



Departamento de Posgrado en Ingeniería e Innovación
CETYS UNIVERSIDAD

Título de Tesis

APLICACIÓN DE MODELOS LSTM Y LLM PARA LA ESTIMACIÓN Y
MEJORA DE LA ECONOMÍA DE CARRERA

Que para obtener el grado de
MAESTRÍA EN INGENIERÍA E INNOVACIÓN

Presenta:

José Luis Pasarin Ibarra

Director de Tesis:
Dr. Ulises Orozco Rosas
Co-Director de Tesis:
Dra. Kenia Picos Espinoza

Tijuana, Baja California, México, a 18 de Marzo de 2026.



ACTA DE REVISIÓN DE TESIS

En la ciudad de Tijuana, Baja California siendo el día 18 de marzo del 2026 se reunieron los miembros del Comité de Revisión de Tesis designada en el Departamento de Posgrado de CETYS Universidad Campus Tijuana para examinar la tesis titulada:

APLICACIÓN DE MODELOS LSTM Y LLM PARA LA ESTIMACIÓN Y MEJORA DE LA ECONOMÍA DE CARRERA

Tesis para obtener el grado académico de la Maestría en Ingeniería e Innovación, presentada por el alumno:

José Luis Pasarín Ibarra

Los miembros del Comité de Revisión de Tesis manifestaron **APROBAR LA TESIS**, en virtud que satisface con los requisitos establecidos por el Reglamento de Posgrado.

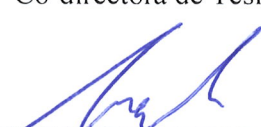
COMITÉ DE TESIS



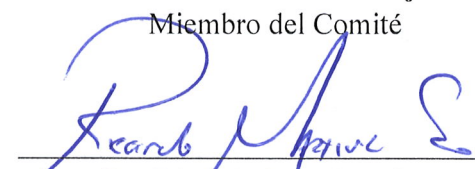
Dr. Ulises Orozco Rosas
Director de Tesis



Dra. Kenia Picos Espinoza
Co-directora de Tesis



Dr. Adán Hiraless Carbajal
Miembro del Comité



Dr. Ricardo Martínez Soto
Coordinador del Posgrado en Ingeniería
Miembro del Comité



DEDICATORIA

A mis padres, Andrea María Ibarra Córdova y José Luis Pasarin Montes, por formar en mí los valores y la disciplina responsables de mi desarrollo personal y profesional. Su apoyo incondicional y su presencia constante han representado la mayor fortaleza en cada etapa de mi vida.

AGRADECIMIENTOS

A mi familia, por ofrecer un apoyo constante y por darme la fortaleza necesaria para enfrentar cada reto de mi camino. A mis amigos, por acompañar mi desarrollo personal y profesional con su presencia y compañía en cada etapa. A los profesores del Centro de Enseñanza Técnica y Superior campus Tijuana, en especial al Dr. Ulises Orozco Rosas, por impulsar mi crecimiento académico y por motivar mi formación como profesional. Al Centro de Enseñanza Técnica y Superior campus Tijuana, por casi diez años de aprendizaje dentro de sus aulas y por la oportunidad de disfrutar plenamente cada experiencia vivida durante este recorrido.

RESUMEN

La Economía de Carrera (Running Economy, RE) es un indicador fisiológico clave en los deportes de resistencia, especialmente en corredores de media y larga distancia. Se define como el costo energético necesario para mantener una velocidad submáxima determinada y está influenciada por factores biomecánicos, metabólicos, cardiorrespiratorios y neuromusculares. En este estudio se presenta un enfoque novedoso para la estimación de la Economía de Carrera en corredores amateurs mediante el análisis de un modelo propuesto basado en redes Long Short-Term Memory (LSTM). Dicho modelo integra variables fisiológicas y biomecánicas como el ritmo, la frecuencia cardíaca, la potencia, la cadencia, el tiempo de contacto con el suelo y la longitud de zancada, las cuales son registradas a través de un dispositivo *wearable*. A partir del análisis de estas secuencias temporales, el modelo estima la eficiencia de carrera utilizando datos iniciales de prueba como referencia. Posteriormente, se realizan análisis de sensibilidad y de importancia global de variables con el fin de interpretar el comportamiento del modelo e identificar los factores con mayor influencia en la Economía de Carrera. Los resultados de estos análisis son utilizados como base para el diseño de un *prompt* que alimenta a un Large Language Model (LLM) basado en Mistral, el cual genera recomendaciones personalizadas orientadas a incrementar la Economía de Carrera. El desempeño del modelo predictivo fue evaluado mediante métricas estadísticas como el Error Cuadrático Medio (Mean Squared Error, MSE), el Error Absoluto Medio (Mean Absolute Error, MAE) y el Coeficiente de Determinación (R^2). Los resultados evidencian el potencial de la integración de aprendizaje profundo, interpretabilidad del modelo, modelos de lenguaje e inteligencia artificial con tecnología *wearable* para el desarrollo de herramientas de entrenamiento accesibles y personalizadas, dirigidas tanto a entrenadores como a atletas amateurs.

ABSTRACT

Running Economy (RE) is a key physiological indicator in endurance sports, particularly in middle and long distance runners. It is defined as the energetic cost required to maintain a given submaximal speed and is influenced by biomechanical, metabolic, cardiorespiratory, and neuromuscular factors. This study presents a novel approach for estimating Running Economy in amateur runners through the analysis of a proposed model based on Long Short-Term Memory (LSTM) networks. The model integrates physiological and biomechanical variables such as pace, heart rate, power, cadence, ground contact time, and stride length, which are recorded using a wearable device. Based on the analysis of these temporal sequences, the model estimates running efficiency using initial test data as a reference. Subsequently, sensitivity analysis and global feature importance analysis are performed in order to interpret the model's behavior and identify the variables with the greatest influence on Running Economy. The results of these analyses are used as the basis for the design of a prompt that feeds a Large Language Model (LLM) based on Mistral, which generates personalized recommendations aimed at improving Running Economy. The performance of the predictive model was evaluated using statistical metrics such as Mean Squared Error (MSE), Mean Absolute Error (MAE), and the Coefficient of Determination (R^2). The results demonstrate the potential of integrating deep learning, model interpretability, large language models, and artificial intelligence with wearable technology for the development of accessible and personalized training tools, targeted at both coaches and amateur athletes.

Índice general

	Page
RESUMEN	IV
ABSTRACT	v
LISTA DE FIGURAS	IX
LISTA DE TABLAS	x
1. Introducción	1
1.1. Antecedentes	1
1.1.1. Estudios Previos	3
1.2. Planteamiento del Problema	4
1.3. Justificación	5
1.4. Preguntas de Investigación	6

1.5. Hipótesis	6
1.6. Objetivo General	7
1.7. Objetivos Específicos	7
2. Marco Teórico	9
2.1. Economía de Carrera	9
2.1.1. Definición	10
2.1.2. Factores Influyentes	11
2.2. Estimación de la Economía de Carrera	13
2.2.1. Fórmula Teórica	13
2.2.2. Dispositivos de Medición	14
2.2.3. Precisión y Validación	16
2.3. Modelos de Aprendizaje Profundo	17
2.3.1. Redes Neuronales Recurrentes	18
2.3.2. Evaluación e Interpretabilidad	24
2.4. Modelos de Inteligencia Artificial Generativa	33
2.4.1. Modelos de Lenguaje de Gran Escala	33
2.4.2. Evaluación e Interpretabilidad	37
3. Sistema para la Estimación y Mejora de la Economía de Carrera	39

3.1. Descripción del Sistema	39
3.2. Adquisición y Preprocesamiento de Datos	41
3.2.1. Fuentes de Datos	41
3.2.2. Variables Analizadas	42
3.2.3. Preprocesamiento de Datos	42
3.3. Diseño del Modelo Predictivo	43
3.3.1. Arquitectura	43
3.3.2. Entrenamiento	45
3.3.3. Evaluación e Interpretabilidad	46
3.4. Diseño del Modelo Generativo	48
3.4.1. Arquitectura	48
3.4.2. Entrenamiento	49
3.4.3. Evaluación e Interpretabilidad	50
3.5. Consideraciones y Limitaciones	51
4. Experimentación y Resultados	53
4.1. Descripción del Entorno Experimental	53
4.1.1. Infraestructura Computacional	53
4.1.2. Librerías y <i>Frameworks</i>	54

4.1.3. Configuración Experimental	55
4.2. Resultados del Modelo Predictivo	56
4.2.1. Desempeño Cuantitativo	56
4.2.2. Análisis de Convergencia	57
4.2.3. Análisis de Interpretabilidad	59
4.3. Resultados del Modelo Generativo	62
4.3.1. Experimentos	62
4.3.2. Evaluación Cualitativa	74
4.4. Discusión de Resultados	74
5. Conclusiones	76
Bibliografía	79

Lista de Figuras

	Page
2.1. Arquitectura general de una red LSTM desarrollada en el tiempo. Cada celda recibe la entrada x_t , el estado oculto previo h_{t-1} y el estado de celda previo c_{t-1} , generando como salida y_t , h_t y c_t	24
3.1. Arquitectura híbrida para la predicción y análisis del rendimiento en carrera.	40
4.1. Evolución del MSE durante el entrenamiento y validación.	58
4.2. Evolución del MAE durante el entrenamiento y validación.	58
4.3. Comparación entre la serie real y la serie predicha de economía de carrera.	59
4.4. Gráfica resumen SHAP que muestra la importancia global y el impacto de cada variable en la predicción de la economía de carrera.	61

Lista de Tablas

	Page
2.1. Factores que influyen en la economía de carrera.	11
2.2. Dispositivos utilizados para la medición de parámetros en economía de carrera.	15
3.1. Porción del conjunto de datos utilizada para el entrenamiento del modelo . . .	42
4.1. Resultados del análisis de sensibilidad local.	60
4.2. Resultados de la Prueba 1 de 5 km.	63
4.3. Resultados de la Prueba 2 de 5 km.	64
4.4. Resultados de la Prueba 3 de 5 km.	64
4.5. Resultados de la Prueba 4 de 5 km.	65
4.6. Resultados de la Prueba 5 de 5 km.	65
4.7. Resultados de la Prueba 1 de 10 km.	66
4.8. Resultados de la Prueba 2 de 10 km.	66

4.9. Resultados de la Prueba 3 de 10 km.	67
4.10. Resultados de la Prueba 4 de 10 km.	68
4.11. Resultados de la Prueba 5 de 10 km.	68
4.12. Resultados de la Prueba 1 de 21 km.	69
4.13. Resultados de la Prueba 2 de 21 km.	69
4.14. Resultados de la Prueba 3 de 21 km.	70
4.15. Resultados de la Prueba 4 de 21 km.	70
4.16. Resultados de la Prueba 5 de 21 km.	71
4.17. Resultados de la Prueba 1 de 42 km.	71
4.18. Resultados de la Prueba 2 de 42 km.	72
4.19. Resultados de la Prueba 3 de 42 km.	73
4.20. Resultados de la Prueba 4 de 42 km.	73
4.21. Resultados de la Prueba 5 de 42 km.	73

Capítulo 1

Introducción

La economía de carrera es un determinante clave del rendimiento en deportes de resistencia y ha sido ampliamente reconocida como uno de los indicadores fisiológicos más importantes para corredores de media y larga distancia. Tradicionalmente, su evaluación ha dependido de entornos controlados de laboratorio mediante el uso de calorimetría indirecta y pruebas metabólicas para cuantificar el consumo de oxígeno. Sin embargo, los avances recientes en modelado bioenergético y en métodos de estimación basados en datos han comenzado a ampliar las posibilidades para evaluar la demanda metabólica fuera del laboratorio.

1.1. Antecedentes

Enfoques emergentes, incluidos modelos analíticos novedosos de la contribución energética durante la carrera (Briand et al., 2025) y estimadores de la tasa metabólica basados en aprendizaje profundo derivados de bioseñales registradas por dispositivos *wearables* (Babakhani et al., 2025), ponen de manifiesto un cambio creciente hacia técnicas de medición más flexibles y no invasivas, que complementan o reducen la necesidad del equipamiento metabólico

tradicional. No obstante, estos métodos siguen siendo costosos, demandan mucho tiempo y, en muchos casos, resultan inaccesibles para atletas y entrenadores fuera de entornos de laboratorio, particularmente debido a la necesidad de protocolos y equipos especializados, como se ha señalado en trabajos recientes sobre evaluación metabólica y rendimiento en deportes de resistencia (Jaszczak and Plociniczak, 2024; Lovell et al., 2025).

Los avances recientes en tecnología *wearable* e inteligencia artificial han abierto nuevas posibilidades para la estimación de parámetros fisiológicos clave fuera de entornos de laboratorio, con enfoques emergentes de aprendizaje automático que han demostrado la capacidad de predecir la capacidad aeróbica y otros indicadores de rendimiento utilizando datos obtenidos en campo o sin la necesidad de pruebas de ejercicio estructuradas (Wenzel et al., 2024). Los dispositivos capaces de registrar datos de forma continua, como la frecuencia cardíaca, la potencia, la cadencia y métricas de zancada, permiten la recolección de grandes volúmenes de información biomecánica y fisiológica en condiciones reales.

Los enfoques de aprendizaje profundo, en particular las Redes Neuronales Recurrentes (*Recurrent Neural Networks*, RNN) y las arquitecturas *Long Short-Term Memory* (LSTM), han demostrado una gran capacidad para modelar señales fisiológicas secuenciales, como lo evidencian sus aplicaciones exitosas en la estimación del gasto energético y en la predicción metabólica asociada a la actividad en estudios previos (Paraschiakos et al., 2022; Song et al., 2025), lo que las hace especialmente adecuadas para capturar las dinámicas temporales subyacentes al rendimiento en carrera.

De manera complementaria a los avances en modelado predictivo, los Modelos de Lenguaje de Gran Escala (*Large Language Models*, LLM) han emergido como herramientas relevantes para transformar resultados cuantitativos en información contextualizada y accionable. Estos modelos, basados en arquitecturas de transformadores y entrenados con grandes volúmenes de datos textuales, han demostrado una alta capacidad para comprender relaciones semánticas complejas y generar recomendaciones coherentes en distintos dominios (Goodfellow et al.,

2016).

A pesar de estos avances, pocos estudios han examinado específicamente la estimación directa de la economía de carrera utilizando datos provenientes de sensores *wearables* en combinación con enfoques de aprendizaje profundo temporal, a pesar del creciente cuerpo de investigación que demuestra las capacidades del aprendizaje automático y los dispositivos inteligentes para el monitoreo de la salud y la actividad física (Qureshi et al., 2025; Saad et al., 2024). Asimismo, la integración de modelos predictivos basados en series temporales con modelos generativos de lenguaje representa, por tanto, una línea emergente de investigación con alto potencial para aplicaciones en entornos de entrenamiento reales.

1.1.1. Estudios Previos

Trabajos recientes en dominios relacionados destacan el papel cada vez más relevante del aprendizaje automático y de los sistemas basados en sensores para la captura, modelado e interpretación de flujos complejos de datos generados por el ser humano. Estudios que emplean arquitecturas habilitadas por *Internet of Things* (IoT) y modelos de predicción de series temporales han demostrado la viabilidad de extraer patrones conductuales y fisiológicos significativos a partir de mediciones continuas obtenidas por dispositivos, lo que subraya el valor de las técnicas de modelado secuencial para el monitoreo fuera del laboratorio (Advaita Vetagiri, 2025).

De manera complementaria, investigaciones que utilizan marcos híbridos de redes neuronales para el reconocimiento de emociones a partir de señales fisiológicas ilustran aún más el potencial de algoritmos de aprendizaje avanzados para decodificar características sutiles y temporalmente evolutivas en bioseñales humanas (Colunga-Rodriguez et al., 2025). En conjunto, estos desarrollos refuerzan el potencial de aplicar aprendizaje profundo a métricas de carrera derivadas de dispositivos *wearables* y respaldan la necesidad de modelos especializa-

dos capaces de estimar la economía de carrera en entornos reales.

1.2. Planteamiento del Problema

La práctica de actividad física en México ha adquirido una relevancia creciente como componente fundamental de la salud y el bienestar de la población. De acuerdo con el Módulo de Práctica Deportiva y Ejercicio Físico (MOPRADEF) del Instituto Nacional de Estadística y Geografía (INEGI), el 39.8 % de la población de 18 años y más en zonas urbanas realiza ejercicio físico o deporte durante su tiempo libre (Instituto Nacional de Estadística y Geografía, 2023). Dentro de este grupo, el 43.0 % declaró correr o trotar como su principal actividad, lo que representa aproximadamente el 17.1 % del total de la población adulta urbana del país.

El World Bank Group estima una población aproximada de 129 millones de habitantes en México, lo que equivale a cerca de 22.4 millones de personas que practican correr o trotar de forma recreativa (World Bank Group, 2024). A pesar de esta alta participación, el acceso a entrenamientos técnicos estructurados continúa siendo limitado. De acuerdo con la Encuesta Nacional de Tendencias Fitness para México en 2024, únicamente el 20.0 % de los corredores recibe retroalimentación o asesoría técnica especializada (Jacobo Gómez Chávez et al., 2024). Esto implica que alrededor de 4.5 millones de corredores cuentan con apoyo estructurado, en contraste con aproximadamente 17.9 millones que entrenan sin retroalimentación técnica orientada a la mejora de sus parámetros de carrera.

La carencia de entrenamiento especializado impacta directamente en la eficiencia de los corredores, incrementando el riesgo de lesiones y limitando el progreso del rendimiento deportivo. Esta situación evidencia una brecha significativa entre la alta participación en la práctica de la carrera recreativa y la limitada disponibilidad de herramientas accesibles que permitan a los corredores amateur mejorar de manera informada y personalizada sus parámetros de

carrera.

1.3. Justificación

La problemática descrita justifica la necesidad de desarrollar soluciones tecnológicas accesibles que permitan proporcionar retroalimentación personalizada a corredores amateur, sin depender de evaluaciones complejas en entornos de laboratorio. En este contexto, la economía de carrera constituye un parámetro fisiológico clave tanto para la mejora del rendimiento como para la prevención de lesiones. Una mayor eficiencia en la economía de carrera permite a los atletas utilizar menos energía para mantener una misma velocidad, optimizando el desempeño en pruebas de resistencia y reduciendo simultáneamente el riesgo de sobrecarga y lesiones asociadas al esfuerzo prolongado (Barnes and Kilding, 2015).

Los avances recientes en tecnología *wearable* y en modelos de aprendizaje profundo ofrecen una oportunidad para cerrar esta brecha mediante herramientas capaces de analizar grandes volúmenes de datos fisiológicos y biomecánicos recolectados en condiciones reales. La implementación de modelos predictivos e interpretables orientados a la economía de carrera permitiría generar retroalimentación objetiva y personalizada, facilitando la toma de decisiones tanto para corredores como para entrenadores.

Adicionalmente, el sector de entrenadores deportivos en México representa un actor estratégico para la adopción de este tipo de soluciones. De acuerdo con la Secretaría de Economía, el país cuenta con aproximadamente 34,300 entrenadores deportivos y directores técnicos en distintas disciplinas (Secretaría de Economía, 2024). Una proporción relevante de estos profesionales se desempeña en disciplinas como atletismo, triatlón o *running*, donde la evaluación continua de parámetros de carrera es fundamental. La integración de modelos de retroalimentación basados en aprendizaje profundo podría fortalecer su labor profesional,

ampliar el alcance del acompañamiento técnico y contribuir a reducir la brecha existente entre la alta demanda de asesoría y la oferta limitada de entrenamiento especializado.

1.4. Preguntas de Investigación

Con base en el planteamiento del problema y la justificación del presente estudio, se formulan las siguientes preguntas de investigación:

1. ¿Es posible estimar la economía de carrera de corredores amateur mediante un modelo basado en redes LSTM utilizando datos fisiológicos y biomecánicos obtenidos a partir de dispositivos *wearables*?
2. ¿Cuáles son las variables fisiológicas y biomecánicas con mayor influencia en la estimación de la economía de carrera según un análisis de sensibilidad y de importancia global de variables?
3. ¿En qué medida la incorporación de técnicas de interpretabilidad del modelo contribuye a la comprensión del comportamiento del modelo LSTM y a la toma de decisiones en el contexto del entrenamiento deportivo?
4. ¿Puede la integración de un LLM generar recomendaciones personalizadas que contribuyan a la mejora de la economía de carrera en corredores amateur?

1.5. Hipótesis

La economía de carrera de corredores amateur puede ser estimada de manera precisa mediante un modelo basado en redes LSTM a partir de datos fisiológicos y biomecánicos obtenidos con dispositivos *wearables*. Asimismo, el análisis de sensibilidad y de importancia global

de variables permite identificar los factores más relevantes que influyen en la economía de carrera, los cuales pueden ser utilizados como base para la generación de recomendaciones personalizadas mediante un LLM, contribuyendo potencialmente a la mejora de la eficiencia de carrera y al apoyo del entrenamiento deportivo.

