualizables que permiten simular respuestas individuales, contrastar escenarios de entrenamiento y valorar alternativas antes de trasladar determinadas decisiones a la práctica.

Componente	Aplicación en la personalización del entrenamiento deportivo
Personalización mediante dispositivos portátiles	Integra señales fisiológicas y mecánicas obtenidas durante la práctica para detectar variaciones relevantes y apoyar ajustes oportunos, bajo criterios de calidad de datos, pertinencia temporal y supervisión profesional.
Integración entrenador-algoritmo	Mantiene el criterio profesional como instancia responsable de interpretar recomendaciones, valorar incertidumbre, establecer límites de intervención y relacionar la información algorítmica con objetivos metodológicos y deportivos.
Orientación adaptativa integral	Articula datos, modelos predictivos, simulación, retroalimentación y decisiones humanas dentro de un proceso dinámico que busca responder a la trayectoria particular del deportista sin perder coherencia con la planificación.

Nota. La personalización algorítmica adquiere valor cuando las herramientas computacionales funcionan como apoyo para interpretar la respuesta individual y ajustar la prescripción de manera trazable, progresiva y compatible con el criterio profesional.

Capítulo V

Inteligencia artificial como sistema de apoyo a la decisión del entrenador

La dirección del entrenamiento deportivo siempre ha exigido decidir entre alternativas imperfectas. Cada jornada obliga a interpretar señales, ponderar riesgos y ajustar planes frente a respuestas humanas que rara vez obedecen por completo a lo previsto. La inteligencia artificial incorpora nuevas capacidades a dicha tarea, no para desplazar el juicio del entrenador, sino para ampliar la información disponible y enriquecer la deliberación. Su presencia modifica, ante todo, la manera de preguntar antes de intervenir sobre el deportista.

Durante años, buena parte de las decisiones se apoyó en observación, experiencia acumulada, pruebas periódicas y conversaciones dentro del equipo técnico. Tales recursos conservan plena vigencia, aunque ahora conviven con flujos continuos de datos y modelos capaces de reconocer relaciones difíciles de advertir mediante procedimientos convencionales. Pashaie et al. (2026) describen una evolución de las estrategias de entrenamiento mediadas por inteligencia artificial hacia mayores posibilidades de personalización, análisis y adaptación de la intervención deportiva.


La transformación no reside únicamente en disponer de más información. El verdadero cambio aparece cuando los datos pueden organizarse para responder preguntas relevantes acerca de carga, rendimiento, recuperación o continuidad del trabajo. Una cifra aislada dice poco; una relación bien interpretada puede modificar una decisión. Desde tal perspectiva, la inteligencia artificial adquiere valor cuando ayuda a convertir registros dispersos en conocimiento operativo, sin borrar la incertidumbre inherente al entrenamiento ni convertir predicciones probabilísticas en certezas metodológicas.

La amplitud de aplicaciones obliga, además, a considerar la relación entre rendimiento y bienestar del deportista. Munoz-Macho et al. (2024) documentan el empleo de inteligencia artificial en equipos de élite para analizar variables vinculadas tanto con desempeño como con atención sanitaria. Dicha convergencia

amplía las posibilidades de intervención, pero también demanda prudencia. Una recomendación relacionada con carga o disponibilidad física puede atravesar competencias profesionales diferentes y requerir acuerdos claros antes de traducirse en una modificación práctica.

Figura 13

IA como apoyo a la decisión del entrenador



A medida que las herramientas ganan capacidad generativa, el entrenador deja de interactuar únicamente con indicadores y predicciones. Puede solicitar alternativas de trabajo, reorganizar contenidos, formular consultas y revisar opciones mediante lenguaje natural. La relación con la tecnología adquiere

entonces un carácter más cercano al diálogo profesional. Ganaie et al. (2026), al examinar intervenciones de entrenamiento asistidas por inteligencia artificial, identifican efectos favorables sobre diversos indicadores de rendimiento, aunque la eficacia depende de una integración metodológica cuidadosamente planteada.

La posibilidad de generar planes adaptativos refuerza esa orientación hacia decisiones dinámicas. Connor et al. (2022) plantean el entrenamiento adaptativo desde sistemas inteligentes de control capaces de utilizar respuestas del atleta para reajustar la prescripción. La idea resulta especialmente fértil porque desplaza la atención desde una planificación rígida hacia ciclos de observación, valoración y ajuste. Sin embargo, adaptar no significa cambiar continuamente; requiere reconocer cuándo una variación aporta valor y cuándo conviene mantener el rumbo previamente definido.

Junto con la capacidad de recomendar aparece una exigencia inevitable: comprender de dónde proviene cada orientación. Cuando un sistema propone reducir una carga, modificar una tarea o advertir una tendencia, el entrenador necesita razones que pueda examinar y comunicar. La transparencia deja de ser una cualidad meramente informática y pasa a formar parte del trabajo profesional. Una recomendación comprensible permite contrastar evidencia, discutir alternativas y reconocer límites, mientras una respuesta opaca puede fomentar confianza injustificada o rechazo preventivo.

La creciente integración de fuentes informativas vuelve todavía más relevante dicha necesidad. Hliš et al. (2024) describen los gemelos digitales deportivos como representaciones capaces de articular datos diversos y modelar procesos asociados con el deportista. Tales desarrollos permiten pensar en entornos donde simulación, seguimiento y predicción convergen alrededor de decisiones cotidianas. Cuanto mayor sea la complejidad tecnológica, mayor deberá ser la capacidad humana para

reconstruir procedencias, identificar supuestos y valorar la pertinencia de cada resultado.

Por ello, la relación entre entrenador e inteligencia artificial no debería entenderse como una competencia por la autoridad decisional. Cada parte aporta capacidades diferentes. Los modelos procesan grandes volúmenes de información y detectan regularidades; las personas interpretan significados, reconocen matices y asumen responsabilidad por las consecuencias. Pashaie et al. (2026) vinculan la evolución del entrenamiento asistido con nuevas formas de personalización, una orientación que cobra sentido cuando la supervisión profesional permanece integrada durante todo el proceso.

Bajo esa perspectiva, el capítulo aborda la inteligencia artificial como una infraestructura de apoyo que necesita criterios deportivos, explicaciones comprensibles, supervisión humana y datos confiables para aportar verdadero valor. La cuestión ya no consiste en decidir entre experiencia o tecnología, sino en establecer una relación donde ambas contribuyan sin confundir funciones. Gobernar datos, validar herramientas y revisar recomendaciones completa dicha arquitectura, permitiendo que la innovación permanezca vinculada con responsabilidad profesional, aprendizaje continuo y bienestar del deportista.

