



Trabajo de Fin de Grado:

Inteligencia artificial aplicada a biomecánica

Autora:

Pilar Mollá Ortigas

Directores:

Sergio Gutiérrez Rodrigo

Luis Martín Moreno.

Junio 2022

AGRADECIMIENTOS

Agradecer a Javier Ruiz uno de los autores del artículo Ref.[4], por proporcionarnos la base de datos con la que iniciamos el desarrollo de los modelos de redes neuronales.

Luis Enrique Roche, investigador y profesor en la Universidad San Jorge de Zaragoza. Gracias por poner a nuestra disposición la base de datos con la que vamos a trabajar a lo largo del proyecto y por facilitarnos varios artículos bibliográficos biomecánicos.

Quiero hacer especial agradecimiento a mis dos directores del trabajo, Luis Martín por su apoyo e interés en este proyecto y a Sergio Gutiérrez por su paciencia conmigo, por su dedicación en este proyecto, por crearme una motivación en este ámbito y por su confianza durante la realización del trabajo.

Finalmente, agradecer a mi familia el apoyo recibido en estos años académicos, han sido un pilar fundamental en mi carrera de estudiante.

INTRODUCCIÓN	4
OBJETIVOS	5
METODOLOGÍA	5
MARCO TEÓRICO	5
4.1 Locomoción.	5
4.2 Biomecánica de la marcha.	6
4.2.1 Marcha.	6
4.2.2 Carrera.	7
4.3 Redes neuronales e inteligencia artificial.	8
4.3.1 Capas	9
4.3.2 Métrica	9
4.3.3 Función de activación	9
4.3.4 Hiperparámetros	10
4.3.5 Backpropagation	10
4.4 Inteligencia artificial aplicada a biomecánica.	10
DESCRIPCIÓN DE LA BASE DE DATOS	11
MODELO RUIZ Y TORICES	12
MODELOS DE LA RED NEURONAL	15
7.1 Datos de validación y entrenamiento.	15
7.2 Modelo simple	16
7.3 Modelo completo	19
CONCLUSIONES	24
REFERENCIAS	25

1. INTRODUCCIÓN

En la Edad Antigua se crearon paradigmas matemáticos y mecánicos que sirvieron para el desarrollo de la biomecánica, aunque su desarrollo definitivo como disciplina científica se encuentra en el siglo XIX. El conocido “Siglo de la Marcha” en el ámbito biomecánico, debido al desarrollo de métodos e instrumentos experimentales para el estudio de la locomoción humana.

Durante todos estos años los experimentos de laboratorio y las clínicas ofrecen una gran cantidad de datos y mediciones sobre el movimiento del cuerpo humano, provenientes de equipos de análisis biomédico. La accesibilidad al uso de sensores portátiles como *smartwatch* en los últimos años, ha provocado que se produzca un crecimiento exponencial en el volumen de datos [1].

Por otro lado, otra idea clave en este Trabajo de Fin de Grado (TFG) nace del concepto de inteligencia artificial (IA). La IA podríamos decir que surge en 1956, cuando varios científicos discutían acerca de cómo simular la inteligencia humana a través de máquinas. Con el paso del tiempo, la IA ha evolucionado hacia áreas de conocimiento más específicas.

La IA no es ajena a los estudios de biomecánica. Ya en 1995 Laphan y Bartlett, publicaron un artículo sobre el uso de IA en la biomecánica deportiva, donde combinaban distintas técnicas deportivas, con un soporte científico biomecánico y redes neuronales artificiales [2].

Actualmente, las herramientas de IA son mejores que las usadas hace unas décadas. Además, la gran cantidad de datos disponibles está llevando a que la combinación de la IA y biomecánica sea una realidad. Por ejemplo, la IA está sustituyendo a las herramientas estadísticas tradicionales en el modelado biomecánico, de forma que éste sea más eficiente.

La mayoría de los estudios biomecánicos surgen con el objetivo de analizar y comprender el movimiento del cuerpo humano en distintas circunstancias. El desarrollo actual de estudios biomecánicos trata de diagnosticar posibles anomalías en las estructuras del cuerpo, alteraciones musculares o incluso patrones perjudiciales en técnicas como son la marcha o la carrera [2]. En los últimos años, la aplicación de la IA en estos diagnósticos está siendo muy relevante destacando que la IA está jugando un papel muy importante en la evaluación de profesionales del deporte, tratando de optimizar el rendimiento específico de la actividad deportiva e individualizado a cada deportista [3].