1.6. Objetivo General

Desarrollar un modelo basado en redes LSTM para la estimación de la economía de carrera en corredores amateur utilizando datos fisiológicos y biomecánicos obtenidos mediante dispositivos *wearables*, incorporando análisis de interpretabilidad del modelo y la integración de un LLM para la generación de recomendaciones personalizadas orientadas a la mejora de la eficiencia de carrera.

1.7. Objetivos Específicos

1. Diseñar y entrenar un modelo LSTM capaz de estimar la economía de carrera a partir de secuencias temporales de variables fisiológicas y biomecánicas recolectadas mediante dispositivos *wearables*.
2. Evaluar el desempeño del modelo predictivo utilizando métricas estadísticas como MSE, MAE y R^2 .
3. Realizar análisis de sensibilidad y de importancia global de variables con el fin de identificar los factores con mayor impacto en la economía de carrera y mejorar la interpretabilidad del modelo.
4. Integrar los resultados del modelo predictivo y de los análisis de interpretabilidad en un LLM para generar recomendaciones personalizadas orientadas a incrementar la

economía de carrera en corredores amateur.

5. Evaluar de manera manual la calidad, coherencia y pertinencia de las recomendaciones generadas por el LLM, considerando su alineación con principios de entrenamiento deportivo y fisiología del ejercicio.

Capítulo 2

Marco Teórico

Correr se ha consolidado como una de las actividades deportivas recreativas y competitivas más relevantes a nivel mundial, impulsada por el creciente interés en la salud física, el manejo del estrés y la optimización del rendimiento. A medida que aumenta la participación, la investigación científica y académica ha centrado su atención en comprender los determinantes fisiológicos y biomecánicos del rendimiento en carrera, particularmente la eficiencia con la que los individuos son capaces de sostener esfuerzos prolongados. En este contexto, la economía de carrera surge como un indicador central para la evaluación y mejora del rendimiento en deportes de resistencia.

2.1. Economía de Carrera

La economía de carrera ha emergido como un constructo fundamental dentro de la fisiología del ejercicio de resistencia debido a su alto valor predictivo del rendimiento en una amplia variedad de pruebas de carrera. En consecuencia, su estudio se ha vuelto esencial tanto para investigadores como para profesionales del deporte que buscan optimizar intervenciones de

entrenamiento, evaluar adaptaciones biomecánicas y desarrollar estrategias orientadas a la mejora del desempeño. A continuación, se presenta una definición que contextualiza este concepto dentro del ámbito de la investigación en rendimiento de resistencia.

2.1.1. Definición

La economía de carrera se define como el costo energético requerido para mantener una velocidad de carrera determinada, comúnmente evaluado a través del consumo de oxígeno (VO_2) durante ejercicio submáximo. Estudios recientes han resaltado la importancia de cuantificar con precisión esta demanda metabólica para una mejor evaluación del rendimiento en resistencia (Barnes and Kilding, 2015; Hsiao et al., 2025). Un menor costo energético para una misma velocidad de carrera refleja una mayor eficiencia, la cual se asocia fuertemente con un mejor desempeño en pruebas de media y larga distancia (Saunders et al., 2004; Van Hooren et al., 2024).

Desde una perspectiva fisiológica, la economía de carrera refleja la eficiencia metabólica, la capacidad cardiorrespiratoria y la habilidad del organismo para transportar y utilizar oxígeno de manera eficaz (Barnes and Kilding, 2015). Desde el punto de vista biomecánico, la economía de carrera depende de la coordinación neuromuscular, la función musculoesquelética y la eficacia con la que la energía mecánica se transforma en propulsión hacia adelante. Entre los principales factores intrínsecos que influyen en la economía de carrera se encuentran la longitud de zancada, la cadencia, la técnica de carrera y la elasticidad del sistema músculo-tendinoso (Bailey et al., 2023; Van Hooren et al., 2024).

La economía de carrera constituye una variable crítica para el monitoreo del rendimiento deportivo, la orientación de estrategias de entrenamiento y la prevención de lesiones. Los avances recientes en tecnología *wearable* y en modelos basados en datos han ampliado la capacidad de estimar la economía de carrera en entornos reales de entrenamiento, permitiendo

generar retroalimentación individualizada orientada a la mejora continua del desempeño.

2.1.2. Factores Influyentes

La economía de carrera resulta de una interacción multifactorial entre componentes fisiológicos y biomecánicos. Variables biomecánicas como la cadencia, la longitud de zancada, el tiempo de contacto con el suelo, la potencia de carrera y la oscilación vertical muestran una influencia directa sobre la eficiencia en carrera (Barnes and Kilding, 2015; Van Hooren et al., 2024). Tal como se resume en la Tabla 2.1, una mayor cadencia, una menor oscilación vertical y un tiempo de contacto reducido se asocian con un menor costo metabólico y una mejora en la economía de carrera.

Tabla 2.1: Factores que influyen en la economía de carrera.

Parámetro	Definición	Relevancia en la Economía de Carrera
Ritmo (min/km)	Tiempo requerido para recorrer un kilómetro.	Se relaciona directamente con la velocidad de carrera y el costo energético (VO_2). Velocidades más altas incrementan la demanda de oxígeno. Constituye la base para el cálculo de formulaciones clásicas de economía de carrera (Barnes and Kilding, 2015).
Frecuencia cardíaca (bpm)	Número de latidos del corazón por minuto.	Presenta una relación aproximadamente lineal con el VO_2 durante esfuerzos submáximos; permite estimar la intensidad relativa del ejercicio. Es un indicador práctico de carga interna, aunque requiere calibración individual (Parak et al., 2017).

Continúa en la siguiente página

Parámetro	Definición	Relevancia en la Economía de Carrera
Potencia (W)	Trabajo mecánico realizado por unidad de tiempo durante la carrera.	Muestra una fuerte correlación con el costo energético y la eficiencia mecánica. Permite estimar la economía de carrera sin necesidad de mediciones directas de VO ₂ (Austin et al., 2018).
Cadencia (spm)	Número de pasos por minuto.	Influye directamente en la eficiencia biomecánica. Una cadencia óptima reduce la oscilación vertical y mejora la estabilidad, disminuyendo el costo energético (Barnes and Kilding, 2015).
Tiempo de contacto con el suelo (ms)	Duración del contacto del pie con el suelo en cada zancada.	Tiempos de contacto más cortos se asocian con una mejor elasticidad músculo-tendinosa, lo que incrementa la eficiencia y reduce el costo metabólico (Bailey et al., 2023).
Longitud de zancada (m)	Distancia recorrida en cada paso durante la carrera.	Una longitud de zancada adecuada, ajustada a la velocidad y cadencia, optimiza el gasto energético. Zancadas excesivas pueden incrementar el consumo de oxígeno y el riesgo de lesión (Shao et al., 2021).

Los sensores *wearables* permiten actualmente la medición precisa de estos parámetros en entornos naturales de entrenamiento, facilitando la recopilación a gran escala de datos fisiológicos y de la marcha (de Fontenay et al., 2020; Strohrmann et al., 2012). Si bien métricas como la cadencia y la duración de la zancada presentan alta validez, algunos parámetros específicos, como la fuerza de frenado y el desplazamiento vertical, pueden mostrar mayor variabilidad y requieren análisis especializados para garantizar su precisión (de Fontenay et al., 2020).

La comprensión de los determinantes de la economía de carrera resulta fundamental para el diseño de programas de entrenamiento personalizados, la optimización de la eficiencia mecánica y la reducción del riesgo de lesiones tanto en corredores recreativos como competitivos. Avances recientes destacan además que estos determinantes se encuentran estrechamente vinculados con la predicción del costo metabólico, como

lo demuestran enfoques emergentes basados en sensores y modelos de aprendizaje automático (Wang et al., 2025).

2.2. Estimación de la Economía de Carrera

Si bien la economía de carrera puede cuantificarse de manera empírica mediante evaluaciones realizadas en laboratorio, su análisis suele beneficiarse de enfoques teóricos complementarios. En particular, las estimaciones teóricas proporcionan un marco estandarizado que facilita la comparación entre estudios, respalda análisis basados en modelos y permite su integración con algoritmos predictivos, como los utilizados en aprendizaje profundo. Sobre esta base, a continuación se introduce la formulación teórica comúnmente empleada para la estimación de la economía de carrera.

2.2.1. Fórmula Teórica

La economía de carrera puede estimarse a partir de mediciones directas del consumo de oxígeno en laboratorio o mediante expresiones teóricas que relacionan la velocidad de carrera con el costo metabólico. La Ecuación 2.1 presenta la expresión teórica estándar para el cálculo de la economía de carrera.

$$\text{RE} = \frac{\text{VO}_2}{v} \tag{2.1}$$

Donde VO_2 representa el consumo relativo de oxígeno ($\text{ml}\cdot\text{kg}^{-1}\cdot\text{min}^{-1}$) y v corresponde a la velocidad de carrera ($\text{km}\cdot\text{min}^{-1}$) (Barnes and Kilding, 2015). Bajo condiciones de carrera en terreno plano y en estado estable, el consumo de oxígeno puede estimarse mediante la Ecuación 2.2.

$$\text{VO}_2 = 3.5 + 0.2 v \tag{2.2}$$

Cuando se considera la inclinación de la superficie de carrera, se aplica la Ecuación 2.3. En este contexto, el

término *grade* representa la pendiente del terreno, expresada como una fracción decimal (por ejemplo, una inclinación del 5% corresponde a un valor de *grade* igual a 0.05). De este modo, el modelo incorpora un término adicional que considera el incremento en el costo metabólico asociado con la carrera en pendiente positiva.

$$\text{VO}_2 = 3.5 + 0.2v + 0.9v \cdot \text{grade} \quad (2.3)$$

Estos marcos teóricos permiten estimar la economía de carrera sin necesidad de equipamiento de laboratorio, proporcionando herramientas escalables para la evaluación del rendimiento y su integración con sistemas de monitoreo basados en dispositivos *wearables*.

2.2.2. Dispositivos de Medición

Los dispositivos de medición, tales como relojes inteligentes, bandas de frecuencia cardíaca, sensores inerciales colocados en el cuerpo y plataformas instrumentadas, permiten la medición continua de métricas clave de la carrera en condiciones ecológicas reales, como se resume en la Tabla 2.2 (Zhang et al., 2025; Parak et al., 2017). Si bien los dispositivos disponibles comercialmente presentan una alta validez en la medición de parámetros como la cadencia y las variables espaciotemporales de la zancada, otros indicadores como las fuerzas de reacción del suelo pueden requerir filtrado adicional o modelos avanzados para garantizar su precisión (de Fontenay et al., 2020; Ursul and Pereymybyda, 2023).

Tabla 2.2: Dispositivos utilizados para la medición de parámetros en economía de carrera.

Dispositivo	Definición	Tipos de Sensores Incluidos	Ejemplos de Fabricantes
Relojes inteligentes	Dispositivos portátiles en la muñeca utilizados para registrar parámetros fisiológicos y biomecánicos durante la actividad física (de Fontenay et al., 2020; Bailey et al., 2023).	Acelerómetro, giroscopio, sensor óptico de frecuencia cardíaca, GPS.	Garmin, Apple, Polar, Suunto.
Bandas de frecuencia cardíaca	Cintas ajustables al pecho utilizadas para medir el ritmo cardíaco en tiempo real mediante sensores eléctricos o ópticos (Carrier and Navalta, 2022; de Fontenay et al., 2020).	Electrocardiografía (ECG), fotopleletismografía (PPG).	Polar, Wahoo, Garmin.
Sensores inerciales corporales	Dispositivos pequeños adheridos al cuerpo utilizados para capturar movimientos, orientación y aceleración en tres dimensiones (Strohrmann et al., 2012; de Fontenay et al., 2020).	Acelerómetro triaxial, giroscopio, magnetómetro.	RunScribe™, Moov Now™, MilestonePod.
Plataformas instrumentadas	Superficies equipadas con sensores utilizados para registrar fuerzas de reacción del suelo, desplazamientos y presiones de contacto (Ursul and Pereymybidá, 2023; Zhang et al., 2020).	Celdas de carga, sensores piezoeléctricos, plataformas de presión.	AMTI, Bertec, Kistler.

La disponibilidad de dispositivos de medición ha contribuido a la democratización del análisis del rendimiento deportivo, permitiendo que corredores amateurs, entrenadores y científicos del deporte accedan a información relevante sin la necesidad de instalaciones especializadas. No obstante, la interpretación adecuada de los datos obtenidos requiere conocimiento técnico, ya que la validez de los parámetros medidos depende tanto del tipo de dispositivo como de la ubicación del sensor y de las condiciones específicas de la carrera. En este

contexto, las tecnologías portátiles proporcionan una base sólida para la recopilación de datos fisiológicos y biomecánicos, los cuales pueden integrarse con modelos de aprendizaje profundo para estimar con mayor precisión la economía de carrera y evaluar la eficiencia individual del corredor (Carrier and Navalta, 2022; Zhang et al., 2020).

Los modelos de aprendizaje profundo han demostrado contribuir significativamente a la mejora en la estimación de parámetros asociados a la marcha y la carrera, reduciendo el error en comparación con sistemas de referencia de laboratorio (Zhang et al., 2020). Estos avances amplían el acceso a herramientas avanzadas de análisis del rendimiento, permitiendo que atletas recreativos se beneficien de tecnologías que anteriormente estaban restringidas a entornos de investigación de alto nivel (Carrier and Navalta, 2022).

2.2.3. Precisión y Validación

Los dispositivos portátiles ofrecen ventajas significativas en términos de accesibilidad y volumen de datos recopilados; sin embargo, no todos los parámetros medidos presentan la misma precisión o consistencia. La exactitud de los sensores puede verse afectada por movimientos corporales no lineales, la ubicación del dispositivo, la variabilidad individual entre corredores y la dinámica propia de la carrera en entornos reales. Estudios de validación han demostrado una alta confiabilidad en parámetros como la cadencia, mientras que otros indicadores, tales como fuerzas específicas y desplazamientos verticales, requieren procesos de filtrado y análisis estadístico adicional para garantizar resultados útiles y consistentes (de Fontenay et al., 2020; Ursul and Pereymybidá, 2023).

Investigaciones recientes han evidenciado que modelos de aprendizaje profundo, como la regresión basada en máquinas de vectores de soporte, pueden mejorar de forma significativa la precisión en la estimación de parámetros clave del patrón de zancada, incluso cuando se emplean sensores portátiles de bajo costo (Zhang et al., 2020). Este enfoque permite reducir el error existente entre las mediciones obtenidas mediante dispositivos comerciales y los valores de referencia de laboratorio, optimizando así la evaluación de la economía de carrera en entornos no controlados. De manera complementaria, Ursul y Pereymybidá (Ursul and Pereymybidá, 2023) aplicaron técnicas de *clustering* y detección de anomalías para identificar patrones de movimiento atípicos, proporcionando herramientas adicionales para la validación de la información y la segmentación de corredores en función de su eficiencia.

En conjunto, estos hallazgos resaltan la importancia de no depender exclusivamente de los datos brutos

generados por sensores portátiles. La integración de técnicas de aprendizaje profundo y modelos predictivos permite transformar datos fisiológicos y biomecánicos en información de alto valor, orientada a la mejora del rendimiento y a la personalización de programas de entrenamiento.

2.3. Modelos de Aprendizaje Profundo

El aprendizaje profundo ha transformado la forma de analizar datos complejos, permitiendo extraer patrones a partir de grandes volúmenes de información de manera automatizada. En el contexto de la economía de carrera, permite integrar métricas fisiológicas y biomecánicas para estimar la eficiencia energética de corredores amateur con mayor precisión en comparación con los métodos tradicionales. Las redes neuronales permiten capturar relaciones no lineales y dinámicas entre variables como ritmo, frecuencia cardíaca, potencia y cadencia, facilitando la predicción de la economía de carrera y permitiendo el diseño de estrategias de entrenamiento personalizadas basadas en datos objetivos.

La Inteligencia Artificial (IA) es definida como la disciplina orientada al diseño de sistemas computacionales capaces de ejecutar funciones cognitivas humanas, tales como aprendizaje, percepción y resolución de problemas (Russell and Norvig, 2021). A partir de esta base, la IA ha consolidado su relevancia en la resolución de problemas complejos, permitiendo a los sistemas computacionales realizar tareas tradicionalmente asociadas con la inteligencia humana.

Dentro de la IA, el aprendizaje automático (*Machine Learning*, ML) constituye un subcampo fundamental cuyo objetivo es desarrollar algoritmos capaces de aprender patrones a partir de datos y realizar predicciones o clasificaciones sin necesidad de programación explícita para cada escenario particular. Los modelos de ML pueden clasificarse en supervisados, no supervisados o por refuerzo, dependiendo del tipo de datos disponibles y del objetivo de la tarea (Carrier and Navalta, 2022).

El aprendizaje profundo (*Deep Learning*, DL) surge como evolución del ML, utilizando redes neuronales con múltiples capas interconectadas capaces de capturar relaciones altamente complejas y no lineales entre variables. A diferencia de los métodos tradicionales de ML, donde se requiere ingeniería manual de características, el DL permite aprender representaciones jerárquicas de los datos, facilitando el modelado de patrones complejos en conjuntos de datos grandes y multidimensionales (Zhang et al., 2020).

Este enfoque resulta particularmente útil en el análisis de datos fisiológicos y biomecánicos de corredores,

donde las interacciones entre variables como ritmo, cadencia, potencia y tiempo de contacto con el suelo presentan alta dinámica y no linealidad. Además, el DL ha demostrado alta eficacia en el procesamiento de secuencias temporales y señales biomédicas, facilitando la extracción automática de patrones latentes difíciles de identificar mediante técnicas convencionales (LeCun et al., 2015). Gracias a estas propiedades, el aprendizaje profundo es considerado un pilar en el desarrollo de modelos predictivos capaces de ofrecer estimaciones robustas y precisas en aplicaciones deportivas.

2.3.1. Redes Neuronales Recurrentes

Las redes neuronales recurrentes (*Recurrent Neural Networks*, RNN) constituyen una extensión de las redes neuronales tradicionales diseñada para manejar datos secuenciales mediante la incorporación de conexiones recurrentes que permiten transmitir información entre pasos temporales consecutivos. Esta arquitectura permite modelar dependencias dinámicas en series temporales al mantener un estado oculto que actúa como memoria de la información previamente procesada (LeCun et al., 2015).

Gracias a esta característica, las RNN han sido aplicadas ampliamente en tareas como reconocimiento de voz, procesamiento de lenguaje natural y predicción de señales fisiológicas, donde la estructura temporal de los datos resulta esencial. En el contexto deportivo, las RNN permiten analizar la evolución dinámica de variables fisiológicas y biomecánicas durante el ejercicio, facilitando la comprensión del comportamiento del rendimiento en función del tiempo.

Desde un punto de vista teórico, una RNN puede interpretarse como la generalización de un modelo de regresión no lineal aplicado de manera iterativa sobre una secuencia temporal. Sea una secuencia de entrada $\{\mathbf{x}_t\}_{t=1}^T$, donde $\mathbf{x}_t \in \mathbb{R}^d$ representa el vector de características en el instante t . La RNN define un estado oculto $\mathbf{h}_t \in \mathbb{R}^m$ que resume la información histórica hasta el tiempo t , el cual se actualiza de forma recursiva mediante la ecuación:

$$\mathbf{h}_t = \phi(\mathbf{W}_{xh}\mathbf{x}_t + \mathbf{W}_{hh}\mathbf{h}_{t-1} + \mathbf{b}_h) \quad (2.4)$$

Donde $\mathbf{W}_{xh} \in \mathbb{R}^{m \times d}$ es la matriz de pesos asociada a la entrada, $\mathbf{W}_{hh} \in \mathbb{R}^{m \times m}$ representa la matriz de transición recurrente, \mathbf{b}_h es el vector de sesgo y $\phi(\cdot)$ es una función de activación no lineal, típicamente tanh

o ReLU. La salida del modelo en cada instante puede definirse como:

$$\mathbf{y}_t = \psi(\mathbf{W}_{hy}\mathbf{h}_t + \mathbf{b}_y) \quad (2.5)$$

Donde \mathbf{W}_{hy} es la matriz de pesos hacia la capa de salida y $\psi(\cdot)$ depende de la tarea (por ejemplo, identidad para regresión o softmax para clasificación). Las funciones de activación introducen no linealidad en la red neuronal, permitiendo que el modelo capture relaciones complejas en los datos. En particular, la función tanh (tangente hiperbólica) transforma los valores de entrada en un rango entre -1 y 1 , lo que permite mantener las activaciones centradas alrededor de cero. Por otro lado, la función ReLU (*Rectified Linear Unit*) activa únicamente los valores positivos y asigna cero a los negativos, lo que favorece una mayor eficiencia computacional y facilita el entrenamiento de redes neuronales profundas. Esta formulación puede entenderse como un sistema dinámico no lineal en tiempo discreto, en el cual el estado oculto actúa como una variable de estado interna que evoluciona de acuerdo con la entrada y su propio valor previo. Desde la perspectiva probabilística, la RNN modela la distribución condicional (Goodfellow et al., 2016; Bishop and Bishop, 2023):

$$p(\mathbf{y}_t \mid \mathbf{x}_1, \dots, \mathbf{x}_t) \quad (2.6)$$

Utilizando la factorización secuencial inducida por el estado oculto como estadístico suficiente aproximado de la historia pasada. El entrenamiento de una RNN se realiza mediante la minimización de una función de pérdida acumulada en el tiempo:

$$\mathcal{L} = \sum_{t=1}^T \ell(\mathbf{y}_t, \hat{\mathbf{y}}_t) \quad (2.7)$$

Donde $\hat{\mathbf{y}}_t$ representa la salida deseada y $\ell(\cdot)$ es típicamente el error cuadrático medio o la entropía cruzada. La optimización se lleva a cabo mediante descenso por gradiente utilizando el algoritmo conocido como *Backpropagation Through Time* (BPTT), el cual consiste en desplegar la red en el eje temporal y aplicar

retropropagación convencional sobre la red expandida (Goodfellow et al., 2016). El problema del desvanecimiento y explosión del gradiente puede analizarse formalmente examinando la derivada del estado oculto respecto a un estado anterior:

$$\frac{\partial \mathbf{h}_t}{\partial \mathbf{h}_{t-k}} = \prod_{i=t-k+1}^t \mathbf{J}_i \quad (2.8)$$

Donde \mathbf{J}_i es el Jacobiano local de la transformación recurrente en el instante i . Si los valores propios de \mathbf{W}_{hh} tienen magnitud menor que uno, el producto sucesivo tiende a cero exponencialmente (desvanecimiento del gradiente); si son mayores que uno, puede crecer exponencialmente (explosión del gradiente) (Bishop and Bishop, 2023). Este comportamiento está directamente relacionado con la estabilidad de sistemas dinámicos lineales discretos y con el radio espectral de la matriz recurrente.