5.1. Sistemas de apoyo a decisiones para la dirección del proceso de entrenamiento

Los sistemas de apoyo a decisiones aplicados al entrenamiento deportivo convierten grandes volúmenes de información en orientaciones útiles para la conducción cotidiana del proceso. Su valor reside en articular registros de carga, rendimiento, recuperación y respuesta individual dentro de una lectura operativa que acompañe el juicio profesional. La inteligencia artificial amplía esa capacidad al reconocer relaciones difíciles de advertir mediante observación convencional, sin

desplazar la responsabilidad del entrenador ni reducir la planificación a recomendaciones automáticas.

Dirigir el entrenamiento exige decidir bajo condiciones cambiantes, con información incompleta y márgenes temporales estrechos. Un sistema de apoyo puede ordenar señales procedentes de sesiones, pruebas, dispositivos y reportes del deportista, estableciendo prioridades para la intervención. Pashaie et al. (2026) describen una evolución del entrenamiento asistido por inteligencia artificial hacia esquemas más personalizados, donde el análisis continuo favorece ajustes vinculados con necesidades individuales y objetivos deportivos concretos de rendimiento, manteniendo al entrenador como referente decisional.

La utilidad de tales sistemas depende menos de acumular indicadores que de convertirlos en información útil. Un tablero saturado puede dificultar la dirección tanto como la ausencia de datos. Por ello, el diseño debe jerarquizar variables según su relevancia para el momento del ciclo de preparación y presentar relaciones entre carga, respuesta y rendimiento. La decisión adquiere calidad cuando el entrenador reconoce tendencias, contrasta antecedentes y comprende el grado de incertidumbre asociado a cada estimación.

En la práctica, el apoyo algorítmico puede intervenir antes, durante y después de una sesión. Antes, contribuye a valorar disposición y ajustar contenidos; durante, permite seguir respuestas frente a la carga prevista; después, facilita comparar resultados con objetivos y antecedentes. Munoz-Macho et al. (2024) señalan que la inteligencia artificial aplicada a equipos de élite integra análisis de rendimiento y salud, vínculo relevante cuando las decisiones de entrenamiento deben equilibrar adaptación deportiva, disponibilidad física y prevención.

Una dirección eficaz requiere distinguir entre información descriptiva, predictiva y prescriptiva. La primera muestra lo

ocurrido; la segunda estima comportamientos probables; la tercera propone cursos de acción bajo criterios. Confundir dichos niveles puede otorgar al sistema una autoridad que no posee. Las predicciones dependen de datos, mientras las recomendaciones incorporan supuestos sobre metas y restricciones. El entrenador necesita conocer diferencias para interpretar resultados con prudencia y decidir cuándo aceptar, modificar o descartar una propuesta algorítmica.

Otro aporte reside en sostener la individualización dentro de grupos numerosos. Dos deportistas sometidos a una carga semejante pueden responder de manera distinta por antecedentes, estado funcional, experiencia o tolerancia acumulada. Los modelos analíticos permiten detectar patrones personales y advertir desviaciones respecto de rangos habituales. Ganaie et al. (2026), mediante metaanálisis, examinan efectos del entrenamiento asistido por inteligencia artificial sobre el rendimiento deportivo, aportando evidencia para valorar su incorporación desde criterios de eficacia y pertinencia.

La calidad decisional también depende de la temporalidad. Una alerta tardía pierde su valor, mientras una advertencia demasiado sensible puede generar interrupciones innecesarias. Por ello, los sistemas deben calibrar umbrales, frecuencia de actualización y relevancia práctica de cada señal. La dirección del entrenamiento se beneficia cuando la información llega en el momento operativo adecuado y con una explicación suficiente para actuar. Tal equilibrio evita convertir la supervisión tecnológica en ruido permanente o en dependencia operativa.

La interacción entre entrenador y sistema adquiere importancia cuando aparecen recomendaciones divergentes respecto de la observación profesional. En lugar de tratar esa discrepancia como un error de una de las partes, conviene asumirla como oportunidad de revisión. Puede revelar datos defectuosos, cambios en el deportista o criterios de planificación no

representados por el modelo. Pashaie et al. (2026) destacan el potencial de la inteligencia artificial para enriquecer estrategias de entrenamiento mediante análisis adaptativos y personalizados.

La adopción institucional de un sistema de apoyo requiere protocolos que definan responsabilidades, calidad de datos y criterios de uso. No basta con adquirir una plataforma avanzada. Es necesario acordar quién registra, valida, interpreta y comunica la información, de establecer procedimientos ante valores atípicos o recomendaciones contradictorias. Munoz-Macho et al. (2024) muestran que las aplicaciones de inteligencia artificial en deporte de élite abarcan dimensiones diversas, circunstancia que demanda coordinación entre entrenamiento, medicina y ciencias aplicadas.

En consecuencia, un sistema de apoyo a decisiones alcanza madurez cuando mejora la capacidad del entrenador para formular preguntas, comparar alternativas y justificar intervenciones. Su aporte no radica en reemplazar experiencia, intuición o conocimiento situado, sino en ampliar la base informativa desde la cual se gobierna el proceso. La inteligencia artificial adquiere sentido cuando permanece vinculada a objetivos deportivos explícitos, criterios profesionales transparentes y evaluación continua de resultados, preservando una dirección flexible, reflexiva y responsable.

5.2. Inteligencia artificial generativa para el diseño y reajuste de sesiones deportivas

La inteligencia artificial generativa abre una vía particular para diseñar sesiones deportivas mediante la producción de propuestas estructuradas a partir de objetivos, cargas previstas, características del deportista y restricciones operativas. Su interés para el entrenador reside en transformar criterios de planificación en borradores susceptibles de revisión profesional. La herramienta puede combinar ejercicios, secuencias, pausas y progresiones, pero la pertinencia de cada decisión continúa dependiendo del

conocimiento técnico, la experiencia y la lectura humana del proceso.

Figura 14

Diseño adaptativo de sesiones mediante IA generativa



A diferencia de los sistemas centrados en clasificar o predecir, los modelos generativos producen contenidos nuevos mediante patrones aprendidos durante su entrenamiento computacional. Aplicados al deporte, permiten formular microestructuras de trabajo, variantes de tareas y distribuciones temporales con rapidez. Pashaie et al. (2026) describen una evolución de las estrategias de entrenamiento apoyadas por inteligencia artificial hacia mayores niveles de personalización, tendencia que favorece propuestas ajustadas a perfiles individuales sin convertir la automatización en autoridad metodológica.