Este TFG plantea un estudio preliminar de la biomecánica de la marcha mediante el uso de redes neuronales, que son parte esencial de las herramientas de la IA.

En este trabajo vamos a basarnos en el modelo de un artículo de Ruiz y Torices [4] que nos proporciona la relación de dependencia entre los parámetros espacio-temporales de la biomecánica. Nuestro modelo consiste en crear una red neuronal a la que le aportamos una serie de parámetros espacio-temporales y tiene que ser capaz de aprender y predecir la velocidad en carrera. Para ello, partimos de una base de datos que ha sido medida con equipos de análisis biomédico y creamos la red neuronal capaz de analizar los datos, aprender y predecir.

Una de las observaciones a tener en cuenta será si la red neuronal creada tiene la capacidad de mejorar el ajuste de esta dependencia, mejorando así la predicción de la velocidad en carrera en función de los parámetros espacio-temporales.

2. OBJETIVOS

- Diseñar y entrenar una red neuronal capaz de predecir la velocidad en carrera a partir de parámetros biomecánicos relevantes en la marcha y la carrera, como son la longitud de zancada, la altura del sujeto, el peso, la edad, la masa y el sexo.
- Comparar estos modelos basados en IA con un modelo conocido en el campo de la biomecánica: el modelo del péndulo forzado (MPF).
- Demostrar que una red neuronal es capaz de proporcionar predicciones, que mejoran la del MPF, con relativo poco esfuerzo.

3. METODOLOGÍA

Se ha utilizado un modelo conocido en el estudio de la marcha y la carrera, el MPF, concretamente una versión refinada del mismo planteada por Ruiz y Torices hace unos años [4]. La sencillez de este modelo, comparada con otros más complejos, nos ha llevado a la elección del mismo. Existen modelos más complejos como el conocido modelo masa-muelle [5]. Sin embargo, no hemos podido conseguir los datos necesarios para alimentar modelos más complejos, de ahí la elección del MPF.

La base de datos que se ha utilizado durante el transcurso del TFG para el entrenamiento y comprobación de los resultados fue proporcionada por el investigador Luis Enrique Roche de la empresa iBiomechanics que a su vez es profesor de la Universidad San Jorge de Zaragoza.

El diseño de las redes neuronales se basa en el programa Tensorflow y las librerías de Keras. Tensorflow es una plataforma de código abierto que facilita la creación de modelos de aprendizaje automático y Keras es una biblioteca de redes neuronales que se ejecuta sobre TensorFlow.

4. MARCO TEÓRICO

A continuación, se describen conceptos relevantes desde el punto de vista de la biomecánica necesarios para entender los distintos apartados del trabajo.

4.1 Locomoción.

El concepto principal y el más básico que debemos entender es cómo se define formalmente la idea de locomoción. La locomoción es la acción mediante la cual el cuerpo se mueve como un todo a través del espacio aéreo, acuático o terrestre con el fin de desplazarse. Este proceso requiere de la coordinación de dos o más extremidades multisegmentadas. Se entiende por extremidad multisegmentada aquella que está formada por varias partes o segmentos dispuestos en serie lineal. Por ejemplo la pierna, extremidad inferior del cuerpo humano.

Si nos centramos en el desplazamiento terrestre de un ser humano suele ser principalmente caminando o corriendo.

4.2 Biomecánica de la marcha.

La biomecánica es la ciencia que estudia la estructura, función y movimiento de los aspectos mecánicos de los sistemas biológicos. Concretamente, la biomecánica de la marcha es la acción de locomoción terrestre y bípeda, cuyos movimientos suceden de forma recíproca, encadenando ciclos completos para lograr un avance hacia delante.

Un parámetro muy relevante en la literatura científica centrada en el estudio de la biomecánica es el número de Froude. Es un parámetro que permite de forma sencilla diferenciar la locomoción entre sujetos de distinto tamaño a velocidades distintas y en entornos gravitacionales distintos. El número de Froude es una cantidad adimensional que viene dada por la siguiente expresión:

$$Nfr = \frac{v^2}{gh} \quad (1)$$

donde v es la velocidad de desplazamiento, g la aceleración de la gravedad y h la altura de la pierna.