Desde el punto de vista funcional, una RNN puede interpretarse como una aproximación universal de funciones sobre secuencias, extendiendo el teorema de aproximación universal de redes *feedforward* al dominio temporal (Goodfellow et al., 2016). No obstante, en la práctica, su capacidad efectiva para capturar dependencias de largo plazo está limitada por las restricciones numéricas mencionadas.

En aplicaciones como el modelado de la economía de carrera o la predicción del rendimiento fisiológico durante una carrera, la RNN permite representar la evolución temporal de variables mediante una dinámica interna que integra información histórica de manera compacta. Matemáticamente, el estado oculto funciona como un codificador no lineal del historial de carga fisiológica acumulada, permitiendo establecer relaciones entre estados pasados y desempeño futuro dentro de un marco determinista entrenado mediante optimización estocástica.

En síntesis, las RNN constituyen modelos dinámicos paramétricos definidos por ecuaciones recursivas no lineales, entrenados mediante optimización basada en gradientes y capaces de aproximar distribuciones condicionales sobre secuencias temporales. Su limitación fundamental radica en la propagación inestable del gradiente, lo que motivó el desarrollo de arquitecturas más avanzadas como LSTM, diseñadas específicamente para preservar información relevante a lo largo de horizontes temporales extensos (Goodfellow et al., 2016; Bishop and Bishop, 2023).

Long Short-Term Memory

Las redes *Long Short-Term Memory* (LSTM) fueron introducidas por Hochreiter y Schmidhuber con el objetivo de superar las limitaciones de las RNN tradicionales relacionadas con el aprendizaje de dependencias a largo plazo (Hochreiter and Schmidhuber, 1997). Estas redes incorporan una arquitectura basada en compuertas que regulan el flujo de información, permitiendo conservar información relevante durante periodos prolongados y descartar información no significativa.

Las LSTM resultan particularmente adecuadas para el análisis de datos fisiológicos y biomecánicos en corredores, donde los patrones dependen de la interacción secuencial de múltiples variables a lo largo del tiempo. Variables como ritmo, frecuencia cardíaca, potencia, cadencia, tiempo de contacto con el suelo y longitud de zancada generan secuencias temporales donde se refleja la evolución de la fatiga y la eficiencia del corredor. Las LSTM permiten capturar estas dinámicas, aprendiendo cómo estados previos influyen en estados futuros y proporcionando predicciones más precisas de la economía de carrera (Shao et al., 2021).

La incorporación de mecanismos de atención en modelos LSTM permite mejorar el rendimiento del modelo al enfocar el procesamiento en las partes más relevantes de la secuencia, reduciendo redundancias en los datos y aumentando la capacidad predictiva sin incrementar significativamente el costo computacional (Shao et al., 2021). Este enfoque resulta especialmente útil al trabajar con datos de múltiples corredores o al integrar variables fisiológicas adicionales.

Asimismo, los modelos LSTM han demostrado robustez frente a la variabilidad interindividual, permitiendo generalizar el aprendizaje a corredores con distintos niveles de habilidad y características fisiológicas. Esta propiedad reduce la necesidad de entrenar modelos altamente personalizados, facilitando su aplicación práctica en contextos de running recreativo (Bailey et al., 2023).

Desde el punto de vista matemático, una celda LSTM introduce un mecanismo explícito de memoria interna $\mathbf{c}_t \in \mathbb{R}^m$, además del estado oculto $\mathbf{h}_t \in \mathbb{R}^m$, con el objetivo de preservar información relevante durante horizontes temporales largos. A diferencia de la RNN clásica, donde la dinámica depende únicamente de \mathbf{h}_{t-1} , la LSTM desacopla la memoria de largo plazo del estado de salida, permitiendo un flujo de gradiente más estable (Goodfellow et al., 2016; Bishop and Bishop, 2023).

Sea $\mathbf{x}_t \in \mathbb{R}^d$ la entrada en el instante t . La LSTM define tres compuertas principales (olvido, entrada y salida) junto con un estado candidato de memoria. Su funcionamiento se describe mediante el siguiente sistema de ecuaciones:

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \mathbf{x}_t + \mathbf{U}_f \mathbf{h}_{t-1} + \mathbf{b}_f) \quad (2.9)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \mathbf{x}_t + \mathbf{U}_i \mathbf{h}_{t-1} + \mathbf{b}_i) \quad (2.10)$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c \mathbf{x}_t + \mathbf{U}_c \mathbf{h}_{t-1} + \mathbf{b}_c) \quad (2.11)$$

$$\mathbf{c}_t = \mathbf{f}_t \odot \mathbf{c}_{t-1} + \mathbf{i}_t \odot \tilde{\mathbf{c}}_t \quad (2.12)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o \mathbf{x}_t + \mathbf{U}_o \mathbf{h}_{t-1} + \mathbf{b}_o) \quad (2.13)$$

$$\mathbf{h}_t = \mathbf{o}_t \odot \tanh(\mathbf{c}_t) \quad (2.14)$$

Donde $\sigma(\cdot)$ es la función sigmoide logística, \odot denota el producto elemento a elemento y los parámetros \mathbf{W}_* , \mathbf{U}_* , \mathbf{b}_* son aprendidos durante el entrenamiento. La ecuación fundamental es la actualización aditiva del estado de celda:

$$\mathbf{c}_t = \mathbf{f}_t \odot \mathbf{c}_{t-1} + \mathbf{i}_t \odot \tilde{\mathbf{c}}_t \quad (2.15)$$

Esta formulación permite que la derivada parcial respecto al estado anterior sea:

$$\frac{\partial \mathbf{c}_t}{\partial \mathbf{c}_{t-1}} = \mathbf{f}_t \quad (2.16)$$

Lo que implica que, si $\mathbf{f}_t \approx \mathbf{1}$, el gradiente puede propagarse a lo largo del tiempo sin atenuarse exponencialmente. Esta propiedad, conocida como *Constant Error Carousel*, constituye el fundamento matemático que permite a las LSTM mitigar el problema del desvanecimiento del gradiente presente en las RNN tradicionales (Goodfellow et al., 2016). Desde el análisis de estabilidad, el flujo del gradiente depende directamente del comportamiento dinámico de la compuerta de olvido, lo cual introduce un mecanismo adaptativo de control del error (Bishop and Bishop, 2023). En términos generales, la LSTM puede representarse como un sistema dinámico no lineal con memoria explícita:

$$(\mathbf{c}_t, \mathbf{h}_t) = F_\theta(\mathbf{c}_{t-1}, \mathbf{h}_{t-1}, \mathbf{x}_t) \quad (2.17)$$

Donde F_θ es una transformación paramétrica no lineal. Este modelo define una ecuación en diferencias con control multiplicativo del estado, en la que las compuertas regulan la incorporación de nueva información, la retención de información pasada y la exposición del estado interno hacia la salida. Desde la perspectiva probabilística, la LSTM modela distribuciones condicionales secuenciales de la forma:

$$p(\mathbf{y}_1, \dots, \mathbf{y}_T \mid \mathbf{x}_1, \dots, \mathbf{x}_T) = \prod_{t=1}^T p(\mathbf{y}_t \mid \mathbf{h}_t) \quad (2.18)$$

Donde \mathbf{h}_t actúa como representación latente del historial completo. En tareas generativas, también puede aproximar distribuciones autorregresivas:

$$p(\mathbf{x}_1, \dots, \mathbf{x}_T) = \prod_{t=1}^T p(\mathbf{x}_t \mid \mathbf{x}_1, \dots, \mathbf{x}_{t-1}) \quad (2.19)$$

Funcionando como un aproximador universal de funciones dinámicas no lineales sobre secuencias (Goodfellow et al., 2016; Bishop and Bishop, 2023). El entrenamiento se realiza minimizando una función de pérdida acumulada:

$$\mathcal{L}(\theta) = \sum_{t=1}^T \ell(\mathbf{y}_t, \hat{\mathbf{y}}_t) \quad (2.20)$$

Utilizando Backpropagation Through Time (BPTT). La propagación del gradiente respecto a estados anteriores incluye productos sucesivos de las compuertas de olvido:

$$\frac{\partial \mathbf{c}_t}{\partial \mathbf{c}_{t-k}} = \prod_{j=t-k+1}^t \mathbf{f}_j \quad (2.21)$$

Lo que muestra explícitamente cómo el diseño estructural de la LSTM controla la estabilidad numérica del aprendizaje. En aplicaciones fisiológicas, el estado de celda \mathbf{c}_t puede interpretarse como una variable latente que representa la acumulación de carga metabólica y fatiga, mientras que las compuertas modelan procesos de retención y disipación adaptativa. Matemáticamente, la LSTM implementa un sistema dinámico no lineal con memoria controlada, capaz de capturar interacciones temporales complejas entre variables como ritmo, frecuencia cardíaca, potencia y cadencia. En la Figura 2.1 se muestra la arquitectura general de una red LSTM desarrollada en el tiempo.

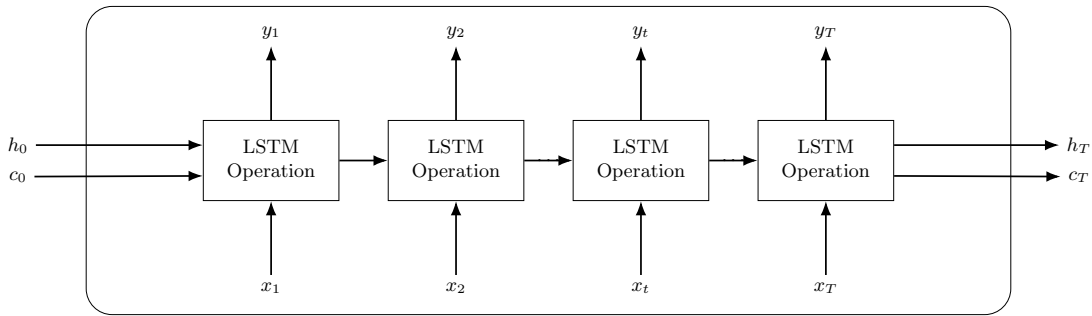


Figura 2.1: Arquitectura general de una red LSTM desarrollada en el tiempo. Cada celda recibe la entrada x_t , el estado oculto previo h_{t-1} y el estado de celda previo c_{t-1} , generando como salida y_t , h_t y c_t .

En síntesis, las LSTM constituyen una extensión estructural de las RNN basada en ecuaciones en diferencias no lineales con compuertas multiplicativas y memoria explícita. Su formulación matemática permite una propagación estable del gradiente y una representación eficiente de dependencias temporales de largo alcance, proporcionando un marco teórico sólido para el modelado de series temporales complejas (Goodfellow et al., 2016; Bishop and Bishop, 2023).

2.3.2. Evaluación e Interpretabilidad

La evaluación de modelos de aprendizaje profundo constituye un proceso fundamental para determinar su capacidad de generalización y robustez frente a datos no observados previamente (Goodfellow et al.,

2016). En el contexto de la predicción de la economía de carrera mediante redes LSTM, esta etapa adquiere especial relevancia debido a que el objetivo final consiste en trasladar el desempeño del modelo desde entornos controlados hacia escenarios reales de entrenamiento de corredores amateur.

La fiabilidad del modelo es establecida mediante métricas cuantitativas donde son comparados los valores predichos con valores de referencia obtenidos a partir de formulaciones teóricas o mediciones fisiológicas directas. Además de evaluar el ajuste estadístico, es necesario validar la capacidad del modelo para generalizar hacia nuevos corredores y condiciones de carrera. Este proceso puede ser realizado mediante la evaluación en conjuntos de datos independientes, así como mediante técnicas de interpretabilidad que permitan comprender el comportamiento del modelo (LeCun et al., 2015).

La combinación de métricas cuantitativas, validación con datos no vistos previamente, análisis de sensibilidad y métodos de interpretabilidad fortalece la confiabilidad del modelo. Este enfoque permite garantizar que las predicciones generadas no solo sean precisas, sino también útiles desde el punto de vista práctico para la generación de recomendaciones orientadas a la mejora del rendimiento deportivo (Shao et al., 2021; Bailey et al., 2023).

Métricas

La evaluación cuantitativa del modelo se realiza mediante métricas estadísticas que permiten medir la diferencia entre los valores predichos y los valores reales de economía de carrera. Entre las métricas más utilizadas se encuentran el error cuadrático medio (Mean Squared Error, MSE), el error absoluto medio (Mean Absolute Error, MAE) y el coeficiente de determinación (R^2) (Goodfellow et al., 2016).

El error cuadrático medio (MSE) penaliza de forma más severa los errores grandes, permitiendo evaluar la precisión global del modelo.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.22)$$

El error absoluto medio (MAE) representa la desviación promedio absoluta entre los valores predichos y los observados, siendo menos sensible a valores atípicos.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.23)$$

Finalmente, el coeficiente de determinación (R^2) mide la proporción de la variabilidad total explicada por el modelo, representando su capacidad explicativa global.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.24)$$

Donde y_i representa el valor real de economía de carrera, \hat{y}_i el valor predicho, \bar{y} la media de los valores observados y n el número total de observaciones. El uso conjunto de estas métricas permite evaluar tanto la precisión como la estabilidad del modelo en escenarios reales de aplicación (Shao et al., 2021; Bailey et al., 2023).

Análisis de Sensibilidad Local

El análisis de sensibilidad local permite evaluar cómo las variaciones en las variables de entrada afectan las predicciones del modelo, proporcionando una visión sobre la robustez y estabilidad del sistema. En modelos aplicados a la economía de carrera, este análisis resulta especialmente útil para identificar la influencia de variables fisiológicas y biomecánicas como ritmo, frecuencia cardíaca, cadencia, potencia y tiempo de contacto con el suelo.

Desde la perspectiva del aprendizaje profundo, este procedimiento permite validar que el modelo no dependa excesivamente de patrones específicos presentes en los datos de entrenamiento, reduciendo el riesgo de sobreajuste y mejorando la capacidad de generalización (LeCun et al., 2015). En este proyecto, el análisis de sensibilidad se realiza evaluando el impacto de variaciones controladas en variables clave sobre la predicción final de la economía de carrera.

Este enfoque permite identificar qué parámetros presentan mayor impacto en el rendimiento del modelo, facilitando la interpretación de resultados y apoyando la generación de recomendaciones personalizadas para corredores amateur. La integración de análisis de sensibilidad con métricas cuantitativas fortalece la

validación del modelo en entornos reales (Shao et al., 2021; Bailey et al., 2023).

Desde una formulación matemática general, sea un modelo de aprendizaje profundo representado como una función paramétrica:

$$\hat{y} = f_{\theta}(\mathbf{x}) \quad (2.25)$$

Donde $\mathbf{x} \in \mathbb{R}^d$ es el vector de variables de entrada, θ representa el conjunto de parámetros entrenables y \hat{y} es la predicción del modelo. El análisis de sensibilidad local estudia la variación infinitesimal de la salida ante perturbaciones pequeñas en las entradas alrededor de un punto específico \mathbf{x}_0 . Formalmente, la sensibilidad local de la salida respecto a la i -ésima variable de entrada se define mediante la derivada parcial:

$$S_i(\mathbf{x}_0) = \left. \frac{\partial f_{\theta}(\mathbf{x})}{\partial x_i} \right|_{\mathbf{x}=\mathbf{x}_0} \quad (2.26)$$

En forma vectorial, el análisis se basa en el gradiente:

$$\nabla_{\mathbf{x}} f_{\theta}(\mathbf{x}_0) = \left[\frac{\partial f_{\theta}}{\partial x_1}, \dots, \frac{\partial f_{\theta}}{\partial x_d} \right]_{\mathbf{x}=\mathbf{x}_0} \quad (2.27)$$

El cual describe la dirección de máxima variación local de la predicción. Desde la perspectiva del cálculo multivariable, este gradiente constituye la aproximación lineal de primer orden del modelo en torno a \mathbf{x}_0 :

$$f_{\theta}(\mathbf{x}_0 + \Delta \mathbf{x}) \approx f_{\theta}(\mathbf{x}_0) + \nabla_{\mathbf{x}} f_{\theta}(\mathbf{x}_0)^{\top} \Delta \mathbf{x} \quad (2.28)$$

Esta expansión de Taylor permite cuantificar cómo pequeñas perturbaciones en variables fisiológicas (por ejemplo, ritmo o frecuencia cardíaca) impactan la predicción de la economía de carrera. En modelos de redes neuronales profundas, el gradiente puede calcularse eficientemente mediante retropropagación, utilizando la

regla de la cadena para propagar derivadas desde la salida hacia las entradas (Goodfellow et al., 2016; Bishop and Bishop, 2023). Si el modelo está compuesto por una sucesión de capas:

$$\mathbf{h}^{(l)} = g^{(l)}(\mathbf{h}^{(l-1)}) \quad (2.29)$$

Entonces la derivada respecto a la entrada se obtiene como:

$$\frac{\partial \hat{y}}{\partial \mathbf{x}} = \frac{\partial \hat{y}}{\partial \mathbf{h}^{(L)}} \prod_{l=L}^1 \frac{\partial \mathbf{h}^{(l)}}{\partial \mathbf{h}^{(l-1)}} \quad (2.30)$$

Donde cada término corresponde al Jacobiano de la transformación de una capa. Además del gradiente simple, pueden considerarse medidas normalizadas de sensibilidad para comparar variables con diferentes escalas:

$$S_i^{norm} = \frac{\partial f_{\theta}}{\partial x_i} \cdot \frac{\sigma_{x_i}}{\sigma_{\hat{y}}} \quad (2.31)$$

Donde σ_{x_i} y $\sigma_{\hat{y}}$ representan las desviaciones estándar de la variable de entrada y de la salida, respectivamente. Otra formulación relevante es el análisis basado en perturbaciones finitas, donde se evalúa:

$$S_i^{\Delta} = \frac{f_{\theta}(\mathbf{x}_0 + \delta \mathbf{e}_i) - f_{\theta}(\mathbf{x}_0)}{\delta} \quad (2.32)$$

Siendo \mathbf{e}_i el vector unitario en la dirección i y δ una perturbación pequeña. Este enfoque resulta útil cuando el modelo es altamente no lineal o cuando se desea validar la estabilidad numérica del gradiente. Desde una perspectiva probabilística, si el modelo aproxima una distribución condicional $p(y | \mathbf{x})$, el análisis de sensibilidad puede extenderse a:

$$\frac{\partial}{\partial x_i} \log p(y | \mathbf{x}) \tag{2.33}$$

Lo cual permite evaluar cómo cambios locales en las variables influyen en la verosimilitud predicha, proporcionando una interpretación en términos de información (Goodfellow et al., 2016). En el contexto de modelos secuenciales como LSTM, donde la predicción depende de una trayectoria completa $\mathbf{x}_{1:T}$, la sensibilidad puede evaluarse respecto a un instante específico:

$$\frac{\partial \hat{y}_T}{\partial x_{t,i}} \tag{2.34}$$

Permitiendo identificar qué momentos temporales influyen más en la predicción final. Esto resulta especialmente relevante en el análisis de fatiga acumulada durante una carrera. Desde el punto de vista teórico, el análisis de sensibilidad local proporciona una aproximación lineal de un modelo no lineal complejo en una vecindad específica del espacio de entrada. Esta aproximación es coherente con la interpretación de redes profundas como composiciones diferenciables de funciones no lineales, donde la derivabilidad casi en todas partes permite aplicar herramientas de cálculo diferencial para interpretar el comportamiento interno del modelo (Goodfellow et al., 2016; Bishop and Bishop, 2023).