El diseño de una sesión mediante inteligencia artificial generativa comienza con la calidad de las instrucciones proporcionadas. Objetivos ambiguos producen respuestas genéricas; criterios precisos permiten obtener propuestas más cercanas a las necesidades deportivas. Conviene especificar

propósito fisiológico o técnico, duración, nivel del atleta, momento de la temporada, recursos materiales y límites de carga. La formulación del encargo se convierte, por tanto, en una competencia ligada al razonamiento del entrenador y a su capacidad de planificación.

La generación automatizada adquiere mayor valor cuando funciona como punto de partida para comparar alternativas. Un entrenador puede solicitar distintas organizaciones de una sesión, contrastar densidades de trabajo o valorar variantes ante restricciones imprevistas. Connor et al. (2022) plantean la generación adaptativa de planes desde un enfoque de sistemas inteligentes de control, donde la información derivada de la respuesta del atleta permite reajustar la prescripción. Tal principio ofrece una base para diseños dinámicos y revisables.

El reajuste durante la práctica constituye una de las aplicaciones más prometedoras. Una sesión planificada puede requerir modificaciones por fatiga inesperada, cambios ambientales, disponibilidad reducida de instalaciones o respuestas alejadas del objetivo previsto. Frente a tales variaciones, un modelo generativo puede elaborar alternativas conservando la intención del trabajo. La rapidez resulta valiosa, aunque cada modificación debe pasar por el criterio del entrenador, quien valora riesgos, compatibilidad metodológica y consecuencias sobre las cargas posteriores del ciclo.

También resulta pertinente considerar la continuidad entre sesiones. Generar tareas atractivas de manera aislada carece de valor cuando rompe la lógica de progresión establecida. La inteligencia artificial debe operar con información sobre cargas previas, metas próximas, contenidos técnicos y necesidades de recuperación. Ganaie et al. (2026), al sintetizar evidencia sobre entrenamiento asistido por inteligencia artificial, encuentran efectos favorables sobre el rendimiento, aunque la aplicación

requiere interpretar resultados según características de programas, deportistas y modalidades deportivas.

La conversación iterativa con un modelo generativo permite refinar propuestas mediante indicaciones. El entrenador puede pedir menor volumen, mayor especificidad, otra distribución de pausas o una variante compatible con determinado material. Esa interacción convierte la generación en un proceso de edición razonada, no en una aceptación del primer resultado. Cada intercambio obliga a explicitar criterios que a veces permanecen implícitos en la práctica profesional, aportando una oportunidad para revisar la coherencia interna de la sesión.

Sin embargo, la fluidez verbal de una respuesta generada puede transmitir una apariencia de precisión superior a su fundamento. Una sesión bien redactada no necesariamente responde a principios adecuados de carga, aprendizaje motor o seguridad. Pashaie et al. (2026) destacan la capacidad de la inteligencia artificial para personalizar estrategias de entrenamiento, pero dicha capacidad demanda supervisión experta. Verificar intensidades, secuencias, recuperaciones y compatibilidad con objetivos protege al proceso frente a recomendaciones plausibles, aunque metodológicamente deficientes.

Desde una perspectiva, conviene integrar la generación de sesiones dentro de protocolos de revisión. El entrenador puede establecer criterios antes de aceptar una propuesta: correspondencia con el objetivo, adecuación de la carga, viabilidad logística, seguridad y continuidad con la planificación. Connor et al. (2022) vinculan la adaptación del entrenamiento con mecanismos de control capaces de responder a cambios del atleta. La generación cobra mayor sentido cuando participa en ciclos de observación, ajuste, ejecución y valoración.

La inteligencia artificial generativa aporta utilidad cuando amplía el repertorio de alternativas sin empobrecer la autonomía profesional. Diseñar y reajustar sesiones deja de ser una tarea apoyada únicamente en plantillas y puede convertirse en un diálogo entre experiencia, datos y generación computacional. El entrenador conserva la responsabilidad de decidir qué propuesta merece aplicarse, modificar sus componentes y valorar efectos. Bajo esa relación, la tecnología favorece creatividad metodológica, capacidad adaptativa y una planificación sensible al deportista.

5.3. Asistentes conversacionales especializados para consulta y seguimiento del entrenamiento

Los asistentes conversacionales especializados incorporan una interfaz lingüística al apoyo decisonal, permitiendo consultar información del entrenamiento mediante preguntas formuladas en lenguaje natural. Frente a paneles que exigen interpretar múltiples indicadores, la conversación facilita recuperar antecedentes, relacionar registros y solicitar explicaciones orientadas a una necesidad concreta. Su aportación cobra sentido cuando el diálogo permanece vinculado con datos fiables, criterios metodológicos definidos y propósitos deportivos explícitos, bajo la supervisión del entrenador responsable del proceso en cada jornada.

La especialización distingue a un asistente deportivo de un sistema conversacional general. Para responder con pertinencia necesita manejar terminología de la disciplina, principios de planificación, características de las cargas y registros propios del deportista. Pashaie et al. (2026) describen una creciente personalización de las estrategias de entrenamiento mediadas por inteligencia artificial. Desde esa perspectiva, la conversación puede acercar conocimiento analítico y experiencia práctica, siempre que las respuestas respeten límites profesionales y fuentes validadas e individuales.

Durante la consulta cotidiana, el entrenador puede interrogar al asistente acerca de tendencias, antecedentes o relaciones entre variables sin revisar manualmente cada registro. Preguntas sobre variaciones de carga, cumplimiento de objetivos o respuestas individuales adquieren una estructura dialogada que favorece consultas sucesivas. La utilidad no reside en conversar por conversar, sino en reducir fricciones para acceder a información pertinente. Cada respuesta debería permitir rastrear su procedencia y distinguir hechos registrados, inferencias analíticas y orientaciones prácticas.

El seguimiento longitudinal amplía esa función porque permite mantener continuidad entre observaciones separadas por días o semanas. Un asistente configurado puede recuperar acuerdos previos, resumir cambios relevantes y señalar discrepancias entre lo planificado y lo ejecutado. Munoz-Macho et al. (2024) documentan aplicaciones de inteligencia artificial que articulan información sobre rendimiento y salud en equipos de élite. Tal convergencia favorece consultas integradoras, aunque exige delimitar competencias cuando intervienen datos sensibles o decisiones clínicas del ámbito deportivo.