Las fluctuaciones de energía mecánica del centro de masa que tienen lugar durante un paso, proporcionan información útil sobre los mecanismos utilizados para moverse [6]. El intercambio de la energía potencial a la cinética del centro de masas difiere según el ejercicio. En concreto, este cambio de influencia de las energías se ve reflejado en la transición del mecanismo de locomoción, de marcha a carrera. La transición según muchos expertos se da en torno a un valor de $Nfr=0.5$, es decir a unos 7.56 km/h [7]. De modo, para velocidades bajas (<7.56km/h), el mecanismo de locomoción será marcha y la energía potencial y la cinética se encuentran casi en oposición de fase. En cambio, en velocidades altas (>7.56km/h), da lugar el mecanismo de locomoción conocido como carrera y la relación entre energía potencial y cinética se ve influida por la energía elástica, como veremos a continuación.

4.2.1 Marcha.

La marcha se define como el mecanismo rígido de la biomecánica, similar al de un péndulo físico forzado. Un péndulo físico se trata de un cuerpo rígido que puede oscilar libremente en el campo gravitatorio alrededor de un eje horizontal fijo, que no pasa por su centro de masa. Cuando hablamos de péndulo físico forzado nos encontramos con que está sometido a una fuerza de rozamiento proporcional a la velocidad y a una fuerza externa tangencial sinusoidal.

El ciclo de marcha tiene dos fases, una fase de oscilación de la pierna y una fase de doble apoyo que se produce cuando ambos pies entran en contacto con el suelo al realizar un paso. Se considera ciclo completo de marcha cuando se producen dos pasos y en cada paso existe la fase de apoyo y la fase de oscilación.

En la marcha, la energía cinética y potencial van en contrafase, es decir cuando una aumenta la otra disminuye y viceversa produciendo transferencia entre ellas.

El modelo teórico elegido se basa en la física de un péndulo físico forzado. Es un modelo simple en el que obtenemos la relación de dependencia entre velocidad, longitud de zancada y altura

de la pierna. En este modelo se considera la pierna como un cilindro uniforme que puede oscilar alrededor del eje de giro que va de una cadera a la otra y se considera longitud de paso a la distancia lineal abarcada en un paso, es decir, distancia entre los sucesivos puntos de un pie al otro. Entonces, consideramos longitud de zancada (L) a la distancia abarcada en un ciclo, como hemos mencionado antes, un ciclo es equivalente a dos pasos.

Este modelo parte de la hipótesis de que cuando un sujeto comienza a caminar o correr, sus piernas son forzadas a oscilar en su frecuencia natural generando a ese ritmo un fenómeno de resonancia que viene dado por la eficiencia máxima entre la transferencia de energía interna del sujeto y energía mecánica (oscilación del péndulo).

$$T = 2\pi \sqrt{\frac{I_0}{MgD}} \quad (2)$$

$$I_0 = \frac{1}{3}Mh^2 \quad (3)$$

,dónde T es el periodo de oscilación, D es la distancia de un extremo de la pierna al centro de masas de la misma el cual consideramos que se encuentra a una distancia $D=h/2$ siendo h la altura de la pierna. I_0 es el momento de inercia de un cilindro con eje en un extremo y considerando el radio de la pierna despreciable.

Finalmente, la velocidad de este sistema se calcula como $v=L/T$, donde encontramos la siguiente expresión:

$$v \approx \frac{\sqrt{g}}{5} \frac{L^\alpha}{h^\beta} \begin{cases} \alpha = 1 \\ \beta = 0.5 \end{cases} \quad (4)$$

donde α y β son coeficientes teóricos.

4.2.2 Carrera.

La carrera se define como la acción de locomoción basada en un mecanismo flexible. Los modelos que se utilizan para describir la carrera en seres humanos son muchos y variados. Uno de los modelos es el modelo masa-muelle [5]. Consiste en una masa (cuerpo) sobre un muelle (pierna) que da lugar a transferencias de energía distintas en función de la fase de carrera en la que se encuentre.

El ciclo de carrera se compone de dos fases, una fase de apoyo y una fase de oscilación o fase de vuelo y cada una de ellas está caracterizada por una duración, tiempo de contacto y tiempo de vuelo. En la fase de apoyo el pie está en contacto con el suelo y aprovecha las fuerzas de reacción de este para generar una fuerza propulsiva que le permite elevarse y avanzar. En la fase de vuelo, a diferencia de la marcha, ninguno de los pies está en contacto con el suelo. Una oscilación se produce desde el punto más posterior en el despegue de un pie hasta el punto más anterior en el aterrizaje.