En síntesis, el análisis de sensibilidad local se fundamenta en el cálculo de gradientes y expansiones de Taylor de primer orden para cuantificar la influencia marginal de cada variable de entrada sobre la salida del modelo. Matemáticamente, constituye una herramienta basada en derivadas parciales y Jacobianos que permite evaluar estabilidad, robustez e interpretabilidad de modelos de inteligencia artificial en entornos de alta dimensionalidad.

Análisis de Importancia Global de Variables (SHAP)

El análisis de importancia global de variables permite cuantificar la contribución de cada variable de entrada en la predicción del modelo. En este contexto, los valores SHAP (SHapley Additive exPlanations) representan un método basado en teoría de juegos que permite asignar una contribución individual a cada variable dentro

del resultado final del modelo.

La utilización de SHAP en modelos de aprendizaje profundo permite mejorar la interpretabilidad al proporcionar una descomposición aditiva de la predicción, facilitando la identificación de qué variables influyen positiva o negativamente en la estimación de la economía de carrera. Esta característica resulta especialmente relevante en aplicaciones deportivas, donde la interpretabilidad es necesaria para traducir predicciones en recomendaciones prácticas para entrenamiento.

En el contexto de este proyecto, el análisis SHAP permite identificar la relevancia global de variables fisiológicas y biomecánicas, facilitando la generación de recomendaciones personalizadas mediante modelos de lenguaje de gran escala. La integración de interpretabilidad con modelos predictivos fortalece la confianza en el sistema y permite validar que las recomendaciones generadas estén alineadas con principios fisiológicos y biomecánicos conocidos (Shao et al., 2021; Bailey et al., 2023).

Desde una formulación matemática general, sea un modelo predictivo entrenado representado como una función:

$$f_{\theta} : \mathbb{R}^d \rightarrow \mathbb{R} \tag{2.35}$$

Donde $\mathbf{x} = (x_1, \dots, x_d)$ es el vector de variables de entrada y $f_{\theta}(\mathbf{x})$ es la predicción del modelo. El método SHAP se fundamenta en la teoría de juegos cooperativos, específicamente en el valor de Shapley, el cual asigna de manera equitativa la contribución de cada variable al resultado del modelo (Goodfellow et al., 2016; Bishop and Bishop, 2023). En este marco, cada variable de entrada x_i se considera un "jugador" dentro de un juego cooperativo donde la función de valor se define como:

$$v(S) = \mathbb{E}[f_{\theta}(\mathbf{x}) \mid \mathbf{x}_S] \tag{2.36}$$

Donde $S \subseteq \{1, \dots, d\}$ representa un subconjunto de variables y \mathbf{x}_S denota las variables observadas en dicho subconjunto. El valor de Shapley asociado a la variable i se define como:

$$\phi_i = \sum_{S \subseteq \mathcal{N} \setminus \{i\}} \frac{|S|!(d - |S| - 1)!}{d!} [v(S \cup \{i\}) - v(S)] \quad (2.37)$$

Donde $\mathcal{N} = \{1, \dots, d\}$ es el conjunto total de variables. Esta expresión representa el promedio ponderado de la contribución marginal de la variable i sobre todos los posibles subconjuntos. Los valores SHAP satisfacen propiedades fundamentales:

- Eficiencia:

$$\sum_{i=1}^d \phi_i = f_{\theta}(\mathbf{x}) - \mathbb{E}[f_{\theta}(\mathbf{x})] \quad (2.38)$$

Garantizando que la suma de contribuciones explique completamente la desviación respecto al valor esperado del modelo.

- Simetría: Variables con contribuciones idénticas reciben el mismo valor.
- Linealidad: La explicación de una combinación lineal de modelos es la combinación lineal de sus explicaciones.
- Nulidad: Si una variable no contribuye marginalmente en ningún subconjunto, su valor SHAP es cero.

El cálculo exacto de ϕ_i requiere evaluar 2^d subconjuntos, lo cual resulta computacionalmente inviable para modelos de alta dimensión. Por ello, se emplean aproximaciones basadas en muestreo de Monte Carlo o métodos específicos para redes neuronales profundas, como DeepSHAP (Goodfellow et al., 2016; Kamath et al., 2024). Una aproximación práctica puede expresarse como:

$$\phi_i \approx \frac{1}{M} \sum_{m=1}^M [f_{\theta}(\mathbf{x}_{S_m \cup \{i\}}) - f_{\theta}(\mathbf{x}_{S_m})] \quad (2.39)$$

Donde S_m son subconjuntos muestreados aleatoriamente. Desde una perspectiva probabilística, si el modelo aproxima una distribución condicional $p(y | \mathbf{x})$, puede considerarse:

$$f_{\theta}(\mathbf{x}) = \log p(y | \mathbf{x}) \quad (2.40)$$

Permitiendo interpretar las contribuciones en términos de cambios en log-verosimilitud o probabilidad predicha (Goodfellow et al., 2016). Para obtener una medida de importancia global, se calcula el promedio del valor absoluto de las contribuciones sobre un conjunto de datos:

$$I_i^{global} = \mathbb{E}_{\mathbf{x}} [|\phi_i(\mathbf{x})|] \quad (2.41)$$

Lo cual cuantifica la relevancia promedio de cada variable en el comportamiento general del modelo. En el contexto del modelado de la economía de carrera, la predicción puede expresarse como una descomposición aditiva:

$$f_{\theta}(\mathbf{x}) = \mathbb{E}[f_{\theta}(\mathbf{x})] + \sum_{i=1}^d \phi_i \quad (2.42)$$

Proporcionando una representación interpretable incluso cuando f_{θ} es altamente no lineal. Este marco permite identificar qué variables fisiológicas y biomecánicas incrementan o disminuyen la estimación de eficiencia energética.

En síntesis, el análisis de importancia global mediante SHAP se fundamenta en el valor de Shapley de la teoría de juegos cooperativos, modelado como un promedio ponderado de contribuciones marginales sobre todos los subconjuntos posibles de variables. Su formulación garantiza consistencia, descomposición aditiva e interpretabilidad matemática rigurosa en modelos de inteligencia artificial complejos (Goodfellow et al., 2016; Bishop and Bishop, 2023; Kamath et al., 2024).

2.4. Modelos de Inteligencia Artificial Generativa

La inteligencia artificial generativa constituye un área emergente dentro del campo de la inteligencia artificial enfocada en la creación de contenido nuevo a partir de patrones aprendidos en grandes volúmenes de datos. Estos modelos son capaces de generar texto, imágenes, audio y código, mediante el aprendizaje de distribuciones probabilísticas complejas presentes en los datos de entrenamiento. Su desarrollo ha sido impulsado principalmente por avances en aprendizaje profundo, aumento en la capacidad computacional y disponibilidad de grandes conjuntos de datos (Goodfellow et al., 2016; LeCun et al., 2015).

A diferencia de los modelos tradicionales de aprendizaje automático orientados únicamente a tareas de clasificación o regresión, los modelos generativos permiten la síntesis de información nueva manteniendo coherencia estadística con los datos originales. Dentro de esta categoría se incluyen arquitecturas como redes generativas adversariales (*Generative Adversarial Networks*, GANs), autoencoders variacionales (*Variational Autoencoders*, VAEs) y modelos basados en transformadores, siendo estos últimos los más utilizados en aplicaciones modernas de procesamiento de lenguaje natural (Goodfellow et al., 2016).

En el ámbito del deporte y análisis del rendimiento, la inteligencia artificial generativa abre nuevas posibilidades para transformar predicciones numéricas en recomendaciones prácticas y contextualizadas. En particular, permite integrar resultados provenientes de modelos predictivos con sistemas capaces de generar retroalimentación personalizada orientada a mejorar el rendimiento deportivo. Este enfoque facilita la traducción de datos fisiológicos y biomecánicos complejos en estrategias comprensibles y aplicables para corredores amateur.

2.4.1. Modelos de Lenguaje de Gran Escala

Los modelos de lenguaje de gran escala (*Large Language Models*, LLM) son sistemas de aprendizaje profundo entrenados sobre grandes volúmenes de texto con el objetivo de comprender y generar lenguaje natural. Estos modelos utilizan principalmente arquitecturas basadas en transformadores, las cuales permiten capturar dependencias contextuales a largo alcance mediante mecanismos de atención (Goodfellow et al., 2016).

Los LLM son capaces de realizar tareas complejas como generación de texto, resumen automático, traducción, análisis semántico y generación de recomendaciones contextuales. Su funcionamiento se basa en el modelado probabilístico de secuencias de palabras, permitiendo generar texto coherente basado en un contexto o

instrucción inicial.

En aplicaciones relacionadas con el rendimiento deportivo, los LLM permiten transformar resultados cuantitativos provenientes de modelos predictivos en recomendaciones interpretables para atletas y entrenadores. En el contexto de la economía de carrera, estos modelos pueden utilizar información derivada de análisis de sensibilidad e importancia de variables para generar sugerencias orientadas a optimizar la eficiencia energética del corredor.

La integración de LLM con modelos predictivos de series temporales representa un avance significativo en sistemas de apoyo a la toma de decisiones basados en datos. Este enfoque permite no solo predecir métricas fisiológicas, sino también proporcionar interpretaciones contextualizadas y estrategias de mejora personalizadas, facilitando la adopción práctica de herramientas de inteligencia artificial en entornos deportivos reales.

Desde una perspectiva teórica, los LLM pueden entenderse como modelos probabilísticos autorregresivos parametrizados mediante redes neuronales profundas basadas en la arquitectura *Transformer*. Su objetivo fundamental consiste en modelar la distribución conjunta de una secuencia de *tokens* $\{x_1, x_2, \dots, x_T\}$ mediante la factorización:

$$p(x_1, x_2, \dots, x_T) = \prod_{t=1}^T p(x_t | x_1, \dots, x_{t-1}) \quad (2.43)$$

Donde cada término condicional es aproximado por una red neuronal con millones o miles de millones de parámetros (Goodfellow et al., 2016; Kamath et al., 2024). En la práctica, los LLM representan cada *token* x_t mediante un vector continuo en un espacio de dimensión d utilizando una matriz de embeddings $\mathbf{E} \in \mathbb{R}^{V \times d}$, donde V es el tamaño del vocabulario. Así, la representación inicial es:

$$\mathbf{z}_t^{(0)} = \mathbf{E}[x_t] + \mathbf{p}_t \quad (2.44)$$

Donde \mathbf{p}_t corresponde al vector de codificación posicional, necesario debido a la ausencia de recurrencia explícita en la arquitectura *Transformer*. El núcleo matemático del modelo es el mecanismo de autoatención

(*self-attention*), que permite capturar dependencias de largo alcance sin recurrencia secuencial. Dada una matriz de representaciones $\mathbf{Z} \in \mathbb{R}^{T \times d}$, se definen tres proyecciones lineales:

$$\mathbf{Q} = \mathbf{Z}\mathbf{W}^Q \quad \mathbf{K} = \mathbf{Z}\mathbf{W}^K \quad \mathbf{V} = \mathbf{Z}\mathbf{W}^V \quad (2.45)$$

Donde $\mathbf{W}^Q, \mathbf{W}^K, \mathbf{W}^V \in \mathbb{R}^{d \times d_k}$ son matrices de parámetros entrenables. La atención escalada se define como:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^\top}{\sqrt{d_k}}\right) \mathbf{V} \quad (2.46)$$

Esta operación calcula pesos de relevancia entre todos los pares de posiciones de la secuencia, permitiendo que cada *token* incorpore información contextual global. En modelos autorregresivos se aplica una máscara triangular para garantizar la causalidad, evitando el acceso a tokens futuros (Kamath et al., 2024). Los LLM emplean atención multi-cabeza (*multi-head attention*), donde el mecanismo anterior se replica H veces con diferentes proyecciones lineales:

$$\text{MultiHead}(\mathbf{Z}) = \text{Concat}(\text{head}_1, \dots, \text{head}_H) \mathbf{W}^O \quad (2.47)$$

Cada capa Transformer incluye además una red feedforward completamente conectada aplicada de manera independiente a cada posición:

$$\text{FFN}(\mathbf{z}) = \sigma(\mathbf{z}\mathbf{W}_1 + \mathbf{b}_1) \mathbf{W}_2 + \mathbf{b}_2 \quad (2.48)$$

Donde $\sigma(\cdot)$ es típicamente GELU o ReLU. Las capas se organizan con conexiones residuales y normalización, formando una composición profunda de transformaciones no lineales:

$$\mathbf{Z}^{(l+1)} = \text{LayerNorm} \left(\mathbf{Z}^{(l)} + \text{MultiHead}(\mathbf{Z}^{(l)}) \right) \quad (2.49)$$

Seguida de la subcapa *feedforward* con estructura residual similar (Goodfellow et al., 2016; Kamath et al., 2024). La probabilidad condicional de cada *token* se obtiene proyectando la representación final $\mathbf{z}_t^{(L)}$ al espacio del vocabulario:

$$p(x_t | x_{<t}) = \text{softmax} \left(\mathbf{W}_{out} \mathbf{z}_t^{(L)} \right) \quad (2.50)$$

El entrenamiento consiste en minimizar la pérdida de entropía cruzada negativa:

$$\mathcal{L}(\theta) = - \sum_{t=1}^T \log p(x_t^{\text{true}} | x_{<t}) \quad (2.51)$$

Mediante optimización estocástica basada en gradiente sobre grandes corpus textuales (Goodfellow et al., 2016). En modelos de gran escala, el número de parámetros puede superar los miles de millones, lo que incrementa significativamente la capacidad de aproximación funcional.

Desde el punto de vista teórico, los LLM pueden interpretarse como aproximadores universales de distribuciones sobre secuencias discretas de alta dimensión. A diferencia de las RNN y LSTM, que modelan la secuencia mediante ecuaciones en diferencias, los LLM implementan una transformación global basada en atención, donde la dependencia temporal se modela mediante interacciones bilineales entre todas las posiciones. Esto elimina la dependencia secuencial estricta y permite paralelización eficiente durante el entrenamiento (Kamath et al., 2024).

En aplicaciones orientadas al rendimiento deportivo, los LLM no modelan directamente variables fisiológicas continuas, sino que operan sobre representaciones simbólicas o textuales derivadas de modelos cuantitativos. Matemáticamente, pueden considerarse como funciones de mapeo:

$$f_{\theta} : \mathcal{T} \rightarrow \mathcal{T} \tag{2.52}$$

Donde \mathcal{T} es el espacio de secuencias de tokens. Al integrar resultados de modelos predictivos (por ejemplo, sensibilidad de variables o predicciones de economía de carrera), los LLM generan descripciones interpretativas coherentes basadas en conocimiento aprendido implícitamente durante el preentrenamiento.

En síntesis, los LLM constituyen modelos probabilísticos autorregresivos implementados mediante arquitecturas Transformer profundas, caracterizadas por mecanismos de autoatención escalada, entrenamiento mediante máxima verosimilitud y capacidad de representación de alta dimensión. Su formulación matemática se basa en el modelado explícito de distribuciones condicionales sobre secuencias discretas, permitiendo capturar dependencias contextuales de largo alcance y generar lenguaje natural coherente a gran escala (Goodfellow et al., 2016; Kamath et al., 2024).

2.4.2. Evaluación e Interpretabilidad

La evaluación de modelos generativos presenta retos adicionales en comparación con modelos predictivos tradicionales, debido a la naturaleza abierta y contextual de las salidas generadas. En este sentido, la evaluación suele realizarse mediante una combinación de métricas automáticas y evaluación humana, permitiendo medir coherencia, relevancia y utilidad práctica del contenido generado (Goodfellow et al., 2016).

En aplicaciones orientadas a la generación de recomendaciones deportivas, la evaluación humana adquiere especial relevancia, ya que permite validar la aplicabilidad práctica de las recomendaciones generadas en contextos reales de entrenamiento. Este proceso puede incluir la revisión manual de las recomendaciones generadas por el modelo, evaluando criterios como consistencia fisiológica, coherencia biomecánica y utilidad para la mejora del rendimiento.

Desde la perspectiva de la interpretabilidad, la integración de LLM con modelos explicables permite aumentar la transparencia del sistema. En este contexto, los resultados de análisis de sensibilidad y métodos de importancia global de variables pueden ser utilizados como insumos estructurados dentro del *prompt*, permitiendo que el modelo generativo produzca recomendaciones alineadas con evidencia cuantitativa proveniente del modelo predictivo.

Este enfoque híbrido, que combina modelos predictivos, técnicas de interpretabilidad y modelos generativos, permite construir sistemas de apoyo a la toma de decisiones más confiables y explicables. La combinación de evaluación automática, validación experimental y evaluación manual fortalece la robustez del sistema, garantizando que las recomendaciones generadas sean coherentes con principios fisiológicos, biomecánicos y de entrenamiento deportivo.

En conjunto, la integración de modelos generativos con modelos predictivos de aprendizaje profundo representa un avance importante en el desarrollo de sistemas inteligentes aplicados al deporte, permitiendo transformar datos complejos en conocimiento práctico y accionable para la mejora del rendimiento en corredores amateur.

Capítulo 3

Sistema para la Estimación y Mejora de la Economía de Carrera

El análisis y mejora del rendimiento en carrera no solo exige la comprensión teórica de sus determinantes fisiológicos y biomecánicos, sino también el desarrollo de enfoques metodológicos capaces de modelar y cuantificar dichas dinámicas en contextos reales de entrenamiento. La creciente disponibilidad de datos provenientes de dispositivos inteligentes y el avance de las técnicas de inteligencia artificial han abierto nuevas posibilidades para abordar la economía de carrera desde una perspectiva computacional y aplicada. En este sentido, la construcción de un marco metodológico estructurado resulta fundamental para articular la captura, procesamiento y análisis de información, así como para integrar herramientas predictivas e interpretativas que permitan transformar datos complejos en conocimiento útil para la optimización del rendimiento deportivo.

3.1. Descripción del Sistema

El sistema propuesto se concibe como una arquitectura híbrida orientada a la estimación y análisis de la economía de carrera a partir de datos fisiológicos y biomecánicos obtenidos en condiciones reales de entrenamiento. Su estructura integra un modelo predictivo basado en una red neuronal LSTM, encargado de modelar la dinámica temporal de las variables asociadas al rendimiento y generar estimaciones cuantitativas,

junto con un modelo generativo fundamentado en un LLM, orientado a la interpretación de los resultados y a la producción de retroalimentación contextualizada. Esta combinación permite no solo estimar el desempeño, sino también traducir los resultados en información comprensible y aplicable para el usuario.

La interacción entre ambos modelos se articula mediante un flujo de procesamiento secuencial que inicia con el tratamiento de las señales registradas, continúa con la generación de predicciones a través del modelo LSTM y culmina con la elaboración de análisis interpretativos mediante el LLM. De esta manera, el sistema trasciende un enfoque exclusivamente numérico y configura una solución integral que combina aprendizaje profundo y capacidades generativas, estableciendo un vínculo entre el modelado computacional de datos y la toma de decisiones orientada a la optimización del entrenamiento deportivo. En la Figura 3.1 se presenta un diagrama que ilustra la arquitectura híbrida y el flujo general de información entre ambos modelos.