La conversación también puede servir para registrar percepciones difíciles de representar mediante sensores. Comentarios sobre esfuerzo, confianza, molestias, disposición o calidad percibida de una tarea aportan matices que enriquecen el seguimiento. El asistente puede organizar tales expresiones y relacionarlas con registros cuantitativos, evitando tratarlas como equivalentes. Para el entrenador, escuchar mediante una interfaz digital no reemplaza el diálogo humano; ofrece otra vía para conservar información que, por su carácter cotidiano, suele dispersarse fácilmente en ocasiones.

Una ventaja operativa aparece cuando el asistente adapta la profundidad de la respuesta a la pregunta planteada. Ante una consulta rápida puede recuperar un dato puntual; frente a una

revisión semanal puede sintetizar patrones y contrastar periodos. Ganaie et al. (2026) encuentran resultados favorables del entrenamiento asistido por inteligencia artificial sobre diferentes indicadores de rendimiento. Esa evidencia respalda su utilidad potencial, pero no autoriza atribuir beneficios automáticos a cualquier herramienta conversacional empleada sin evaluación específica.

La calidad del intercambio depende de que el entrenador formule preguntas capaces de orientar respuesta útil. Consultas vagas favorecen generalidades; preguntas delimitadas por objetivo, periodo, deportista y variable permiten análisis más pertinentes. Con el uso continuado, el diálogo puede adquirir una lógica acumulativa: una pregunta abre otra, una anomalía conduce a revisar antecedentes y una explicación invita a contrastar registros. Esa dinámica convierte la consulta en razonamiento asistido, siempre sujeto a verificación antes de intervenir.

También deben reconocerse los riesgos propios de una interfaz que responde con fluidez y aparente seguridad. Un asistente puede interpretar incorrectamente una pregunta, recuperar información incompleta o construir explicaciones sin respaldo suficiente. Pashaie et al. (2026) resaltan posibilidades amplias de personalización mediante inteligencia artificial, pero la aplicación deportiva requiere preservar la intervención profesional. Conviene, por ello, exigir trazabilidad, indicar niveles de incertidumbre y establecer mecanismos para corregir respuestas cuando la evidencia documentada disponible resulte insuficiente.

El seguimiento conversacional plantea exigencias relacionadas con privacidad, gobernanza y acceso a la información. Los registros deportivos pueden contener datos personales, valoraciones internas y referencias vinculadas con la salud. Determinar quién consulta, qué información recibe y durante cuánto tiempo se conserva forma parte del diseño responsable. Munoz-Macho et al. (2024) muestran la proximidad creciente entre

análisis de rendimiento y atención sanitaria, relación que obliga a establecer fronteras claras para proteger al deportista y al equipo.

Integrado con criterio, el asistente conversacional funciona como una puerta de acceso al conocimiento acumulado durante el entrenamiento. Su valor aumenta cuando permite preguntar, recuperar, contrastar y documentar sin interrumpir la dinámica de trabajo. La conversación tecnológica adquiere entonces un carácter instrumental: ayuda a mantener continuidad, hacer visibles cambios relevantes y fundamentar intercambios entre profesionales. La decisión permanece en manos del entrenador, cuya experiencia convierte las respuestas del sistema en acciones prudentes, justificadas y pertinentes.

5.4. Explicabilidad y trazabilidad de recomendaciones algorítmicas en contextos deportivos

La explicabilidad adquiere relevancia cuando una recomendación algorítmica interviene en decisiones que modifican cargas, recuperaciones o prioridades de entrenamiento. No basta recibir una indicación técnicamente plausible; el entrenador necesita comprender qué variables influyeron, qué relaciones detectó el modelo y bajo qué grado de incertidumbre opera. Esa comprensión permite valorar la recomendación frente al conocimiento profesional, discutirla con otros especialistas y reconocer cuándo una respuesta automatizada merece confianza, revisión adicional o rechazo razonado antes de aplicarla.

Explicar una recomendación no equivale a describir íntegramente la arquitectura matemática que la produce. En la práctica deportiva interesa ofrecer razones inteligibles y vinculadas con la decisión: variaciones recientes de carga, tendencias fisiológicas, antecedentes de rendimiento o combinaciones relevantes entre indicadores. Pashaie et al. (2026) destacan que la inteligencia artificial favorece estrategias de entrenamiento más personalizadas. Tal personalización gana legitimidad cuando el

entrenador puede reconocer las bases informativas que orientan cada propuesta generada por algoritmos.

La trazabilidad complementa la explicación mediante la reconstrucción del camino seguido desde los datos hasta la recomendación. Implica conocer fuentes, fechas de registro, transformaciones realizadas, versión del modelo y criterios empleados para producir una salida determinada. En deporte, donde las decisiones pueden revisarse semanas después, conservar dicho rastro facilita distinguir entre cambios atribuibles al atleta y variaciones derivadas del sistema. También permite auditar errores, comparar decisiones previas y documentar responsabilidades dentro del equipo técnico multidisciplinario.

Una explicación útil debe guardar proporción con la relevancia de la decisión. Ajustar un ejercicio menor requiere menos detalle que modificar una carga semanal por una alerta relacionada con disponibilidad física. Munoz-Macho et al. (2024) describen aplicaciones inteligentes directamente vinculadas tanto al rendimiento como a la salud en equipos de élite. Cuando ambas dimensiones convergen, comprender el fundamento de una recomendación adquiere mayor importancia por las consecuencias deportivas y humanas asociadas a su aplicación práctica.

Los métodos explicativos pueden mostrar variables influyentes, comparar escenarios alternativos o indicar cuánto cambiaría una recomendación ante modificaciones concretas de los datos. Para el entrenador, tales recursos resultan valiosos cuando traducen operaciones computacionales en preguntas cercanas a la práctica: qué factor inclinó la decisión, qué registro alteró la estimación o qué condición produciría otra respuesta. La explicación deja entonces de funcionar como adorno técnico y pasa a respaldar una deliberación profesional informada, verificable y compartida.

La incorporación de gemelos digitales amplía las exigencias de trazabilidad porque las representaciones virtuales del deportista pueden integrar datos procedentes de múltiples fuentes y actualizarse continuamente. Hliš et al. (2024) analizan el potencial deportivo de tales sistemas y destacan su capacidad para representar procesos mediante estructuras digitales dinámicas. Cuanto mayor sea la integración informativa, mayor resulta la necesidad de registrar procedencia, transformaciones y supuestos empleados antes de convertir una simulación en orientación para el entrenamiento.