El modelo masa muelle, como hemos mencionado, nos indica que la pierna se comporta de manera similar a un muelle dando lugar a transferencias de energía. La energía cinética y potencial van en fase de modo que aumentan y decrecen a la vez. Esto provoca que entre en juego la energía elástica, diferenciando cada fase. En la primera fase, la fase de apoyo, se produce la transferencia de energía potencial y cinética a energía elástica que queda almacenada en los tejidos. En la segunda fase, fase de vuelo, esa energía elástica es liberada y se produce la transferencia ahora a energía potencial y cinética.

En este modelo entran en juego muchas más variables como el tiempo de vuelo y de contacto, la frecuencia de paso, el ángulo de paso, la rigidez de la pierna... Como hemos mencionado, es un modelo más complejo con parámetros biomecánicos de los que no disponemos.

4.3 Redes neuronales e inteligencia artificial.

La inteligencia artificial (IA) es la ciencia que combina algoritmos con el objetivo de crear máquinas capaces de analizar, comprender y resolver tareas con una capacidad similar o superior a la que consigue el ser humano.

Las redes neuronales son algoritmos inspirados en el funcionamiento de las redes neuronales humanas. Recuerdan una parte de lo que sabemos que hace el cerebro humano. Están compuestas de miles de unidades de computación conocidas como neuronas. Éstas, están interconectadas entre sí, agrupadas y organizadas en capas. Una capa es un conjunto de neuronas cuyas entradas provienen de los datos de entrada o de una capa anterior y cuyas salidas pasan a ser la entrada de una capa posterior o directamente los datos de salida de la red.

La arquitectura de la red viene dada por:

- La capa de entrada, contiene las variables de entrada.
- Las capas ocultas, contienen nodos no observables y el valor de cada unidad oculta es una función de los valores de entrada.
- La capa de salida, contiene las respuestas, donde cada unidad de salida es una función de las entradas ocultas.

El funcionamiento de una neurona, se ilustra esquemáticamente en la Figura 1. Consiste en recibir n datos de entrada ($x_1, x_2, x_3, \dots, x_n$) y calcular el peso ponderado de esos valores ($w_1, w_2, w_3, \dots, w_n$). Todos los pesos se escogen durante el aprendizaje obteniendo así, una función lineal que relaciona los datos de entrada y los pesos. A esta relación, además, se le aplica la función no-lineal, que en la jerga del campo de la IA se la conoce como función de activación.

Estas neuronas con función de activación son las que llamamos perceptrones que usan varios datos de entrada (x) para calcular finalmente los datos de salida (y).

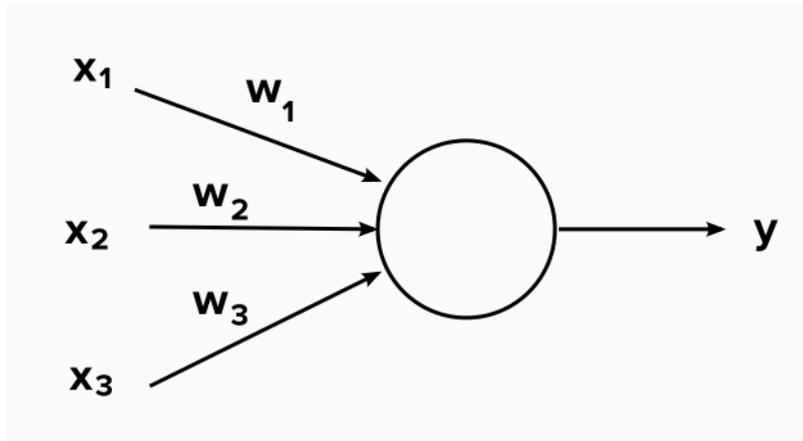


Figura 1. Funcionamiento de un perceptrón.

4.3.1 Capas

Definimos las capas de las que haremos uso en el TFG. Las capas densas son aquellas que conectan todas las neuronas de una capa con las neuronas de la siguiente. La capa *dropout*, es capaz de desactivar en cada interacción un conjunto de neuronas de manera que las neuronas cercanas no aprenden patrones sino que trabajan de forma solitaria.

4.3.2 Métrica

El optimizador, es el encargado de optimizar los valores de los parámetros para reducir el error cometido por la red.

La función de coste es la encargada de determinar el error entre el valor estimado y el valor real, con el objetivo de optimizar los parámetros de la red neuronal.