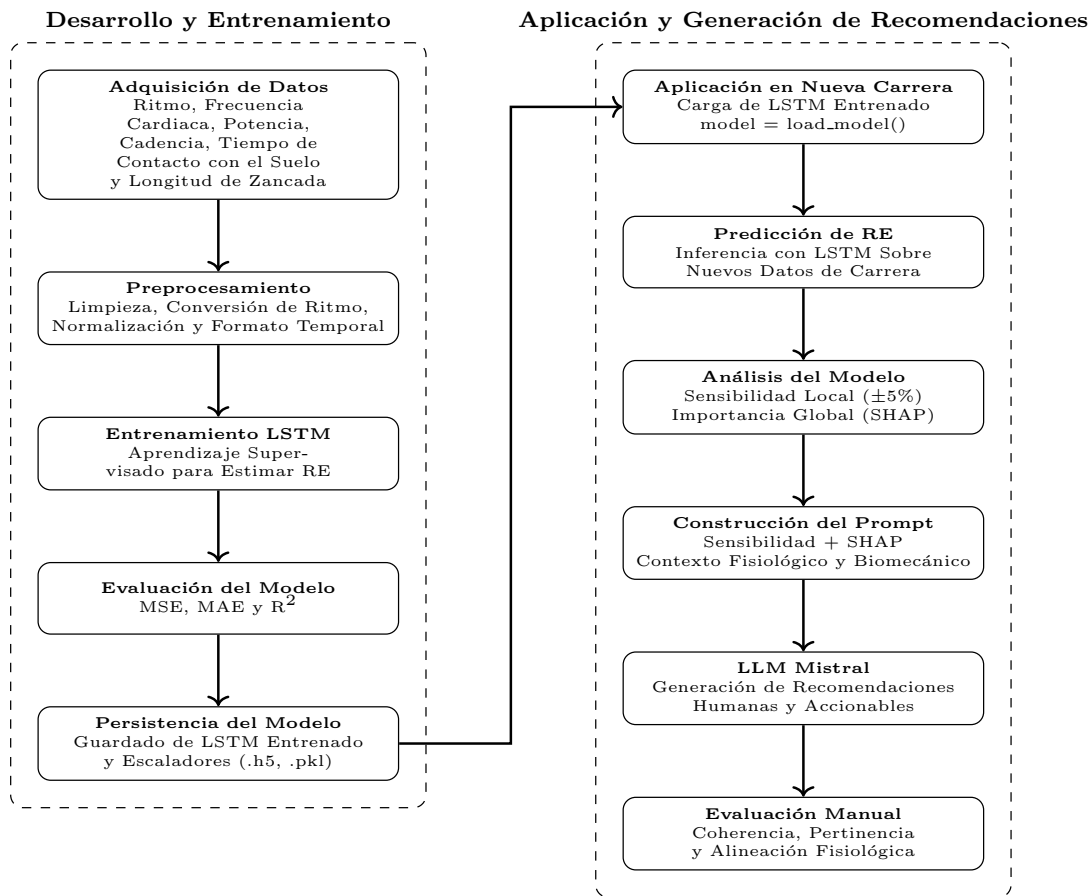


Figura 3.1: Arquitectura híbrida para la predicción y análisis del rendimiento en carrera.

3.2. Adquisición y Preprocesamiento de Datos

La obtención y preparación de los datos constituyen una etapa fundamental para garantizar la confiabilidad y solidez del modelo propuesto. Debido a que el desempeño de los algoritmos de aprendizaje profundo depende en gran medida de la calidad, coherencia y estructura de la información de entrada, se estableció un proceso sistemático orientado a asegurar consistencia en las mediciones, adecuación de las variables y correcta organización de los datos para su posterior modelado. Este proceso permitió transformar los registros crudos de entrenamiento en un conjunto estructurado y analíticamente robusto, apto para el análisis predictivo de la economía de carrera.

3.2.1. Fuentes de Datos

El conjunto de datos utilizado se generó a partir de registros históricos de actividades de carrera recopilados mediante un reloj inteligente Garmin Epix™ Pro (Gen. 2). De acuerdo con la documentación técnica del fabricante, este dispositivo permite capturar múltiples variables fisiológicas y biomecánicas relevantes para el análisis del rendimiento, entre ellas el ritmo promedio, la frecuencia cardíaca, la potencia de carrera, la cadencia, el tiempo de contacto con el suelo y la longitud de zancada (Garmin Ltd., 2023).

Los datos fueron exportados en formato CSV (*comma-separated values*), lo que permitió su procesamiento mediante herramientas de análisis en Python. Cada fila del conjunto de datos corresponde a un segmento de carrera de 1 km, lo que garantiza una estructura homogénea para el modelado secuencial posterior. La selección del dispositivo se sustentó en su precisión reportada en la medición de la frecuencia cardíaca mediante sensores ópticos, con alta concordancia respecto a sistemas de electrocardiografía (ECG) en diferentes intensidades de ejercicio (Jamieson et al., 2024). Esta confiabilidad respalda la validez de las variables fisiológicas empleadas en el estudio. La Tabla 3.1 muestra una porción del conjunto de datos utilizada para el entrenamiento del modelo.

Tabla 3.1: Porción del conjunto de datos utilizada para el entrenamiento del modelo

Fila	Ritmo (min/km)	Frecuencia cardíaca (bpm)	Potencia (W)	Cadencia (spm)	Tiempo de contacto con el suelo (ms)	Longitud de zancada (m)
1	5:25	144	341	171	257	1.07
2	5:13	154	362	172	252	1.12
3	5:39	147	333	167	257	1.05
⋮	⋮	⋮	⋮	⋮	⋮	⋮
498	5:20	171	361	174	251	1.07
499	5:16	172	361	175	249	1.08
500	5:02	176	376	177	244	1.12

3.2.2. Variables Analizadas

Las variables consideradas integran métricas fisiológicas y biomecánicas directamente asociadas con el rendimiento en carrera. Como variables de entrada se emplearon: ritmo promedio (min/km), frecuencia cardíaca promedio (bpm), potencia promedio (W), cadencia promedio (spm), tiempo de contacto con el suelo (ms) y longitud de zancada (m). Estas características constituyen un conjunto representativo de la interacción entre demanda metabólica y mecánica del movimiento.

Adicionalmente, a partir del ritmo promedio se estimaron variables derivadas relacionadas con el consumo de oxígeno y la economía de carrera. En particular, el consumo de oxígeno (VO_2 , ml/kg/min) y la economía de carrera (RE, ml/kg/km) se calcularon utilizando las ecuaciones propuestas por Barnes y Kilding (Barnes and Kilding, 2015). La variable RE fue definida como el objetivo del modelo predictivo, al representar una medida directa de la eficiencia metabólica por unidad de distancia recorrida.

3.2.3. Preprocesamiento de Datos

Con el objetivo de garantizar consistencia y estabilidad numérica durante el entrenamiento del modelo, se implementó un pipeline de preprocesamiento en Python. En primer lugar, el ritmo promedio registrado en formato `mm:ss` fue convertido a minutos por kilómetro como valor numérico en punto flotante, permitiendo su manipulación matemática y la posterior estimación de velocidad. A partir de esta conversión se calcularon la velocidad (km/min), el VO_2 y el RE para cada segmento.

Posteriormente, se seleccionaron las variables de entrada y se aplicó un proceso de estandarización mediante la técnica de normalización tipo *z-score*, utilizando la implementación `StandardScaler` de la biblioteca `scikit-learn` (Pedregosa et al., 2011). Este procedimiento asegura que todas las variables contribuyan de manera proporcional al proceso de aprendizaje y mejora la estabilidad del entrenamiento. Finalmente, debido a la naturaleza secuencial del modelo, se incorporó una dimensión temporal adicional al conjunto de características, obteniendo una estructura de entrada con forma $(samples, 1, features)$, donde cada muestra corresponde a un segmento de 1 km.

3.3. Diseño del Modelo Predictivo

El diseño del modelo predictivo tuvo como objetivo estimar la economía de carrera a partir de variables fisiológicas y biomecánicas registradas por segmento de kilómetro. Dado el carácter secuencial y dependiente del tiempo de los datos, se optó por una arquitectura basada en redes neuronales recurrentes del tipo LSTM, debido a su capacidad para modelar dependencias temporales y patrones no lineales en series de tiempo fisiológicas.

El flujo general del modelo incluyó: (1) preprocesamiento y normalización de variables, (2) estructuración de los datos en formato secuencial compatible con LSTM, (3) entrenamiento supervisado bajo un esquema de regresión, y (4) evaluación cuantitativa e interpretabilidad mediante técnicas de sensibilidad local y análisis global de importancia de variables.

3.3.1. Arquitectura

La arquitectura implementada consistió en un modelo secuencial desarrollado utilizando TensorFlow y Keras. TensorFlow es una biblioteca de código abierto desarrollada por Google para el aprendizaje automático y la computación numérica de alto rendimiento, basada en grafos computacionales y optimizada para ejecución en CPU (*Central Processing Unit*) y GPU (*Graphics Processing Unit*) (Abadi et al., 2016). Su diseño permite construir, entrenar y desplegar modelos de aprendizaje profundo de manera escalable y eficiente.

Por su parte, Keras es una API de alto nivel integrada en TensorFlow que facilita la construcción y experimentación con redes neuronales mediante una interfaz modular, intuitiva y orientada a prototipado

rápido (Chollet et al., 2015). Keras abstrae la complejidad de bajo nivel del entrenamiento, permitiendo definir arquitecturas profundas a través de componentes como capas, funciones de activación, optimizadores y métricas.

En este trabajo se utilizó la API `Sequential` de Keras, la cual permite construir modelos lineales capa por capa de forma estructurada. El modelo está compuesto por:

- Una capa LSTM con 64 unidades ocultas.
- Una capa *Dropout* con tasa de 0.20 para regularización.
- Una capa densa intermedia de 32 neuronas con función de activación ReLU.
- Una capa densa de salida con una neurona y activación lineal.

La capa LSTM constituye el núcleo del modelo. Cada celda LSTM incorpora mecanismos de compuertas (*input gate*, *forget gate* y *output gate*) que regulan el flujo de información entre estados temporales. Esta estructura permite conservar información relevante de pasos anteriores y descartar aquella que no contribuye significativamente a la predicción, mitigando el problema del desvanecimiento del gradiente típico de redes recurrentes simples.

Posterior a la capa LSTM se incorpora una capa *Dropout*, la cual consiste en una técnica de regularización que desactiva aleatoriamente un porcentaje de neuronas durante cada iteración de entrenamiento. En este caso, se empleó una tasa de 0.20, lo que implica que el 20 % de las salidas neuronales se anulan temporalmente en cada actualización de pesos. Este mecanismo evita que el modelo dependa excesivamente de neuronas específicas, reduce la co-adaptación entre ellas y disminuye el riesgo de sobreajuste. Como efecto, el modelo tiende a generalizar mejor sobre datos no vistos, manteniendo estabilidad en la fase de validación y prueba.

En la arquitectura utilizada, la entrada tiene dimensión ($timesteps = 1, features = n$), donde n corresponde a las variables biomecánicas y fisiológicas seleccionadas: ritmo promedio, frecuencia cardiaca promedio, potencia promedio, cadencia, tiempo de contacto con el suelo y longitud de zancada. Aunque se empleó un solo timestep por segmento, la naturaleza recurrente del modelo permite capturar relaciones no lineales entre variables y su contribución a la RE.

La función de activación ReLU en la capa densa intermedia favorece una convergencia más rápida y reduce la probabilidad de gradientes pequeños. La capa de salida utiliza activación lineal, coherente con la naturaleza continua del problema de regresión. El modelo fue compilado utilizando el optimizador Adam (*Adaptive*

Moment Estimation) y la función de pérdida MSE, incluyendo además MAE como métrica adicional de monitoreo.

3.3.2. Entrenamiento

Previo al entrenamiento, las variables de entrada fueron estandarizadas mediante *StandardScaler*, garantizando media cero y varianza unitaria. De igual manera, la variable objetivo (RE) fue escalada para estabilizar el proceso de optimización y posteriormente transformada a su escala original para la evaluación final.

El conjunto de datos fue dividido en entrenamiento y prueba utilizando una partición 80/20 sin barajado (*shuffle=False*), preservando el orden temporal y evitando fuga de información entre segmentos futuros y pasados.

El modelo fue entrenado bajo las siguientes condiciones:

- Tamaño de lote (*batch size*): 16
- Máximo de épocas: 500
- *Validation split*: 15% del conjunto de entrenamiento
- Función de pérdida: MSE
- Métricas monitoreadas: MAE y MSE

Se implementaron dos mecanismos de control para evitar sobreajuste:

1. *Early Stopping*: Monitoreo de la pérdida de validación con paciencia de 20 épocas y restauración automática de los mejores pesos.
2. *Model Checkpoint*: Almacenamiento automático del modelo con menor error de validación.

La selección de hiperparámetros (64 unidades LSTM, 0.20 de *dropout*, 32 neuronas densas, *batch size* de 16) fue resultado de un proceso iterativo de experimentación, buscando un equilibrio entre capacidad de modelado, estabilidad numérica y eficiencia computacional. La configuración final mostró una convergencia estable y una adecuada capacidad de generalización en el conjunto de prueba.

3.3.3. Evaluación e Interpretabilidad

Una vez entrenado el modelo, su desempeño fue evaluado sobre el conjunto de prueba utilizando métricas estándar de regresión. Además de la evaluación cuantitativa, se incorporaron técnicas de interpretabilidad para comprender el impacto de cada variable en la predicción de la economía de carrera. El análisis incluyó tres componentes principales: métricas de error, análisis de sensibilidad local y análisis de importancia global mediante SHAP.

Métricas

El desempeño del modelo se evaluó mediante tres métricas:

- *Mean Squared Error* (MSE): Penaliza de forma cuadrática las desviaciones entre valores reales y predichos, enfatizando errores grandes.
- *Mean Absolute Error* (MAE): Mide el error absoluto promedio, ofreciendo una interpretación directa en las unidades originales de la RE.
- Coeficiente de Determinación (R^2): Cuantifica la proporción de varianza explicada por el modelo respecto a la variabilidad total observada.

Adicionalmente, se analizaron gráficamente:

1. La comparación entre valores reales y predichos en entrenamiento y prueba.
2. La evolución de MSE y MAE a lo largo de las épocas para identificar patrones de convergencia y posibles indicios de sobreajuste.

Análisis de Sensibilidad Local

El análisis de sensibilidad local se realizó perturbando individualmente cada variable de entrada en un $\pm 5\%$ y observando la variación resultante en la predicción de RE.

Para cada característica x_i , se calculó:

$$\Delta RE_i = RE(x_i \cdot (1 + \delta)) - RE(x_i)$$

Donde $\delta = 0.05$.

Este procedimiento permitió cuantificar la influencia marginal de cada variable en un punto específico del espacio de entrada. Un valor positivo de ΔRE indica que el incremento de la variable mejora la economía de carrera (mayor eficiencia), mientras que un valor negativo indica deterioro en la eficiencia. El análisis de sensibilidad proporciona una interpretación local del comportamiento del modelo y facilita la generación de recomendaciones prácticas basadas en la respuesta individual del sistema.

Análisis de Importancia Global de Variables (SHAP)

Para complementar la interpretación local, se empleó SHAP (SHapley Additive exPlanations), utilizando el método *KernelExplainer* para estimar la contribución de cada variable a la predicción del modelo. SHAP asigna a cada característica un valor de contribución basado en teoría de juegos cooperativos, representando cuánto aporta cada variable, positiva o negativamente, respecto a una predicción promedio. El análisis permitió:

- Identificar las variables con mayor impacto global en la estimación de RE.
- Evaluar consistencia entre importancia global (SHAP) y sensibilidad local.
- Detectar posibles interacciones no lineales entre variables fisiológicas y biomecánicas.

La combinación de métricas cuantitativas, sensibilidad local y análisis SHAP proporcionó un marco integral de evaluación, no solo midiendo precisión predictiva, sino también asegurando interpretabilidad y coherencia fisiológica en los resultados del modelo.

3.4. Diseño del Modelo Generativo

El modelo generativo fue incorporado como un módulo complementario al sistema predictivo de economía de carrera. Su objetivo principal fue transformar resultados cuantitativos derivados del análisis de sensibilidad local y del análisis global de importancia de variables (SHAP) en retroalimentación técnica comprensible, estructurada y accionable para el usuario.

A diferencia del modelo predictivo, cuya naturaleza es puramente numérica y orientada a regresión, el modelo generativo cumple una función semántica e interpretativa. Su propósito no es realizar estimaciones fisiológicas, sino traducir información estructurada en recomendaciones coherentes desde el punto de vista biomecánico y del entrenamiento de resistencia. El flujo general del módulo generativo comprende las siguientes etapas:

1. Construcción de un *payload* estructurado que contiene:
 - Resultados de sensibilidad local (ΔRE).
 - Importancia global de variables (valores absolutos SHAP).
2. Generación de un *prompt* con instrucciones explícitas.
3. Inferencia mediante un modelo de lenguaje de gran escala.
4. Producción de retroalimentación textual clara, breve y accionable.

3.4.1. Arquitectura

La arquitectura generativa se basa en un LLM preentrenado de tipo autoregresivo, específicamente la versión instruccional de Mistral 7B. El modelo utilizado fue:

- Modelo: Mistral-7B-Instruct-v0.2
- Tipo: Transformer autoregresivo *decoder-only*
- Precisión: float16
- Ejecución: GPU (cuando disponible) mediante *device_map=auto*

La arquitectura *Transformer* emplea mecanismos de autoatención multi-cabeza que permiten modelar dependencias de largo alcance dentro del texto generado. A diferencia de modelos recurrentes, los *Transformers* procesan la información de manera paralela y capturan relaciones contextuales mediante matrices de atención.

En este sistema, el modelo generativo no fue reentrenado; se utilizó en modalidad *zero-shot instruction following*. La especialización hacia el dominio de biomecánica y resistencia se logró exclusivamente mediante ingeniería de *prompt*, incluyendo:

- Definición de rol: Especialista en biomecánica y entrenamiento.
- Restricciones explícitas (no inventar métricas, no mencionar IA).
- Límite máximo de recomendaciones.
- Instrucciones estructuradas sobre tareas a realizar.

El proceso de generación utilizó muestreo controlado con:

- *Temperature*: 0.4
- *Top-p*: 0.9
- *Repetition penalty*: 1.1
- *Max new tokens*: 350

Estos parámetros fueron seleccionados para favorecer coherencia, baja variabilidad estocástica y respuestas técnicamente consistentes.

3.4.2. Entrenamiento

El modelo generativo no fue entrenado ni ajustado finamente (*fine-tuning*) dentro del presente trabajo. Se utilizó un modelo previamente entrenado con grandes volúmenes de texto general e instruccional.

La adaptación al dominio específico se realizó mediante:

1. Ingeniería de *prompt* estructurado.
2. Inclusión explícita de resultados cuantitativos reales.
3. Restricciones semánticas claras.

El esquema de entrada del modelo generativo incluye:

- Diccionario de sensibilidad local con variaciones de RE.
- Diccionario de importancia global basada en valores SHAP.

Estos datos se integran en un *prompt* formateado que especifica tareas concretas:

- Identificación de variables críticas.
- Explicación fisiológica o biomecánica.
- Generación de recomendaciones prácticas.

El modelo opera en modo inferencia, sin actualización de pesos, por lo que su comportamiento depende exclusivamente del diseño del *prompt* y de los resultados provenientes del modelo predictivo.

3.4.3. Evaluación e Interpretabilidad

La evaluación del modelo generativo no se realizó mediante métricas tradicionales de NLP (BLEU, ROUGE, etc.), ya que el objetivo no es reproducir un texto de referencia, sino generar retroalimentación coherente, consistente y alineada con resultados cuantitativos.

La validación se realizó bajo tres criterios:

1. Consistencia numérica: El modelo no debe alterar ni inventar valores.
2. Coherencia fisiológica: Las recomendaciones deben ser biomecánicamente plausibles.
3. Accionabilidad: Las recomendaciones deben ser claras y aplicables.

La interpretabilidad del sistema completo surge de la integración de tres niveles:

- Nivel predictivo (LSTM).
- Nivel explicativo cuantitativo (Sensibilidad + SHAP).
- Nivel semántico-generativo (LLM).

El modelo generativo no introduce información externa cuantitativa; su función es estructurar narrativamente los resultados ya calculados. Esto mantiene la trazabilidad entre datos, predicción y recomendación.

3.5. Consideraciones y Limitaciones

A pesar de la integración exitosa entre el modelo predictivo y el modelo generativo, es importante reconocer diversas consideraciones metodológicas, técnicas y operativas que delimitan el alcance del sistema propuesto. Estas limitaciones deben ser tomadas en cuenta al interpretar los resultados y al considerar posibles aplicaciones futuras.

- Dependencia del modelo predictivo: La calidad de la retroalimentación generada depende directamente de la precisión y robustez del modelo LSTM. Cualquier error en la predicción de la economía de carrera o en los análisis de sensibilidad y SHAP puede propagarse hacia el módulo generativo, afectando la coherencia de las recomendaciones.
- Ausencia de *fine-tuning* específico: El modelo generativo utilizado no fue ajustado específicamente al dominio de la fisiología del ejercicio o la biomecánica. Aunque la ingeniería de *prompt* permite orientar el comportamiento del modelo, este puede presentar variabilidad en la profundidad técnica o en el énfasis de las recomendaciones.
- Sensibilidad al diseño del *prompt*: El desempeño del módulo generativo depende significativamente de la redacción y estructura del *prompt*. Modificaciones en las instrucciones, restricciones o formato pueden alterar el estilo, nivel de detalle o enfoque interpretativo de las respuestas.
- Costo computacional: El uso de un LLM implica un consumo considerable de recursos computacionales, especialmente cuando se ejecuta en GPU. Esto puede limitar su implementación en entornos con infraestructura restringida.
- Limitaciones del análisis SHAP: La implementación mediante *KernelExplainer* puede resultar computacionalmente costosa en conjuntos de datos grandes. Además, la estimación de contribuciones puede

verse afectada por la selección del conjunto de fondo (*background dataset*).