Figura 15
Explicabilidad y trazabilidad de decisiones algorítmicas



También conviene reconocer que una explicación comprensible puede ser incompleta. Simplificar demasiado corre el riesgo de ocultar interacciones relevantes, mientras una descripción excesivamente técnica puede resultar inútil durante la toma de decisiones. El diseño debe buscar un equilibrio entre fidelidad al modelo y comprensión. Una opción consiste en ofrecer niveles progresivos de detalle: primero la razón principal, luego variables asociadas y, cuando sea necesario, información

metodológica que permita examinar con mayor profundidad la recomendación recibida.

La trazabilidad adquiere además una dimensión colectiva. Preparadores físicos, entrenadores, médicos y analistas pueden interpretar una misma señal desde perspectivas diferentes, por lo que disponer de un registro común ayuda a reconstruir decisiones y evitar versiones contradictorias. Munoz-Macho et al. (2024) muestran que la inteligencia artificial aplicada al deporte de élite atraviesa áreas de rendimiento y atención sanitaria. Documentar quién consultó, interpretó y autorizó una recomendación fortalece la coordinación sin diluir responsabilidades profesionales individuales claramente.

La confianza merece atención particular. Un sistema transparente no debe aspirar a que el entrenador acepte todas sus respuestas, sino a permitir una evaluación informada de sus límites. Pashaie et al. (2026) vinculan la evolución del entrenamiento asistido por inteligencia artificial con posibilidades de personalización y análisis. Para que tal desarrollo resulte defendible, conviene acompañar recomendaciones con evidencia accesible, incertidumbre estimada y registros que permitan identificar por qué una orientación cambió entre dos momentos comparables.

Explicabilidad y trazabilidad convierten la recomendación algorítmica en un objeto susceptible de examen, discusión y aprendizaje profesional. Cuando el entrenador puede reconstruir su origen, entender sus razones y contrastar sus límites, la tecnología participa en la decisión sin adquirir una autoridad opaca. Hliš et al. (2024) permiten advertir que sistemas deportivos crecientemente complejos demandan representaciones y relaciones informativas bien definidas. La transparencia operativa además favorece decisiones justificables, continuidad metodológica y una responsabilidad humana claramente reconocible.

5.5. Interacción entrenador-IA y modelos de decisión con supervisión humana

La interacción entre entrenador e inteligencia artificial alcanza mayor sentido cuando ambas capacidades ocupan funciones diferenciadas dentro de la decisión deportiva. Los algoritmos pueden procesar información, detectar regularidades y producir alternativas con rapidez; el entrenador aporta experiencia, conocimiento del deportista, interpretación situacional y responsabilidad profesional. La supervisión humana articula ambas dimensiones mediante un principio sencillo: ninguna recomendación adquiere valor por proceder de un modelo, sino por superar una valoración razonada antes de orientar cualquier intervención práctica relevante.

Los modelos con supervisión humana distribuyen la decisión entre distintos grados de automatización. Algunas operaciones pueden ejecutarse rutinariamente, mientras otras requieren confirmación profesional antes de producir cambios sobre el entrenamiento. Pashaie et al. (2026) describen una transformación de las estrategias de entrenamiento mediante inteligencia artificial orientada hacia mayor personalización y capacidad analítica. Esa evolución invita a definir con precisión qué decisiones pueden delegarse, cuáles requieren validación y cuáles deben permanecer bajo responsabilidad directa del entrenador.

La supervisión adquiere especial importancia cuando una recomendación contradice la observación del entrenador. En lugar de privilegiar automáticamente una fuente, la discrepancia puede convertirse en motivo de indagación: revisar datos, examinar antecedentes, conversar con el deportista o consultar a otros profesionales. La interacción productiva nace precisamente de esa tensión. Un algoritmo puede advertir patrones inadvertidos, mientras la experiencia humana reconoce circunstancias difíciles

de representar numéricamente. Decidir implica entonces contrastar evidencias antes de modificar la intervención prevista.

La evidencia disponible respalda el interés por combinar capacidades humanas y computacionales sin confundir asistencia con sustitución profesional. Ganaie et al. (2026), mediante una revisión sistemática y metaanálisis, identifican efectos favorables asociados al entrenamiento asistido por inteligencia artificial en diferentes medidas de rendimiento. Sin embargo, trasladar tales resultados a la práctica exige considerar características del deportista, modalidad, programa aplicado y calidad de la intervención. La supervisión permite convertir resultados generales en decisiones particulares prudentes y justificadas.

Un modelo de interacción bien diseñado debe determinar momentos de intervención humana. Puede requerirse aprobación ante modificaciones relevantes de carga, alertas vinculadas con bienestar, cambios en objetivos o recomendaciones que excedan rangos previamente acordados. Para decisiones rutinarias, bastará una revisión periódica. Tal graduación evita dos extremos: controlar manualmente cada operación, anulando ventajas de automatización, o delegar demasiado, debilitando la responsabilidad profesional. La autonomía algorítmica debe guardar proporción con riesgo, incertidumbre y consecuencias previsibles para cada deportista.

La decisión deportiva rara vez pertenece a una persona aislada. Preparadores físicos, médicos, fisioterapeutas, analistas y entrenadores pueden participar desde competencias distintas. Munoz-Macho et al. (2024) documentan una presencia creciente de inteligencia artificial tanto en análisis del rendimiento como en aplicaciones relacionadas con la salud de deportistas de élite. Cuando una recomendación atraviesa varias áreas, la supervisión humana necesita reglas de coordinación que permitan identificar quién interpreta, quién valida y quién posee autoridad para intervenir operativamente.

La interacción también transforma la competencia profesional del entrenador. Ya no basta conocer métodos de entrenamiento; resulta necesario interpretar resultados algorítmicos, formular consultas precisas, reconocer incertidumbre y detectar respuestas incompatibles con principios deportivos. Tal alfabetización no convierte al entrenador en especialista informático. Le permite dialogar críticamente con sistemas cada vez más presentes. Pashaie et al. (2026) relacionan la evolución del entrenamiento asistido por inteligencia artificial con nuevas posibilidades de personalización, análisis y adaptación de estrategias deportivas contemporáneas.

La supervisión humana requiere, además, capacidad para interrumpir o corregir el funcionamiento algorítmico. Si aparecen datos defectuosos, recomendaciones repetidamente inadecuadas o cambios relevantes en las condiciones de preparación, el entrenador debe poder detener una automatización y revisar sus parámetros. Tal facultad representa una forma concreta de control profesional. Mantener registros de intervenciones humanas permite también aprender de discrepancias, identificar fallos recurrentes y mejorar progresivamente los criterios mediante los cuales sistema y entrenador distribuyen sus respectivas tareas.

La calidad de la relación entrenador-IA puede evaluarse mediante resultados, pero también observando el proceso decisonal. Importa conocer si las recomendaciones fueron comprendidas, qué porcentaje recibió modificaciones, por qué fueron rechazadas y qué consecuencias tuvieron las decisiones adoptadas. Ganaie et al. (2026) aportan evidencia favorable sobre intervenciones asistidas por inteligencia artificial, aunque la eficacia práctica depende de su integración metodológica. Evaluar la interacción permite evitar que una herramienta permanezca incorporada únicamente por novedad tecnológica o conveniencia operativa.

La supervisión humana configura, en suma, una relación donde inteligencia artificial y entrenador participan desde capacidades complementarias sin compartir idéntica responsabilidad. El sistema calcula, organiza y anticipa; la persona interpreta, pondera consecuencias y responde por la decisión. Tal distribución preserva la autonomía profesional mientras aprovecha recursos analíticos avanzados. En el entrenamiento deportivo, la inteligencia artificial adquiere verdadero valor cuando amplía la deliberación del entrenador, fortalece decisiones justificadas y permanece subordinada al bienestar y desarrollo integral del deportista.

5.6. Gobernanza del dato y validación de sistemas de IA aplicados al entrenamiento deportivo

La gobernanza del dato constituye la base que permite utilizar inteligencia artificial con criterios verificables dentro del entrenamiento deportivo. Define responsabilidades sobre captura, almacenamiento, acceso, transformación y eliminación de registros, evitando que la tecnología desplace preguntas sobre calidad y legitimidad. Cuando un algoritmo participa en decisiones deportivas, conocer el origen de la información resulta tan importante como interpretar su resultado. Datos deficientes pueden producir recomendaciones convincentes, aunque carezcan de fundamento para orientar la práctica profesional.

Gobernar datos implica acordar qué variables merecen registrarse, con qué frecuencia y mediante qué procedimientos. Acumular mediciones sin propósito definido incrementa complejidad y puede introducir inconsistencias difíciles de detectar. Munoz-Macho et al. (2024) describen una amplia utilización de inteligencia artificial para analizar rendimiento y salud en equipos de élite. Tal amplitud vuelve necesario establecer criterios comunes de calidad, interoperabilidad y acceso, especialmente cuando diferentes profesionales alimentan o

consultan una misma infraestructura informativa durante la temporada.

La calidad del dato depende de dimensiones que deben vigilarse desde su captura: precisión, completitud, consistencia, actualidad y representatividad. Un sensor mal calibrado, una sesión registrada de manera incompleta o categorías utilizadas con criterios variables pueden alterar el aprendizaje del modelo. Por ello, la gobernanza requiere controles periódicos y mecanismos de corrección documentados. La confianza algorítmica comienza mucho antes del entrenamiento computacional; nace en prácticas cotidianas de registro que suelen parecer menores al equipo técnico.

La procedencia de los datos adquiere mayor relevancia cuando varias tecnologías convergen en una representación digital del deportista. Hliš et al. (2024) analizan los gemelos digitales en deporte como estructuras capaces de integrar información diversa para modelar procesos y apoyar aplicaciones prácticas. Una arquitectura semejante demanda reglas para identificar fuentes, sincronizar mediciones y conservar metadatos. Sin tales garantías, la integración puede multiplicar errores en lugar de ofrecer una representación útil para orientar decisiones de entrenamiento.

Junto con la calidad aparece la gestión del acceso. Los datos deportivos pueden revelar rendimiento, hábitos, percepciones personales y variables relacionadas con la salud, por lo que no todos los integrantes de una organización necesitan nivel de consulta. Definir permisos según funciones reduce exposiciones innecesarias y facilita atribuir responsabilidades. También conviene establecer periodos de conservación, procedimientos de anonimización y criterios para compartir información con proveedores tecnológicos, investigadores u organizaciones externas sin debilitar derechos del deportista.

La validación comienza cuando se pregunta si un sistema mide, clasifica o predice aquello para lo cual será utilizado. Una precisión elevada durante el desarrollo no garantiza rendimiento equivalente ante nuevos deportistas, temporadas o modalidades. Pashaie et al. (2026) destacan posibilidades de personalización derivadas de la inteligencia artificial en las estrategias de entrenamiento. Validar exige comprobar que las recomendaciones mantienen utilidad cuando cambian perfiles individuales, condiciones de aplicación y características específicas de la preparación deportiva.

Conviene distinguir validación técnica de validación aplicada. La primera examina métricas del modelo, estabilidad, errores y capacidad de generalización; la segunda determina si sus resultados aportan valor dentro de decisiones deportivas reales. Un algoritmo puede mostrar buen desempeño predictivo y, pese a ello, ofrecer poca utilidad para modificar una sesión o gestionar una carga. La prueba práctica debe valorar relevancia, oportunidad, comprensión profesional y consecuencias derivadas de utilizar la recomendación durante periodos suficientemente representativos amplios.

La validación tampoco concluye cuando una herramienta entra en funcionamiento. Los patrones del entrenamiento cambian por modificaciones metodológicas, incorporación de deportistas, nuevos dispositivos o variaciones en los procedimientos de registro. Munoz-Macho et al. (2024) muestran la diversidad de aplicaciones inteligentes presentes en deporte de alto rendimiento, diversidad que exige vigilancia continuada. Comparar predicciones con resultados observados permite detectar degradación del modelo y decidir cuándo recalibrar, reentrenar o retirar una herramienta que perdió utilidad práctica comprobable.

La documentación conecta gobernanza y validación mediante un registro común de decisiones técnicas. Debe permitir conocer versiones del modelo, conjuntos de datos utilizados,

criterios de exclusión, métricas obtenidas, modificaciones realizadas y responsables de cada revisión. Hliš et al. (2024) destacan la complejidad asociada con arquitecturas digitales deportivas que integran múltiples componentes informativos. Documentar cada cambio facilita auditorías y evita que el conocimiento sobre funcionamiento, limitaciones y dependencias permanezca concentrado en personas dentro de la organización.

Una política madura de gobernanza y validación convierte la inteligencia artificial en una infraestructura sometida a revisión, no en una adquisición tecnológica aceptada por prestigio o novedad. La calidad de los datos, la protección del deportista y la evaluación deben acompañar toda aplicación durante su vida útil. Bajo ese marco, el entrenador recibe herramientas cuyo rendimiento ha sido comprobado y cuyos límites pueden reconocerse, favoreciendo decisiones responsables, aprendizaje institucional y confianza profesional en evidencia verificable.