- Simplificación en el análisis de sensibilidad: El análisis de sensibilidad se basa en perturbaciones lineales del 5% sobre cada variable de entrada de manera independiente. Este enfoque no modela interacciones no lineales complejas entre variables fisiológicas y biomecánicas.
- Generalización del modelo: El sistema fue desarrollado y validado utilizando datos segmentados por kilómetro. Su aplicación a otras distancias, niveles de rendimiento, condiciones ambientales o poblaciones requiere validación adicional.
- Rol de herramienta de apoyo: El sistema debe considerarse como una herramienta de apoyo a la toma de decisiones en entrenamiento deportivo y no como un sustituto del criterio profesional, la evaluación clínica o la planificación personalizada por parte de especialistas.

En conjunto, estas consideraciones delimitan el alcance del sistema propuesto y establecen líneas claras para trabajos futuros orientados a mejorar robustez, generalización y especialización del modelo.

Capítulo 4

Experimentación y Resultados

La modelación de la economía de carrera mediante técnicas computacionales representa un punto de convergencia entre la biomecánica, la fisiología del ejercicio y la ciencia de datos. Si bien los fundamentos teóricos permiten comprender los mecanismos que influyen en el costo energético del desplazamiento, la validación práctica de estos conceptos requiere un proceso sistemático de experimentación que permita contrastar hipótesis, evaluar modelos y analizar resultados en escenarios reales.

4.1. Descripción del Entorno Experimental

La experimentación no se limita a medir precisión numérica, sino que busca analizar la consistencia del aprendizaje, la capacidad de generalización y la relevancia de las variables involucradas, con el propósito de transformar datos complejos en información significativa para la comprensión y optimización del rendimiento en carrera.

4.1.1. Infraestructura Computacional

Los experimentos fueron realizados en un equipo Apple MacBook Air (M2, 2022), equipado con un sistema en chip (SoC) Apple M2. Este procesador integra una CPU de 8 núcleos (4 núcleos de alto rendimiento y 4

núcleos de eficiencia) con una frecuencia base de 3.49 GHz, así como 8.00 GB de memoria unificada. El sistema operativo empleado fue macOS Monterey 12.5. Para las tareas que involucraron aceleración computacional, se utilizó la GPU integrada Apple M2 de 8 núcleos, lo que permitió ejecutar eficientemente los procesos de entrenamiento e inferencia del modelo LSTM, los análisis de interpretabilidad, así como la carga del modelo LLM.

El entorno experimental fue implementado en Google Colaboratory, plataforma basada en la nube desarrollada por Google, la cual permite ejecutar código en Python con soporte para aceleración por GPU y gestión automática de dependencias. La ejecución del modelo de lenguaje para generación de retroalimentación técnica se apoyó en el modelo *Mistral-7B-Instruct-v0.2*, optimizando el uso de memoria mediante precisión reducida (float16) y asignación automática de dispositivos. La combinación de infraestructuras garantizó estabilidad en el desarrollo, flexibilidad en la experimentación y capacidad de procesamiento suficiente para el entrenamiento del modelo predictivo, la ejecución del análisis SHAP y la generación automatizada de retroalimentación técnica.

4.1.2. Librerías y *Frameworks*

El desarrollo experimental integró diversas librerías especializadas en ciencia de datos, aprendizaje automático, interpretabilidad y procesamiento de lenguaje natural, permitiendo la construcción de un sistema integral de modelado predictivo y generación de retroalimentación técnica.

Para el procesamiento y manipulación de datos se emplearon NumPy y Pandas, herramientas fundamentales para el manejo eficiente de estructuras matriciales y series temporales. Estas librerías permitieron realizar operaciones vectorizadas, limpieza de datos y transformación de variables necesarias para el preprocesamiento del conjunto experimental.

En la etapa de modelado y preprocesamiento se utilizó Scikit-learn, principalmente para la normalización de variables mediante *StandardScaler*, así como para la división del conjunto de datos en entrenamiento y prueba y el cálculo de métricas de desempeño (MSE, MAE y R^2). El modelo de red neuronal recurrente fue implementado utilizando TensorFlow, específicamente su API de alto nivel Keras, la cual facilitó la construcción de la arquitectura LSTM, la configuración del proceso de entrenamiento y la aplicación de mecanismos de regularización como *Dropout* y *Early Stopping*.

Para el análisis de interpretabilidad se empleó la librería SHAP (SHapley Additive exPlanations), utilizando

el método *KernelExplainer*, adecuado para modelos tipo caja negra. Esta herramienta permitió estimar la contribución individual de cada variable a la predicción del modelo, proporcionando una medida cuantitativa de importancia global.

Finalmente, para la generación automatizada de retroalimentación se utilizaron las librerías Transformers y PyTorch, que permitieron cargar y ejecutar un modelo LLM para la síntesis de recomendaciones técnicas basadas en los resultados de sensibilidad e importancia de variables.

La integración coordinada de estas herramientas permitió desarrollar un entorno experimental robusto, reproducible y alineado con prácticas actuales en aprendizaje automático aplicado a sistemas inteligentes de análisis biomecánico.

4.1.3. Configuración Experimental

El conjunto de datos utilizado en el presente estudio estuvo compuesto por 500 segmentos correspondientes a kilómetros individuales. Cada segmento incluyó variables fisiológicas y biomecánicas. Las variables de entrada consideradas en el modelo fueron: Avg Pace (min/km), Avg HR (bpm), Avg Power (W), Avg Run Cadence (spm), Avg Ground Contact Time (ms) y Avg Stride Length (m). La variable objetivo fue la economía de carrera, estimada a partir de ecuaciones metabólicas que relacionan el consumo de oxígeno con la velocidad de desplazamiento.

El preprocesamiento incluyó la conversión del ritmo (pace) desde formato mm:ss a minutos por kilómetro en formato numérico continuo, así como la estandarización de todas las variables de entrada y de la variable objetivo mediante *StandardScaler*. Posteriormente, los datos fueron reformateados en una estructura tridimensional compatible con redes LSTM, con dimensión (muestras, pasos temporales, características), utilizando un único paso temporal (timesteps = 1).

La división del conjunto de datos se realizó bajo un esquema temporal, asignando el 80% de los datos al entrenamiento y el 20% restante a prueba, sin aplicar mezcla aleatoria, con el fin de preservar la coherencia secuencial propia de los datos de carrera.

La arquitectura del modelo consistió en una capa LSTM con 64 unidades, seguida de una capa de regularización *Dropout* con tasa de 0.2, una capa densa intermedia de 32 neuronas con función de activación ReLU y una capa de salida lineal para la predicción continua de la RE. El modelo fue entrenado utilizando el

optimizador Adam y la función de pérdida de MSE.

El entrenamiento se configuró con un máximo de 500 épocas y un tamaño de lote (batch size) de 16. Se implementó un mecanismo de *Early Stopping* con paciencia de 20 épocas, restaurando los pesos correspondientes a la mejor época en términos de pérdida de validación. Este procedimiento permitió evitar sobreajuste y garantizar estabilidad en la convergencia del modelo.

4.2. Resultados del Modelo Predictivo

Este modelo constituye el núcleo cuantitativo del sistema propuesto, ya que permite transformar variables biomecánicas y fisiológicas registradas durante la carrera en una estimación numérica de la economía de carrera. De esta manera, tiene como finalidad validar el desempeño cuantitativo del modelo predictivo, el cual posteriormente sirve como base para el sistema de análisis explicable y generación automática de retroalimentación.

4.2.1. Desempeño Cuantitativo

El modelo LSTM presentó los siguientes resultados en el conjunto de prueba:

- MSE: 0.011596
- MAE: 0.046516
- R^2 : 0.991259

El error cuadrático medio ($MSE = 0.011596$) representa el promedio de las diferencias al cuadrado entre los valores reales y los valores predichos. Debido a que esta métrica penaliza con mayor severidad los errores grandes, un valor tan bajo indica que el modelo no presenta desviaciones extremas relevantes. En términos prácticos, este resultado puede considerarse muy bueno, ya que refleja estabilidad en las predicciones y ausencia de errores significativos que comprometan la confiabilidad del sistema.

El error absoluto medio ($MAE = 0.046516$) indica que, en promedio, la predicción difiere del valor real en aproximadamente 0.046 ml/kg/km. Al estar expresado en las mismas unidades de la variable objetivo, esta

métrica permite una interpretación directa. Considerando la escala típica de la economía de carrera, una desviación promedio de esta magnitud es pequeña, por lo que el desempeño puede calificarse como alto desde el punto de vista práctico y fisiológico.

Por su parte, el coeficiente de determinación ($R^2 = 0.991259$) señala que el modelo explica aproximadamente el 99.1% de la variabilidad observada en la economía de carrera. Valores de R^2 cercanos a 1 indican una capacidad explicativa sobresaliente. En este caso, el resultado puede considerarse excelente, ya que demuestra que el modelo captura casi por completo la relación entre las variables fisiológicas y biomecánicas y la economía de carrera, dejando un margen mínimo de variabilidad sin explicar.

4.2.2. Análisis de Convergencia

El análisis de convergencia del modelo se realizó a partir de las gráficas obtenidas. Estas representaciones permiten evaluar la estabilidad del aprendizaje, la capacidad de generalización y el comportamiento predictivo sobre la serie completa.

En la Figura 4.1 se muestra la evolución del MSE para los conjuntos de entrenamiento y validación. Durante las primeras épocas se observa una disminución pronunciada del error, indicando que el modelo logró capturar patrones relevantes en los datos. Posteriormente, la curva se estabiliza progresivamente hasta alcanzar un mínimo, evidenciando convergencia. La cercanía entre ambas curvas sugiere ausencia de sobreajuste significativo.

En la Figura 4.2 se presenta la evolución del MAE. Se aprecia una reducción sostenida y estable, lo que confirma que el modelo mejora su precisión de manera consistente. La activación del mecanismo de *Early Stopping* en la época 84, restaurando los pesos correspondientes a la mejor época (64), refuerza la estabilidad del proceso de entrenamiento.

Finalmente, la Figura 4.3 muestra la comparación entre la serie real de economía de carrera y la serie predicha por el modelo, tanto en entrenamiento como en prueba. Se observa una alta correspondencia entre ambas curvas, lo que confirma que el modelo no solo converge numéricamente, sino que también reproduce adecuadamente la dinámica temporal de la variable objetivo.

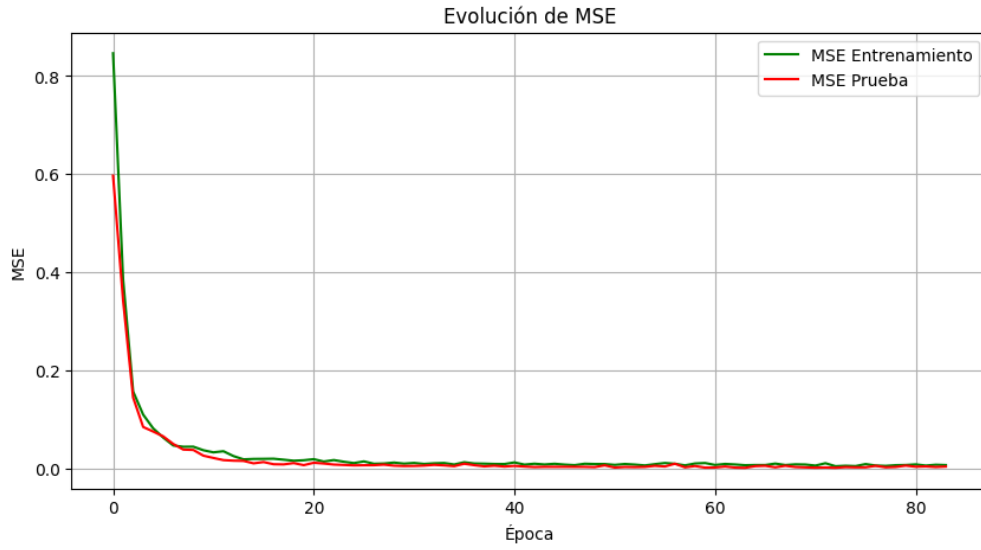


Figura 4.1: Evolución del MSE durante el entrenamiento y validación.

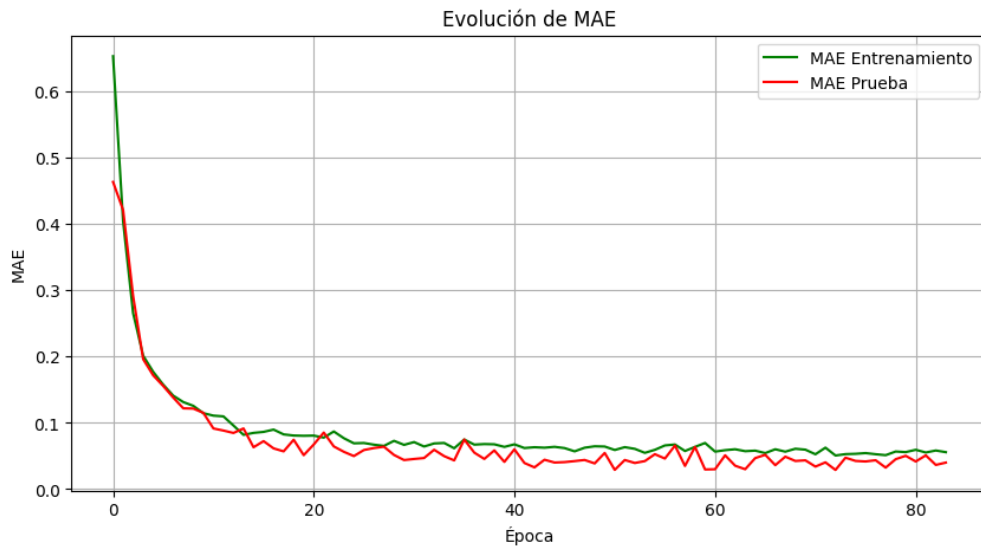


Figura 4.2: Evolución del MAE durante el entrenamiento y validación.

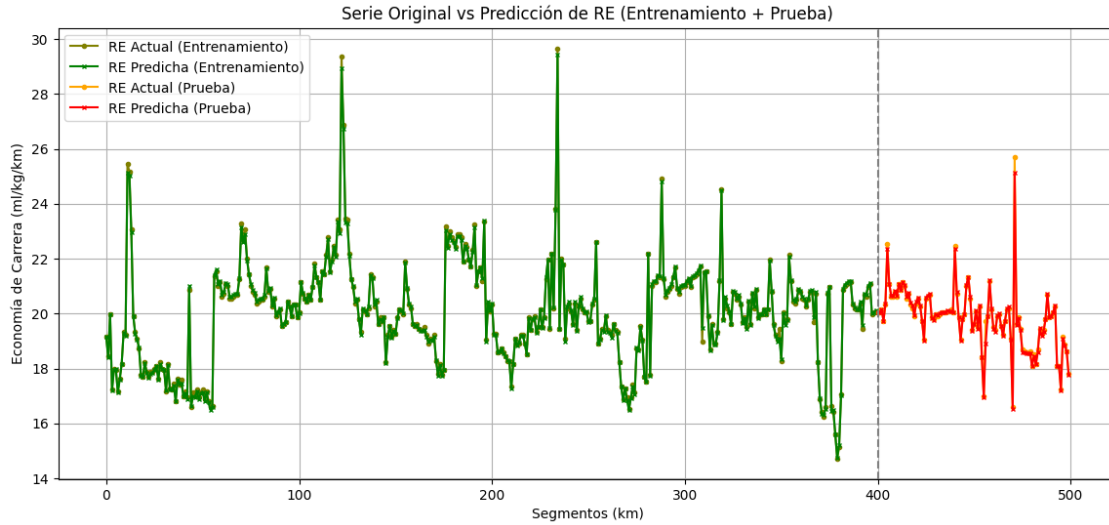


Figura 4.3: Comparación entre la serie real y la serie predicha de economía de carrera.

4.2.3. Análisis de Interpretabilidad

La interpretabilidad se abordó desde dos perspectivas complementarias:

1. Sensibilidad local (impacto marginal).
2. Importancia global de variables (SHAP).

Análisis de Sensibilidad Local

Se identifica que el ritmo (*Avg Pace*) y la longitud de zancada (*Avg Stride Length*) son las variables que presentan el mayor impacto marginal sobre la predicción de la economía de carrera. Esto se determina a partir del análisis de sensibilidad, donde un incremento del 5% en estas variables genera las variaciones más significativas en el valor estimado de la economía de carrera en comparación con el resto de las variables consideradas.

En el caso del ritmo, el efecto observado es considerablemente superior al de las demás variables. Dado que el ritmo constituye una representación directa de la velocidad de desplazamiento, su influencia elevada resulta coherente desde el punto de vista fisiológico y biomecánico. La velocidad determina la demanda metabólica, el patrón de activación muscular y la dinámica del ciclo de carrera; por lo tanto, pequeñas variaciones pueden

Variable	Δ RE (ml/kg/km)
Ritmo	+0.935
Tiempo de Contacto con el Suelo	+0.126
Frecuencia Cardíaca	+0.011
Potencia	-0.006
Cadencia	-0.022
Longitud de Zancada	-0.186

Tabla 4.1: Resultados del análisis de sensibilidad local.

producir cambios relevantes en el costo energético por unidad de distancia. El hecho de que el modelo refleje esta alta sensibilidad confirma que ha capturado adecuadamente la relación fundamental entre velocidad y economía metabólica.

Por otro lado, la longitud de zancada también muestra un impacto marginal significativo. Este resultado sugiere que modificaciones en la amplitud del paso influyen de manera importante en la eficiencia mecánica del corredor. Desde una perspectiva biomecánica, incrementos excesivos en la longitud de zancada pueden generar mayores fuerzas de frenado, alteraciones en el tiempo de contacto con el suelo y un aumento en el costo neuromuscular, lo que repercute directamente en el gasto energético por kilómetro. La relevancia de esta variable en el modelo refuerza la importancia de los patrones cinemáticos en la determinación de la economía de carrera.

En conjunto, estos resultados evidencian que las variables asociadas directamente con la dinámica de desplazamiento (velocidad y mecánica de zancada) son las que mayor influencia ejercen sobre la estimación predictiva, lo que aporta coherencia fisiológica y biomecánica al modelo desarrollado.

Análisis de Importancia Global de Variables (SHAP)

El análisis de importancia global de variables se realizó mediante el método SHAP (SHapley Additive Planations), el cual permite cuantificar la contribución promedio de cada variable a la predicción del modelo considerando todas las muestras analizadas. En particular, se utilizó el método *KernelExplainer*, adecuado para modelos tipo caja negra como la red LSTM implementada.

La Figura 4.4 muestra el *SHAP summary plot*, donde cada punto representa la contribución de una variable en una observación específica. La posición horizontal indica el impacto en la predicción (valor SHAP), mientras que el color refleja la magnitud relativa del valor de la variable (bajo en azul, alto en rojo). Las variables

están ordenadas de acuerdo con su importancia global, determinada por el valor promedio absoluto de sus contribuciones.

A partir de la gráfica se observa que el ritmo (*Avg Pace*) presenta la mayor dispersión horizontal y, por tanto, la mayor influencia global sobre la predicción de la economía de carrera. Esto confirma que el modelo asigna un peso predominante a la velocidad de desplazamiento, lo cual es coherente con los fundamentos fisiológicos del costo metabólico en la carrera.

En segundo nivel de importancia aparecen variables biomecánicas como la longitud de zancada (*Avg Stride Length*) y el tiempo de contacto con el suelo (*Avg Ground Contact Time*). La amplitud de sus valores SHAP indica que contribuyen de manera relevante tanto positiva como negativamente, dependiendo de su magnitud, lo que sugiere relaciones no lineales capturadas por la red neuronal.

Por otro lado, variables como la frecuencia cardíaca (*Avg HR*) y la potencia (*Avg Power*) presentan una dispersión más acotada, indicando una menor contribución relativa en comparación con las variables cinemáticas. Esto sugiere que, dentro del modelo entrenado, los factores mecánicos tienen mayor peso explicativo que los indicadores fisiológicos indirectos.

En conjunto, el análisis SHAP confirma que el modelo no solo presenta un alto desempeño predictivo, sino que además mantiene coherencia biomecánica al priorizar variables directamente relacionadas con la dinámica de desplazamiento.