Tabla 5
Componentes de la inteligencia artificial como sistema de apoyo a la decisión del entrenador

Componente del capítulo	Aporte a la dirección del entrenamiento deportivo
Sistemas de apoyo a decisiones	Integran datos de carga, rendimiento, recuperación y respuesta individual para transformar registros dispersos en información útil. Favorecen la comparación de alternativas y respaldan el juicio profesional ante decisiones relacionadas con la planificación y regulación del entrenamiento.
IA generativa para sesiones deportivas	Facilita la elaboración y reajuste de sesiones mediante propuestas adaptables a objetivos, características del deportista, disponibilidad de recursos y restricciones operativas. Su utilidad depende de instrucciones precisas y de una revisión metodológica realizada por el entrenador.

Asistentes conversacionales especializados	Permiten consultar registros, recuperar antecedentes y mantener seguimiento longitudinal mediante lenguaje natural. La interacción conversacional reduce fricciones en el acceso a información y facilita relacionar datos cuantitativos con percepciones del deportista, preservando la responsabilidad profesional sobre las decisiones adoptadas.
Explicabilidad y trazabilidad algorítmica	Permiten comprender las razones que sustentan una recomendación y reconstruir su procedencia desde los datos hasta la respuesta producida. Favorecen la evaluación crítica, la auditoría de decisiones y la identificación de incertidumbres, errores o modificaciones en los modelos utilizados.
Interacción entrenador-IA	Articula capacidades computacionales y juicio profesional mediante esquemas de supervisión humana. Los algoritmos procesan información y generan alternativas, mientras el entrenador interpreta implicaciones, contrasta evidencias y conserva autoridad sobre decisiones que afectan la preparación y el bienestar del deportista.
Gobernanza del dato y validación	Establece criterios para calidad, acceso, almacenamiento, protección y utilización de información deportiva. La validación técnica y aplicada permite comprobar precisión, generalización y utilidad práctica de los sistemas, junto con mecanismos de vigilancia capaces de detectar pérdida de rendimiento durante su utilización.

Nota. La tabla organiza los principales componentes desarrollados en el capítulo y muestra su articulación dentro de un modelo de apoyo a la decisión donde la inteligencia artificial amplía las capacidades analíticas y operativas, mientras el entrenador mantiene la supervisión y responsabilidad profesional.

Conclusiones

La inteligencia artificial aplicada al entrenamiento deportivo confirma su valor cuando transforma registros dispersos en información pertinente para orientar decisiones profesionales. Su aporte depende de la calidad de los datos, de la correspondencia entre variables y objetivos, y de una interpretación vinculada con principios del entrenamiento. La planificación gana capacidad adaptativa cuando incorpora respuestas individuales, evolución temporal y metas de rendimiento, permitiendo reajustes razonados que superan esquemas rígidos y favorecen intervenciones más precisas, coherentes y evaluables.

Respecto de las variables necesarias para construir modelos útiles, la evidencia examinada permite reconocer una integración prioritaria de carga interna, carga externa, rendimiento, recuperación, sueño, percepción del esfuerzo, indicadores fisiológicos y características biomecánicas. Ninguna variable posee valor explicativo permanente por sí misma. La utilidad predictiva proviene de relaciones temporales e individuales, por lo que cada sistema requiere selección cuidadosa de indicadores, depuración de registros y actualización periódica conforme evoluciona el deportista durante ciclos sucesivos de preparación competitiva.

La predicción de fatiga, recuperación y disponibilidad representa una aplicación especialmente relevante para regular el entrenamiento. Los algoritmos pueden identificar patrones difíciles de advertir mediante observación aislada, pero sus resultados deben interpretarse como estimaciones probabilísticas sujetas a variabilidad biológica. Una predicción adquiere utilidad cuando facilita decidir entre mantener, reducir o modificar una carga. La combinación de series temporales, respuestas subjetivas y mediciones objetivas permite construir perfiles individuales con mayor sensibilidad ante cambios del estado funcional diario.

La visión artificial y los dispositivos portátiles amplían notablemente la capacidad de registrar movimiento, carga y respuestas fisiológicas durante la práctica deportiva. Su precisión, sin embargo, varía según tecnología, tarea motriz, calidad de captura y procedimiento analítico. Por ello, la adopción de herramientas digitales requiere validación previa frente a medidas de referencia y condiciones reales de uso. El valor tecnológico reside en producir información suficientemente fiable para complementar evaluaciones biomecánicas, técnicas y fisiológicas sin convertir la medición automatizada en criterio absoluto.

La personalización algorítmica de las cargas constituye una evolución significativa frente a prescripciones basadas predominantemente en promedios grupales. Modelos entrenados con trayectorias individuales pueden relacionar dosis, respuesta y recuperación para recomendar ajustes de volumen, intensidad, densidad o frecuencia. La personalización exige continuidad en el registro y criterios deportivos explícitos. Cuando ambas condiciones se cumplen, los sistemas inteligentes favorecen programas sensibles a diferencias entre atletas y permiten revisar decisiones conforme aparecen nuevas respuestas durante la preparación y la competencia.

Los sistemas de recomendación, el aprendizaje por refuerzo y los gemelos digitales amplían las posibilidades de prescripción adaptativa mediante simulación y aprendizaje continuo. Tales recursos permiten comparar alternativas antes de intervenir, estimar consecuencias probables y ajustar decisiones según resultados previos. Su desarrollo académico requiere prudencia metodológica. Una representación digital nunca equivale plenamente al deportista real, porque toda modelización selecciona variables y simplifica relaciones; por ello, la simulación debe funcionar como apoyo analítico dentro de procesos profesionales supervisados.

La relación entre predicción algorítmica y experiencia profesional conduce a una conclusión central: la inteligencia artificial alcanza mayor utilidad cuando complementa el juicio del entrenador. La experiencia aporta interpretación situacional, conocimiento interpersonal, lectura táctica y comprensión de circunstancias difíciles de formalizar. El algoritmo aporta capacidad para procesar grandes volúmenes de información y reconocer regularidades. La integración de ambas capacidades favorece decisiones trazables, discutibles y revisables, donde la recomendación computacional permanece sometida a valoración humana y responsabilidad profesional.