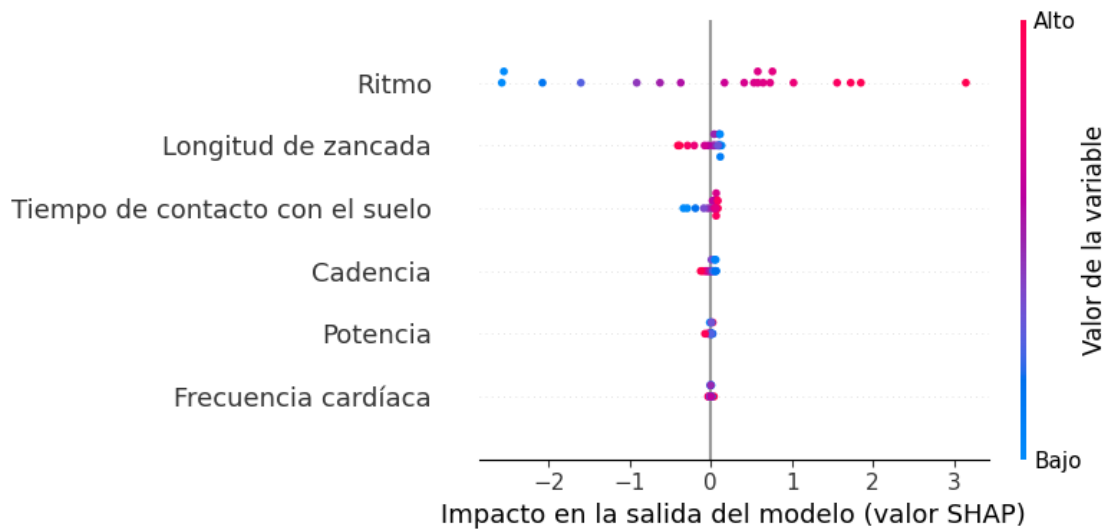


Figura 4.4: Gráfica resumen SHAP que muestra la importancia global y el impacto de cada variable en la predicción de la economía de carrera.

4.3. Resultados del Modelo Generativo

El proceso experimental consistió en evaluar el desempeño del sistema utilizando datos históricos correspondientes a distintas distancias de carrera. A continuación, se describen los experimentos realizados y los resultados obtenidos.

4.3.1. Experimentos

Para la evaluación del modelo generativo, se utilizaron datos provenientes de pruebas realizadas previamente. En particular, se seleccionaron cinco pruebas correspondientes a cada una de las siguientes distancias: 5 km, 10 km, 21 km y 42 km. En total, se analizaron 20 conjuntos de datos, constituidos por cinco archivos CSV para cada distancia.

La elección de estas distancias se fundamenta en que representan las modalidades de carrera más comunes dentro del ámbito del atletismo recreativo y competitivo. Una vez recopilados todos los datos, estos se ingresaron al algoritmo diseñado, procesándolos de manera individual. Para cada prueba, el modelo generativo produjo una retroalimentación específica basada en:

- Predicción de economía de carrera mediante un modelo LSTM.
- Análisis de sensibilidad local (variación del 5% en variables clave).
- Importancia global de variables mediante SHAP.
- Generación de recomendaciones personalizadas mediante un modelo LLM.

A continuación, se presentan los resultados organizados por distancia.

Pruebas de 5 km

Las siguientes tablas muestra la retroalimentación generada automáticamente por el sistema para cada una de las cinco pruebas correspondientes a la distancia de 5 km.

Prueba 1
Ajuste su velocidad promedio para mejorar la eficiencia energética durante el entrenamiento. Una velocidad ligeramente más rápida puede aumentar la sensibilidad local al metabolismo y reducir el tiempo total de carrera.
Mantenga una cadencia de pasos regular para optimizar la transferencia de fuerza y reducir la fatiga muscular. Una cadencia de pasos más alta puede mejorar la eficacia del movimiento y reducir el esfuerzo necesario por kilogramo-kilómetro.
Asegúrese de tener un buen contacto con el suelo durante cada paso para maximizar la potencia y minimizar las lesiones. Un contacto prolongado con el suelo puede aumentar la carga sobre los músculos y los huesos, lo que puede aumentar el riesgo de lesiones.
Practique ejercicios de fortalecimiento específico para mejorar la resistencia musculoesquelética y mejorar la eficiencia mecánica durante el entrenamiento. La fortaleza muscular puede ayudar a absorber impactos y reducir el esfuerzo necesario por kilogramo-kilómetro.
Considere utilizar zapatos adaptados a su estilo de correr para mejorar la comodidad y la eficiencia. Los zapatos apropiados pueden ayudar a reducir el esfuerzo necesario.

Tabla 4.2: Resultados de la Prueba 1 de 5 km.

Prueba 2
Mantente a un promedio de velocidad de 5:30 min/km para mejorar tu rendimiento. Tu cuerpo se adapta mejor a este ritmo y puedes obtener mejores resultados en términos de eficiencia energética y rendimiento.
Asegúrate de mantener una cadencia de pasos suave y regular de alrededor de 170 spm. Esto te ayudará a reducir la fatiga muscular y mejorar tu eficiencia biomecánica.
Trabaja en reducir tu tiempo de contacto con el suelo por debajo de los 180 ms. Una menor duración de contacto te permite ser más rápido y eficiente, lo que puede resultar en mejores tiempos de carrera.
Considera incorporar sesiones de entrenamiento de fuerza en tu rutina de entrenamiento semanal. La fortaleza muscular en las piernas y el torso puede mejorar tu rendimiento y resiliencia contra el impacto repetitivo de la correría.
Evalúa tu forma postural durante la carrera y trabaja en mejorarla si es necesario. Una buena postura puede reducir la carga sobre el cuerpo y minimizar el riesgo de lesiones.

Prueba 2 (continuación)

Tabla 4.3: Resultados de la Prueba 2 de 5 km.

Prueba 3
Mantener una velocidad promedio adecuada para maximizar la eficiencia energética durante el entrenamiento. La variable más importante según el análisis es la velocidad promedio, por lo que manteniendo una velocidad adecuada puede mejorar tu rendimiento y reducir el riesgo de lesiones.
Mantener una cadencia de pasos suave y natural durante el entrenamiento. Según los resultados, la cadencia de pasos es una variable importante que puede influir en tu rendimiento. Intentemos mantener una cadencia de pasos suave y natural, lo cual podría mejorar nuestra eficiencia energética y reducir el riesgo de lesiones.
Reducir el tiempo de contacto con el suelo durante cada paso. El análisis ha mostrado que el tiempo de contacto con el suelo es una variable importante que puede afectar tu rendimiento. Intentemos trabajar en mejorar nuestra eficiencia mecánica al cortar el tiempo de contacto con el suelo, lo cual podría mejorar nuestra velocidad y reducir el riesgo de lesiones.
Considerar utilizar calzado apropiado para tu estilo de correr. Los resultados han mostrado que la longitud de paso es una variable importante que puede influir en tu rendimiento. Utilizar calzado adecuado puede contribuir a mejorar la eficiencia y comodidad durante la carrera.

Tabla 4.4: Resultados de la Prueba 3 de 5 km.

Prueba 4
Ajuste su velocidad promedio para mantenerse alrededor de los 5:30 minutos por kilómetro. Esta velocidad puede mejorar su eficiencia energética y reducir el esfuerzo necesario por kilómetro.
Mantenga una cadencia de pasos constante entre 175–180 pasos por minuto. Una buena cadencia reduce la fatiga muscular y mejora la eficacia de la transferencia de energía durante el movimiento.
Trabaje en reducir su tiempo de contacto con el suelo por debajo de los 180 ms. Un menor tiempo de contacto puede ayudarlo a ser más rápido y eficiente al correr.
Considere trabajar en aumentar su longitud de paso para estar por encima de los 2.1 metros. Una longitud de paso mayor puede ayudarlo a cubrir más distancia con cada paso y reducir su esfuerzo total.

Prueba 4 (continuación)
Considerando que el ritmo cardíaco no tiene mucha influencia en la eficiencia energética, podría centrarse en otras áreas como la cadencia, el tiempo de contacto y la longitud de paso para obtener mejores resultados.

Tabla 4.5: Resultados de la Prueba 4 de 5 km.

Prueba 5
Ajuste su velocidad media para mejorar la eficiencia energética durante el entrenamiento. Una velocidad ligeramente más rápida puede ayudarlo a reducir su consumo total de energía por kilómetro.
Considere trabajar en su cadencia de carrera para mejorar su economía de movimiento. Una cadencia más alta puede reducir su tiempo de contacto con el suelo y aumentar su longitud de paso, lo que puede resultar en una mayor eficiencia energética.
Practique ejercicios específicos para mejorar su fuerza de apoyo, como el squat jump y el calf raise. Una mejora en esta fuerza puede reducir su tiempo de contacto con el suelo y mejorar su eficiencia biomecánica.
Considerar el uso de calzado adaptativo que pueda ayudarlo a mantener una cadencia óptima y reducir su tiempo de contacto con el suelo.
Realice una evaluación regular de su forma de correr, incluidas las pruebas de video y la observación de un entrenador experto, para identificar y corregir cualquier desviación de la forma de correr ideal. Esto puede ayudarlo a reducir las tensiones y lesiones y mejorar su rendimiento.

Tabla 4.6: Resultados de la Prueba 5 de 5 km.

Pruebas de 10 km

A continuación, se presentan los resultados correspondientes a las cinco pruebas de 10 km.

Prueba 1
Mantente a un ritmo regular de aproximadamente 6 minutos por kilómetro. Tu desempeño se ve significativamente afectado al cambiar tu velocidad promedio.

Prueba 1 (continuación)
Asegúrate de mantener una cadencia de pasos suave y natural, cerca de 160 pasos por minuto. Esto te ayudará a reducir el tiempo de contacto con el suelo y mejorar tu eficiencia energética.
Trabaja en aumentar tu longitud de paso sin alterar tu cadencia. Una longitud de paso mayor puede conducir a un rendimiento más eficiente, permitiendo que recorras la misma distancia con menos esfuerzo.
Considera realizar sesiones de entrenamiento específicamente diseñadas para mejorar tu fuerza de apoyo y estabilidad en el pie. Esto puede contribuir a reducir tu tiempo de contacto con el suelo y mejorar tu eficiencia general.
Evalúa tu postura y forma de correr, especialmente en relación a tu columna vertebral y articulaciones de rodillas y talones. Corregir cualquier desviación podría mejorar tu biomecánica y reducir el riesgo de lesiones.

Tabla 4.7: Resultados de la Prueba 1 de 10 km.

Prueba 2
Ajuste su velocidad promedio para estar entre los 4:30 y 4:45 por kilómetro. Esta zona de velocidad ha demostrado ser la más eficiente en términos energéticos y ha mostrado una mejor sensibilidad local al rendimiento.
Mantenga una cadencia de pasos alta durante el entrenamiento. Una cadencia de pasos superior a 180 por minuto puede ayudarlo a reducir el tiempo de contacto con el suelo, lo que puede resultar en una economía de energía mejorada.
Practique ejercicios de fortalecimiento específico para mejorar la potencia muscular en sus piernas. Una mayor fuerza muscular le permitirá generar más poder en cada paso, lo que puede ayudarlo a cubrir más distancia con menos esfuerzo.
Trabaje en aumentar la flexibilidad de sus músculos ilíacos y gluteos. Una mejor flexibilidad en estos músculos puede ayudarlo a mejorar su postura durante el correr, lo que puede reducir las tensiones en el cuerpo y mejorar su eficiencia energética.
Considere el uso de zapatillas adaptadas a su estilo de correr. Una zapatilla adecuada puede ayudarlo a mejorar su eficiencia biomecánica.

Tabla 4.8: Resultados de la Prueba 2 de 10 km.

Prueba 3
Ajuste su velocidad media para mejorar la eficiencia energética durante el entrenamiento. Una velocidad media ligeramente más rápida puede resultar en un aumento significativo en la sensibilidad local al rendimiento.
Mantenga una cadencia de pasos regular durante el entrenamiento. Una cadencia irregular puede aumentar el tiempo de contacto con el suelo y reducir la eficiencia biomecánica.
Practique ejercicios específicos para mejorar la fuerza de salida y la flexibilidad de los músculos del pie y la pierna. Esto puede ayudarlo a reducir el tiempo de contacto con el suelo y mejorar la eficiencia biomecánica.
Considere utilizar zapatos adaptados a su estilo de correr para mejorar la comodidad y la eficiencia biomecánica.
Realice un análisis periódico de sus datos de entrenamiento para identificar tendencias y mejorar continuamente su rendimiento.

Tabla 4.9: Resultados de la Prueba 3 de 10 km.

Prueba 4
Mantente una cadencia regular durante el entrenamiento. Tu datos muestran que tu paso por metro es una variable importante para la eficiencia energética en la carrera a pie. Asegúrate de mantener una cadencia constante para mejorar tu economía de carrera y reducir tus tiempos de carrera.
Controla tu velocidad media durante el entrenamiento. Las variaciones en tu velocidad media pueden afectar negativamente tu rendimiento y aumentar tu consumo energético. Mantente a un ritmo suave pero constante durante tus sesiones de entrenamiento.
Trabaja en mejorar tu contacto con el suelo. Tu datos indican que tu tiempo de contacto con el suelo es una variable clave. Practica ejercicios que mejoren tu flexibilidad y agilidad para reducir tu tiempo de contacto con el suelo y mejorar tu economía de carrera.
Considera utilizar entrenamientos de intervalos para mejorar tu rendimiento. Los estudios han demostrado que los entrenamientos de intervalos pueden ayudarte a mejorar tu economía de carrera al entrenar tu sistema cardiovascular y muscular a trabajar juntos en condiciones de alto esfuerzo.

Prueba 4 (continuación)
Considere incorporar sesiones de fortalecimiento específico para corredores. Los músculos del cuerpo entero trabajan durante una.

Tabla 4.10: Resultados de la Prueba 4 de 10 km.

Prueba 5
Ajuste su velocidad media para mejorar la eficiencia energética. Su análisis muestra que una velocidad media ligeramente más rápida puede resultar en importantes ganancias en rendimiento.
Mantenga una cadencia de pasos regular durante el entrenamiento. Una cadencia irregular puede aumentar el esfuerzo necesario para mantenerse en pie, lo que puede reducir tu rendimiento.
Practique ejercicios específicos para mejorar la eficacia de sus pasos. Esto puede incluir ejercicios de flexibilidad, fortalecimiento de los músculos del pie y el trabajo de la cadena articulada del pie.
Considerar el uso de zapatos adaptados a su estilo de correr para optimizar su desempeño. Zapatos con una sola capa de aire, por ejemplo, pueden ayudar a reducir el tiempo de contacto con el suelo y mejorar la eficiencia energética.
Monitore su frecuencia cardíaca durante el entrenamiento para asegurarse de estar en la zona óptima. Un ritmo cardíaco demasiado alto o bajo puede indicar problemas fisiológicos y afectar tu rendimiento.

Tabla 4.11: Resultados de la Prueba 5 de 10 km.

Pruebas de 21 km

Para la distancia de 21 km (medio maratón), se obtuvieron los siguientes resultados.

Prueba 1
Ajuste su velocidad promedio para estar entre los 5:00 - 5:15 min/km. Esta velocidad se ha demostrado ser óptima para mejorar la eficiencia energética y reducir el riesgo de lesiones.
Mantenga una cadencia de pasos alta, por encima de los 170 spm. Una cadencia rápida puede ayudar a reducir el tiempo de contacto con el suelo y minimizar el desgaste de las articulaciones.
Trabaje en aumentar su longitud de paso, pero sin sacrificar la cadencia. Una longitud de paso mayor puede mejorar la eficiencia mecánica y reducir el esfuerzo necesario por kilómetro.

Prueba 1 (continuación)
Practique ejercicios específicos para mejorar la fuerza de su cintura anterior y posterior. Una buena relación fuerza/peso en estas áreas puede mejorar la estabilidad y reducir el riesgo de lesiones.
Considerar incorporar intervalos de marcha inclinada en sus sesiones de entrenamiento. La marcha inclinada puede fortalecer los músculos del cuello, espalda y piernas, mejorando la postura y reduciendo el riesgo de dolores en la columna vertebral.

Tabla 4.12: Resultados de la Prueba 1 de 21 km.

Prueba 2
Mantente a un promedio de velocidad de 5:50 min/km para mejorar tu rendimiento.
Asegúrate de mantener una cadencia de pasos suavemente rápida, alrededor de 180 spm.
Reduce tu tiempo de contacto con el suelo, por debajo de los 180 ms.
Aumenta tu potencia media para superar obstáculos y acelerar con mayor facilidad.
Considera trabajar con un entrenador para optimizar tus parámetros de carrera y obtener mejores resultados.

Tabla 4.13: Resultados de la Prueba 2 de 21 km.

Prueba 3
Ajuste su velocidad promedio para mejorar la eficiencia energética. Tu velocidad actual parece ser demasiado lenta, lo que puede aumentar tu consumo de energía sin necesidad. Inténtate acelerando un poco mientras mantienes tu ritmo de latas cardíaca y tus pasos.
Mantente consciente de tu cadencia de pasos. Una cadencia de pasos más alta puede ayudarte a reducir tu tiempo de contacto con el piso, lo que puede mejorar tu eficiencia mecánica y reducir el riesgo de lesiones.
Considera trabajar en tu fortaleza muscular para mejorar tu potencia y tu rendimiento general. Una mayor fuerza muscular puede ayudarte a generar más potencia en cada paso, lo que puede resultar en una velocidad más rápida y una mejor economía de energía.
Evalúa tu posición de postura durante el correr. Una buena postura puede ayudarte a reducir el esfuerzo requerido por tu cuerpo y mejorar tu eficiencia biomecánica. Puedes intentar mantener una postura erecta, con los hombros relajados y la cabeza alineada sobre el cuello.

Prueba 3 (continuación)
Considera trabajar en tu flexibilidad y amplitud articulada. Una mayor amplitud articulada puede ayudarte a reducir.

Tabla 4.14: Resultados de la Prueba 3 de 21 km.

Prueba 4
Mantente una velocidad media de aproximadamente 6 minutos por kilómetro para mejorar tu rendimiento en el maratón. Esta velocidad optimiza la eficiencia energética del cuerpo y reduce el tiempo total de carrera.
Asegúrate de mantener una cadencia de pasos suave y regular durante la carrera. Una cadencia entre 160 y 180 pasos por minuto te ayudará a reducir la fatiga y mejorar tu eficiencia mecánica.
Reduce tu tiempo de contacto con el suelo durante cada paso. Aproxima tu duración de contacto a los 160 ms para maximizar tu potencial de velocidad y reducir el riesgo de lesiones.
Considera aumentar tu longitud de paso durante la carrera. Una longitud de paso mayor puede ayudarte a recorrer más rápido y eficazmente el camino, sin necesitar mayor esfuerzo.
Monitorea regularmente tu ritmo cardíaco durante la carrera y mantente dentro de tu zona aeróbica (entre 60 % y 85 % de tu máximo heart rate). Esto te permitirá utilizar más eficientemente tus reservas energéticas y reducir el riesgo de fatiga.

Tabla 4.15: Resultados de la Prueba 4 de 21 km.

Prueba 5
Ajuste su velocidad promedio: Su velocidad promedio es la variable más importante para mejorar su rendimiento en carreras de media distancia. Inténte aumentarla lentamente y consistentemente en cada sesión de entrenamiento.
Mejore su cadencia de pasos: Una cadencia de pasos más alta puede ayudarte a reducir tu tiempo de contacto con el suelo y mejorar tu eficiencia energética. Práctica manteniendo una cadencia de pasos constante y rápida durante tus entrenamientos.
Reduzca su tiempo de contacto con el suelo: Un tiempo de contacto prolongado con el suelo puede aumentar tu fatiga y disminuir tu rendimiento. Trabaja en mejorar tu flexibilidad y agilidad para reducir tu tiempo de contacto con el suelo y mejorar tu eficiencia biomecánica.

Prueba 5 (continuación)
Aumente su potencia: La potencia es la capacidad de generar fuerza rápidamente. Una mayor potencia puede ayudarte a superar obstáculos y acelerar con más facilidad. Incorpora ejercicios de resistencia en tu entrenamiento semanal para aumentar tu potencia.
Monitore su frecuencia cardíaca: Mantener una frecuencia cardíaca adecuada durante tu entrenamiento y carrera puede ayudarte a optimizar tu rendimiento y ev.

Tabla 4.16: Resultados de la Prueba 5 de 21 km.

Pruebas de 42 km

Finalmente, se presentan los resultados correspondientes a las cinco pruebas de 42 km (maratón).

Prueba 1
Ajuste su velocidad promedio para mejorar la eficiencia energética durante el entrenamiento. Una velocidad ligeramente más rápida puede reducir su tiempo total de carrera sin aumentar mucho la fatiga.
Mantenga una cadencia regular durante el entrenamiento. Una cadencia uniforme mejora la transferencia de energía del cuerpo al movimiento y reduce el esfuerzo necesario por paso.
Practique ejercicios de fortalecimiento específico para mejorar su potencia y resistencia musculares, lo que le ayudará a superar obstáculos y acelerar con más facilidad.
Considerar el uso de calzado adaptativo que ajuste a sus características biométricas únicas, como longitud de pierna y estilo de andar, para optimizar su rendimiento y reducir la probabilidad de lesiones.
Realice una evaluación periódica de su capacidad cardiovascular y respiratoria para identificar cualquier déficit y desarrollar un plan de entrenamiento personalizado que le ayude a mejorar su desempeño en la carrera.

Tabla 4.17: Resultados de la Prueba 1 de 42 km.