La explicabilidad adquiere relevancia académica y práctica porque una recomendación carente de razones comprensibles limita la confianza y dificulta su evaluación. Entrenadores y equipos interdisciplinarios necesitan conocer qué variables influyeron en una predicción, con qué grado de incertidumbre y bajo qué condiciones fue generado el resultado. La trazabilidad permite reconstruir decisiones y detectar errores. Por ello, transparencia, documentación y supervisión humana deben incorporarse desde el diseño de cualquier sistema destinado a intervenir en planificación o regulación deportiva.

Desde una perspectiva investigativa, el campo requiere diseños longitudinales, muestras deportivas diversas y comparaciones entre modelos que permitan establecer validez, generalización y utilidad práctica. Resulta necesario diferenciar precisión estadística de relevancia deportiva. Un algoritmo puede alcanzar métricas elevadas y aportar poco a una decisión concreta. La investigación futura deberá valorar beneficios sobre rendimiento, recuperación y calidad de la planificación, junto con sesgos, privacidad, reproducibilidad y estabilidad de los modelos cuando cambian atletas, temporadas, dispositivos o modalidades competitivas.

En conjunto, la inteligencia artificial ofrece una vía rigurosa para enriquecer la planificación, interpretar el rendimiento, anticipar estados de fatiga y personalizar cargas, siempre que permanezca vinculada con conocimiento científico y criterio profesional. El progreso tecnológico adquiere sentido cuando mejora decisiones y respeta la singularidad del deportista. La meta consiste en ampliar la capacidad analítica del entrenador sin desplazar su responsabilidad. Datos, modelos y experiencia pueden conformar una práctica deportiva más precisa, reflexiva, verificable y responsable.

Referencias Bibliográficas

- Badiola-Bengoia, A., & Mendez-Zorrilla, A. (2021). A systematic review of the application of camera-based human pose estimation in the field of sport and physical exercise. *Sensors*, 21(18), Article 5996. <https://doi.org/10.3390/s21185996>
- Connor, M., Beato, M., & O'Neill, M. (2022). Adaptive athlete training plan generation: An intelligent control systems approach. *Journal of Science and Medicine in Sport*, 25(4), 351–355. <https://doi.org/10.1016/j.jsams.2021.10.011>
- Cordeiro, M. C., Cathain, C. O., Daly, L., Kelly, D. T., & Rodrigues, T. B. (2025). A synthetic data-driven machine learning approach for athlete performance attenuation prediction. *Frontiers in Sports and Active Living*, 7, Article 1607600. <https://doi.org/10.3389/fspor.2025.1607600>
- Cui, J., Du, H., & Wu, X. (2023). Data analysis of physical recovery and injury prevention in sports teaching based on wearable devices. *Preventive Medicine*, 173, Article 107589. <https://doi.org/10.1016/j.ypmed.2023.107589>
- de Leeuw, A.-W., van der Zwaard, S., van Baar, R., & Knobbe, A. (2022). Personalized machine learning approach to injury monitoring in elite volleyball players. *European Journal of Sport Science*, 22(4), 511–520. <https://doi.org/10.1080/17461391.2021.1887369>
- Fukushima, T., Blauburger, P., Guedes Russomanno, T., & Lames, M. (2024). The potential of human pose estimation for motion capture in sports: A validation study. *Sports Engineering*, 27, Article 19. <https://doi.org/10.1007/s12283-024-00460-w>
- Ganaie, M. U. D., Shah, M. M., Awan, A. M., Ganaie, M. M., Kousar, T., Nissa, B., & Tomar, R. (2026). Effect of artificial intelligence-assisted coaching on sports performance: A systematic review and meta-analysis. *Journal of Human Sport and Exercise*. <https://doi.org/10.55860/vjqgvm08>
- Hliš, T., Fister, I., & Fister, I., Jr. (2024). Digital twins in sport: Concepts, taxonomies, challenges and practical potentials. *Expert Systems with Applications*, 258, Article 125104. <https://doi.org/10.1016/j.eswa.2024.125104>
- Li, S., & Zhang, W. (2022). Evaluation method of basketball teaching and training effect based on wearable device. *Frontiers in Physics*, 10, Article 900169. <https://doi.org/10.3389/fphy.2022.900169>

- Lukač, L., Fister, I., Jr., & Fister, I. (2022). Digital twin in sport: From an idea to realization. *Applied Sciences*, 12(24), Article 12741. <https://doi.org/10.3390/app122412741>
- Majumdar, A., Bakirov, R., Hodges, D., McCullagh, S., & Rees, T. (2024). A multi-season machine learning approach to examine the training load and injury relationship in professional soccer. *Journal of Sports Analytics*. <https://doi.org/10.3233/JSA-240718>
- Mandorino, M., Tessitore, A., Leduc, C., Persichetti, V., Morabito, M., & Lacome, M. (2023). A new approach to quantify soccer players' readiness through machine learning techniques. *Applied Sciences*, 13(15), Article 8808. <https://doi.org/10.3390/app13158808>
- Munoz-Macho, A. A., Domínguez-Morales, M. J., & Sevillano-Ramos, J. L. (2024). Performance and healthcare analysis in elite sports teams using artificial intelligence: A scoping review. *Frontiers in Sports and Active Living*, 6, Article 1383723. <https://doi.org/10.3389/fspor.2024.1383723>
- Pashaie, S., Mohammadi, S., & Golmohammadi, H. (2026). Unlocking athlete potential: The evolution of coaching strategies through artificial intelligence. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, 240(3), 666–685. <https://doi.org/10.1177/17543371241300889>
- Teixeira, J. E., Encarnação, S., Branquinho, L., Ferraz, R., Portella, D. L., Monteiro, D., Morgans, R., Barbosa, T. M., Monteiro, A. M., & Forte, P. (2024). Classification of recovery states in U15, U17, and U19 sub-elite football players: A machine learning approach. *Frontiers in Psychology*, 15, Article 1447968. <https://doi.org/10.3389/fpsyg.2024.1447968>
- Xia, X., Chen, Q., & Wang, Z. (2025). Deep reinforcement learning-driven personalized training load control algorithm for competitive sports performance optimization. *Scientific Reports*, 16, Article 845. <https://doi.org/10.1038/s41598-025-30453-z>



Red de Investigación
Científica y Desarrollo
Tecnológico **Del Pacífico**

“Datos, conocimiento
y experiencia humana
para un entrenamiento más
**preciso, individualizado
y con mayor impacto** en
el rendimiento deportivo.”


EDITORIAL
SAGA

ISBN: 978-9907-803-74-7