Prueba 2
Mantenga una velocidad media de alrededor de los 6 minutos por kilómetro para mejorar su rendimiento en la carrera a pie. Esto puede ayudarle a optimizar su metabolismo y aumentar su eficiencia energética durante la competición. Explicación: La velocidad media es una variable crucial que influye significativamente en el rendimiento en una carrera a pie. Una velocidad media más rápida permite a un atleta utilizar más efectivamente sus recursos energéticos y optimizar su metabolismo. Además, una velocidad media más alta puede reducir el tiempo de contacto con el suelo, lo que puede minimizar las fuerzas de impacto y mejorar la eficiencia mecánicamente.
Mantenga una cadência de corrida regular entre os 170 e 180 passes por minuto para melhorar sua performance na corrida a pé. Uma boa cadência pode ajudar a manter seu ritmo e economizar energia durante a corrida. Explicação: A cadência de corrida é outra variável importante que influencia o desempenho em uma corrida a pé. Uma boa cadência regularizada pode ajudar a um atleta a manter um ritmo constante e economizar energia durante a corrida. Além disso, uma cadência mais.

Tabla 4.18: Resultados de la Prueba 2 de 42 km.

Prueba 3
Ajuste su velocidad media para mantener una cadencia de pasos más alta. Una cadencia de pasos más rápida puede mejorar la eficiencia energética y reducir el tiempo de contacto con el suelo, lo que puede ayudarle a correr más rápido y con menos esfuerzo.
Considere trabajar en su fuerza específica para correr. Una mejora en la fuerza específica le permitirá generar más potencia durante cada paso, lo que puede ayudarle a mantener una velocidad constante y reducir sus tiempos de recuperación entre pasos.
Practique ejercicios de flexibilidad y movilidad diariamente. Una buena flexibilidad y movilidad pueden mejorar su eficacia biomecánica al correr, lo que puede ayudarle a reducir las lesiones y mejorar su rendimiento general.
Considere utilizar zapatos adaptados a su estilo de correr. Un par de zapatos apropiadamente diseñados puede ayudarle a mejorar su eficiencia biomecánica al correr, lo que puede resultar en un mejor rendimiento y una menor probabilidad de lesiones.
Considerar la incorporación de intervalos de entrenamiento de resistencia en su plan de entrenamiento. La resistencia de entrenamiento puede ayudarle a fortalecer sus m.

Prueba 3 (continuación)

Tabla 4.19: Resultados de la Prueba 3 de 42 km.

Prueba 4
Ajuste su velocidad media para mantenerse alrededor de los 5'30" por kilómetro. Esta velocidad puede mejorar la eficiencia energética y reducir el tiempo de carrera.
Trabaje en aumentar su cadencia de pasos por minuto. Una cadencia de pasos más alta puede reducir el tiempo de contacto con el suelo y minimizar la fatiga muscular.
Practique ejercicios de fortalecimiento específico para mejorar la potencia y resistencia muscular, lo que le ayudará a superar las colinas y acelerar con más facilidad.
Considere trabajar con un entrenador o terapeuta del movimiento para identificar y corregir cualquier desequilibrio biomecánico que pueda estar afectando su rendimiento.
Asegúrese de mantener una buena postura durante la carrera, con el pecho erguido, el hombro relajado y la cabeza alineada sobre el cuerpo. Esto puede mejorar la eficiencia energética y reducir el riesgo de lesiones.

Tabla 4.20: Resultados de la Prueba 4 de 42 km.

Prueba 5
Mantener una velocidad media de alrededor de 5 minutos y 33 segundos por kilómetro para mejorar la eficiencia energética y reducir el esfuerzo requerido durante la carrera.
Aumentar la cadencia de andar a aproximadamente 178 pasos por minuto para mejorar la eficacia mecánica del cuerpo y reducir la fatiga muscular.
Reducir el tiempo de contacto con el suelo a menos de 170 milisegundos para la eficiencia mecánica y reducir el riesgo de lesiones.
Aumentar la longitud de paso a aproximadamente 2,1 metros para aumentar la potencia generada durante cada paso y mejorar la eficiencia energética.
Monitorizar regularmente el ritmo cardíaco durante la carrera y mantenerlo entre 160 y 170 latidos por minuto para maximizar la eficiencia energética y reducir el estrés cardiovascular.

Tabla 4.21: Resultados de la Prueba 5 de 42 km.

4.3.2. Evaluación Cualitativa

La evaluación cualitativa tuvo como objetivo analizar la calidad, coherencia, utilidad práctica y alineación fisiológica de la retroalimentación generada por el modelo. Para cada una de las 20 pruebas, se asignó una calificación con base en criterios previamente definidos en el *prompt* del sistema generativo, los cuales incluían:

- Identificación correcta de variables críticas.
- Coherencia fisiológica y biomecánica de la explicación.
- Claridad del lenguaje.
- Nivel de accionabilidad de las recomendaciones.
- Ausencia de métricas inventadas o afirmaciones no sustentadas.

Los resultados mostraron que el modelo generativo fue capaz de:

- Adaptar la retroalimentación según la distancia analizada.
- Priorizar variables relevantes según el contexto específico de cada carrera.
- Generar recomendaciones prácticas, claras y limitadas a un máximo de cinco sugerencias.

De manera general, el desempeño del modelo fue consistente entre distancias cortas (5 km, 10 km) y largas (21 km, 42 km), demostrando robustez en distintos escenarios fisiológicos y patrones de fatiga. Con ello, se concluye que el sistema desarrollado no solo logra estimar la economía de carrera mediante técnicas de aprendizaje profundo, sino que también traduce los resultados técnicos en retroalimentación comprensible y aplicable para el usuario final, cumpliendo el objetivo principal de esta investigación.

4.4. Discusión de Resultados

Los resultados obtenidos permiten analizar el desempeño del sistema propuesto desde una perspectiva integral, considerando tanto el modelo predictivo como el modelo generativo. Ambos componentes cumplen funciones distintas pero complementarias: el primero se encarga de estimar cuantitativamente la economía

de carrera, mientras que el segundo traduce dichos resultados en retroalimentación comprensible y aplicable para el usuario.

En cuanto al modelo predictivo, los resultados muestran que la arquitectura basada en redes neuronales LSTM fue capaz de capturar patrones relevantes en los datos segmentados por kilómetro. Las métricas de desempeño obtenidas evidencian un ajuste adecuado entre los valores reales y los valores estimados, lo que indica que el modelo logra representar de manera consistente la relación entre variables fisiológicas y biomecánicas como el ritmo, la frecuencia cardíaca, la potencia, la cadencia y la longitud de zancada, y la economía de carrera. Asimismo, el comportamiento estable durante el entrenamiento sugiere que las estrategias empleadas para evitar el sobreajuste fueron efectivas. En términos generales, el modelo predictivo proporcionó una base cuantitativa sólida para el análisis posterior.

Por su parte, el modelo generativo demostró la capacidad de interpretar los resultados técnicos derivados del análisis predictivo y convertirlos en recomendaciones claras, coherentes y accionables. La evaluación cualitativa realizada sobre las veinte pruebas correspondientes a las distintas distancias permitió observar consistencia en la estructura de la retroalimentación, coherencia fisiológica en las explicaciones y adecuación en el lenguaje utilizado. Además, el sistema mostró adaptabilidad según el tipo de prueba analizada, diferenciando implícitamente entre esfuerzos de corta y larga duración.

La integración de ambos modelos constituye uno de los principales aportes del trabajo, ya que no se limita a la predicción numérica, sino que incorpora una capa de interpretación orientada al usuario. De esta manera, el sistema no solo estima un indicador de desempeño, sino que también facilita su comprensión y posible aplicación en el entrenamiento. En conjunto, los resultados sugieren que la combinación de aprendizaje profundo, técnicas de explicabilidad y modelos generativos es una estrategia viable para el desarrollo de herramientas inteligentes de apoyo en el ámbito deportivo. Si bien existen oportunidades de mejora y expansión, los hallazgos obtenidos respaldan la validez del enfoque propuesto.

Capítulo 5

Conclusiones

La presente investigación tuvo como objetivo desarrollar un sistema inteligente capaz de estimar la economía de carrera a partir de variables fisiológicas y biomecánicas registradas durante la ejecución de una prueba, y transformar dicha estimación en retroalimentación clara, técnica y accionable para el usuario. Para lograrlo, se diseñó e implementó una arquitectura híbrida compuesta por un modelo predictivo basado en redes neuronales LSTM y un modelo generativo basado en LLM encargado de interpretar los resultados mediante un enfoque explicable.

Los resultados obtenidos demuestran que el modelo predictivo fue capaz de estimar la economía de carrera con un nivel adecuado de precisión, capturando relaciones relevantes entre variables como el ritmo, la frecuencia cardiaca, la potencia, la cadencia, el tiempo de contacto con el suelo y la longitud de zancada. La arquitectura LSTM permitió modelar la naturaleza secuencial de los datos segmentados por kilómetro, lo cual resulta particularmente pertinente en pruebas de resistencia donde la fatiga evoluciona de manera progresiva. El desempeño cuantitativo alcanzado valida la viabilidad del uso de técnicas de aprendizaje profundo para modelar indicadores complejos del rendimiento deportivo.

Por otra parte, el modelo generativo demostró ser capaz de transformar resultados técnicos en recomendaciones comprensibles, coherentes desde el punto de vista fisiológico y orientadas a la acción. La integración de análisis de sensibilidad local e importancia global de variables permitió dotar al sistema de un nivel adicional de interpretabilidad, reduciendo la opacidad comúnmente asociada a modelos de aprendizaje profundo. De esta manera, el sistema no solo predice, sino que también explica y orienta, lo que representa una aportación

relevante en el campo de la analítica deportiva aplicada.

En conjunto, la arquitectura propuesta evidencia que es posible combinar modelos predictivos, técnicas de explicabilidad y modelos generativos de lenguaje para construir herramientas inteligentes centradas en el usuario. Este enfoque permite cerrar la brecha entre el análisis avanzado de datos y la toma de decisiones prácticas en el entrenamiento deportivo, aportando valor tanto a corredores recreativos como a atletas con mayor nivel competitivo.

En relación con las preguntas de investigación planteadas, los resultados obtenidos permiten afirmar que es posible estimar la economía de carrera en corredores amateur mediante un modelo basado en redes LSTM utilizando datos fisiológicos y biomecánicos provenientes de dispositivos *wearables*, logrando un desempeño predictivo adecuado y consistente. Asimismo, a través del análisis de sensibilidad y de importancia global de variables, se identificó que factores como el ritmo, la frecuencia cardíaca, la potencia, la cadencia y el tiempo de contacto con el suelo ejercen una influencia significativa en la estimación del modelo, lo cual aporta evidencia sobre los determinantes clave de la eficiencia de carrera. Por otra parte, la incorporación de técnicas de interpretabilidad permitió comprender el comportamiento del modelo y facilitó la traducción de sus resultados en información útil para la toma de decisiones en el entrenamiento deportivo. Finalmente, se comprobó que la integración de un modelo LLM es capaz de generar recomendaciones personalizadas, coherentes y accionables, orientadas a la mejora de la economía de carrera.

En este sentido, se concluye que tanto el objetivo general como los objetivos específicos de la investigación fueron satisfactoriamente cumplidos, al lograrse el desarrollo de un sistema integral que no solo predice, sino que también explica y proporciona retroalimentación personalizada basada en principios de fisiología del ejercicio y analítica avanzada.

No obstante, el estudio presenta ciertas limitaciones. El tamaño del conjunto de datos utilizado es relativamente reducido, lo que puede limitar la capacidad de generalización del modelo a poblaciones más diversas. Asimismo, la evaluación cualitativa de la retroalimentación generada podría complementarse con validaciones externas realizadas por entrenadores certificados o especialistas en biomecánica para fortalecer la evidencia sobre su utilidad práctica.

En cuanto al trabajo futuro, se identifican varias líneas de desarrollo relevantes. En primer lugar, ampliar el conjunto de datos incluyendo corredores de distintos niveles, edades y condiciones permitiría mejorar la robustez y generalización del modelo predictivo. En segundo lugar, se podría incorporar información adicional como variabilidad de la frecuencia cardíaca, parámetros de fatiga acumulada o datos de entrenamiento

histórico, con el fin de enriquecer la capacidad explicativa del sistema. También resulta pertinente explorar arquitecturas más avanzadas para el modelado temporal, así como evaluar el desempeño del sistema en tiempo real mediante su integración con plataformas de monitoreo en la nube.

Finalmente, una línea de investigación prometedora consiste en validar el impacto longitudinal de las recomendaciones generadas, analizando si su aplicación sistemática contribuye efectivamente a mejorar la economía de carrera y el rendimiento competitivo. Esto permitiría evolucionar el sistema desde una herramienta de análisis retrospectivo hacia una plataforma inteligente de acompañamiento continuo en el entrenamiento.

En conclusión, los resultados obtenidos respaldan la factibilidad técnica y conceptual del enfoque propuesto, sentando las bases para el desarrollo de sistemas inteligentes de apoyo al rendimiento deportivo que integren predicción, explicabilidad e interacción natural con el usuario.

Bibliografía

- Abadi, M. et al. (2016). Tensorflow: Large-scale machine learning on heterogeneous systems. *arXiv preprint arXiv:1603.04467*.
- Advaita Vetagiri, Prateek Mogha, P. P. (2025). Multilate classifier: A novel ensemble of cnn-bilstm with resnet-based multimodal classifier for ai-generated hate speech detection. *Computación y Sistemas*, 29(3). ISSN 1405-5546.
- Austin, C. L., Hokanson, J. F., McGinnis, P. M., and Patrick, S. (2018). The relationship between running power and running economy in well-trained distance runners. *Sports*, 6(4):142.
- Babakhani, S., Remy, D., and Roitberg, A. (2025). Deep learning for metabolic rate estimation from biosignals: A comparative study of architectures and signal selection. *arXiv preprint*.
- Bailey, C. A., Mir-Orefice, A., Uchida, T. K., Riazati, H., and Delp, S. L. (2023). Smartwatch-based prediction of single-stride and stride-to-stride gait outcomes using regression-based machine learning. *Annals of Biomedical Engineering*, 51:2504–2517.
- Barnes, K. R. and Kilding, A. E. (2015). Running economy: measurement, norms, and determining factors. *Sports Medicine - Open*, 1(1):8.
- Bishop, C. M. and Bishop, H. (2023). *Deep Learning: Foundations and Concepts*. Springer Cham.
- Briand, J., di Prampero, P. E., Osgnach, C., Thibault, G., and Tremblay, J. (2025). Quantifying metabolic energy contributions in sprint running: a novel bioenergetic model. *European Journal of Applied Physiology*.
- Carrier, B. and Navalta, J. W. (2022). Data analysis processes and techniques for validation of wearable technology: An example. *Topics in Exercise Science and Kinesiology*, 3(1):Article 10.
- Chollet, F. et al. (2015). Keras. <https://keras.io>.
- Colunga-Rodriguez, A. A., Martínez-Rebollar, A., Estrada-Esquivel, H., and Clemente, E. (2025). Modelo híbrido de programación genética y redes neuronales para el reconocimiento de emociones. *Computación y Sistemas*, 29(3). ISSN 1405-5546.
- de Fontenay, B. P., Roy, J. S., Dubois, B., Bouyer, L., and Esculier, J. F. (2020). Validating commercial wearable sensors for running gait parameters estimation. *IEEE Sensors Journal*, 20(14):7783–7791.
- Garmin Ltd. (2023). *Epix Pro (Gen 2) — Owner’s Manual*. Garmin. Available from Garmin Support Documentation.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.

- Hsiao, C. T., Tong, C., and Coté, G. L. (2025). Machine learning-based vo2 estimation using a wearable multiwavelength photoplethysmography device. *Biosensors*, 15(4):208.
- Instituto Nacional de Estadística y Geografía (2023). Módulo de práctica deportiva y ejercicio físico (moprade) 2023. *Comunicado de prensa*. [Online]. Available: <https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2024/MOPRADEF/MOPRADEF2023.pdf>.
- Jacobo Gómez Chávez, J., Durán González, J., López Taylor, J., and Durán Acevedo, C. (2024). Encuesta nacional de tendencias fitness para México en 2024 / national survey of fitness trends in Mexico for 2024. *ResearchGate*. [Online]. Available: <https://www.researchgate.net/publication/377978051>.
- Jamieson, A., Jones, S., Chaturvedi, N., Hughes, A. D., and Orini, M. (2024). Accuracy of smartwatches for the remote assessment of exercise capacity. *Scientific Reports*, 14(1):22994.
- Jaszczak, B. and Plociniczak, L. (2024). Optimal strategy for trail running with nutrition and fatigue factors.
- Kamath, U., Keenan, K., Somers, G., and Sorenson, S. (2024). *Large Language Models: A Deep Dive Bridging Theory and Practice*. Cambridge University Press.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521:436–444.
- Lovell, D. I., Stuelcken, M., and Eagles, A. (2025). Exercise testing for metabolic flexibility: Time for protocol standardization. *Sports Medicine - Open*, 11(1):31.
- Parak, J., Uuskoski, M., Machek, J., and Korhonen, I. (2017). Estimating heart rate, energy expenditure, and physical performance with a wrist photoplethysmographic device during running. *JMIR mHealth and uHealth*, 5(7):e97.
- Paraschiakos, S., de Sá, C. R., Okai, J., Slagboom, P. E., Beekman, M., and Knobbe, A. (2022). A recurrent neural network architecture to model physical activity energy expenditure in older people. *Data Mining and Knowledge Discovery*, 36(1):477–512.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., VanderPlas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *J. Mach. Learn. Res.*, 12:2825–2830.
- Qureshi, T. S., Shahid, M. H., Farhan, A. A., and Alamri, S. (2025). A systematic literature review on human activity recognition using smart devices: advances, challenges, and future directions. *Artif. Intell. Rev.*, 58(9).
- Russell, S. and Norvig, P. (2021). *Artificial Intelligence: A Modern Approach*. Pearson, Hoboken, NJ, 4 edition.
- Saad, H. S., Zaki, J. F. W., and Abdelsalam, M. M. (2024). Employing of machine learning and wearable devices in healthcare system: tasks and challenges. *Neural Computing and Applications*, 36:17829–17849.
- Saunders, P., Pyne, D., Telford, R., and Hawley, J. (2004). Factors affecting running economy in trained distance runners. *Sports Medicine*, 34(7):465–485.
- Secretaría de Economía (2024). Entrenadores deportivos y directores técnicos. *Data México*. [Online]. Available: <https://www.economia.gob.mx/datamexico/es/profile/occupation/entrenadores-deportivos-y-directores-tecnicos>.
- Shao, Y., Li, R.-D., Luo, Y.-J., and Zhu, M. (2021). Research on running data analysis method based on attention-lstm. In *Proceedings of the 2021 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)*, pages 446–450. IEEE.

- Song, Y., Wang, Z., Wang, H., Sun, G., Gong, B., and Zhang, F. (2025). Interpretable deep learning for personalized energy expenditure prediction using ecg and acceleration signals in incremental exercise. *Scientific Reports*, 15(1):36277.
- Strohrmann, C., Harms, H., and Tröster, G. (2012). Monitoring fatigue in running using body-worn sensors. In *2012 Ninth International Conference on Wearable and Implantable Body Sensor Networks*, pages fatigue-monitoring-1-6. IEEE.
- Ursul, I. and Pereymybid, A. (2023). Unsupervised detection of anomalous running patterns using cluster analysis. In *Proceedings of the 2023 IEEE 13th International Conference on Electronics and Information Technologies (ELIT)*, pages 148-152. IEEE.
- Van Hooren, B., Jukic, I., Cox, M., Frenken, K. G., Bautista, I., and Moore, I. S. (2024). The relationship between running biomechanics and running economy: A systematic review and meta-analysis of observational studies. *Sports Medicine*, 54(5):1269-1316.
- Wang, Z., Song, Y., Pang, L., Li, S., and Sun, G. (2025). Attention-enhanced cnn-lstm model for exercise oxygen consumption prediction with multi-source temporal features. *Sensors*, 25(13):4062.
- Wenzel, C., Liebig, T., Swoboda, A., Smolarek, R., Schlagheck, M. L., Walzik, D., Groll, A., Goulding, R. P., and Zimmer, P. (2024). Machine learning predicts peak oxygen uptake and peak power output for customizing cardiopulmonary exercise testing using non-exercise features. *European Journal of Applied Physiology*, 124(11):3421-3431.
- World Bank Group (2024). Mexico. *World Development Indicators*. [Online]. Available: <https://data.worldbank.org/country/mexico>.
- Zhang, H., Guo, Y., and Zanutto, D. (2020). Accurate ambulatory gait analysis in walking and running using machine learning models. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(1):191-202.
- Zhang, T., Zhang, M., and Luo, J. (2025). The application and development trends of wearable devices (wd) in endurance sports training: A literature review. *Quality in Sport*, 37:57604.