4.3.3 Función de activación

Hemos mencionado la función de activación como la función que se aplica a la neurona para dar lugar a los perceptrones. Vamos a definir las dos funciones de activación más utilizadas en redes neuronales que serán las que usamos en los modelos de este TFG.

La función *sigmoid*, Figura (2a) varía entre 0 y 1. Será aproximadamente 0 cuando el valor de x sea muy negativo y será 1 cuando el valor de x sea muy positivo.

La función de activación *relu*, Figura (2b) depende de un valor, donde vale 0 si ese x es negativo y vale x , es decir es lineal, si x es positivo. La derivada de la función es importante para el tiempo de aprendizaje y en la *relu* la derivada vale 1.

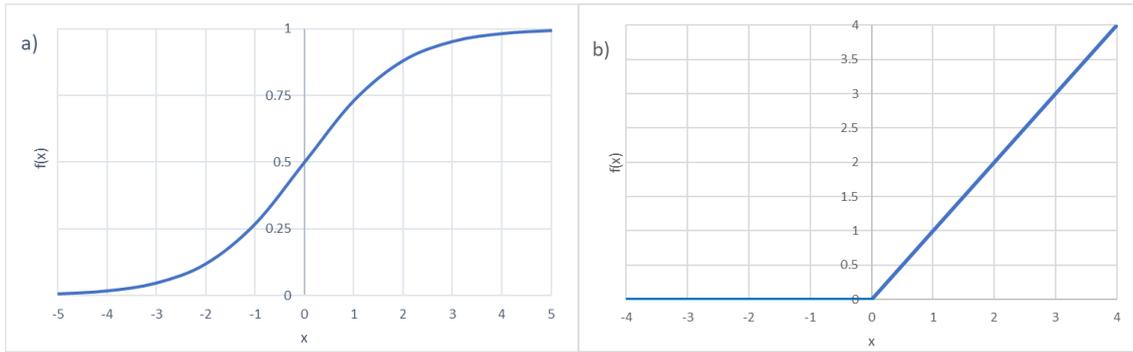


Figura 2. a) Función de activación *sigmoid* b). Función de activación *relu*

4.3.4 Hiperparámetros

Los hiperparámetros son los valores utilizados durante el proceso de entrenamiento que regulan el comportamiento de la red, por eso es importante el ajuste de hiperparámetros para controlar el aprendizaje de la red. Estos valores deben ser fijados antes del entrenamiento y podremos variarlos dependiendo de los resultados que obtengamos. La búsqueda de estos parámetros no es un procedimiento estándar, sino que depende de los datos que estemos analizando.

Los hiperparámetros típicos de una red neuronal, como los utilizados en este TFG son: el tamaño del *batch*, se refiere a la cantidad de ejemplos de entrenamiento utilizados en cada interacción, las épocas y la tasa de aprendizaje. Este último consiste en un hiperparámetro de ajuste para optimizar el algoritmo y determina el tamaño de cada paso en cada iteración. Este parámetro es iterado produciendo un avance hacia un mínimo en la función de pérdida durante el entrenamiento de la red.

4.3.5 Backpropagation

Es el proceso en el cual se calcula el gradiente de la función pérdida durante el entrenamiento de la red. Este cálculo consiste en ajustar los pesos de una red neuronal en función de la tasa de error obtenida en la iteración anterior. Un ajuste adecuado de los pesos durante el entrenamiento de la red garantiza un descenso de gradiente en la función pérdida.

4.4 Inteligencia artificial aplicada a biomecánica.

Este TFG pretende explorar el uso de redes neuronales en el análisis del movimiento del cuerpo humano en la marcha y la carrera. Los datos utilizados en el entrenamiento se han obtenido utilizando equipos de análisis biomédico, como son las unidades de medición, los acelerómetros, varios tipos de sensores, la técnica de electromiografía etc, en las dependencias de la empresa iBiomechanics.

La aplicación de la inteligencia artificial en el análisis y evaluación de la técnica de marcha y carrera es un propósito importante en el ámbito de la biomecánica [1]. Otras de las

aplicaciones importantes son la valoración de lesiones donde se pueden identificar anomalías o patrones perjudiciales en las estructuras del cuerpo humano para diferentes acciones biomecánicas [8] y el análisis de las técnicas deportivas tratando de maximizar el rendimiento individualizado de los deportistas [9].

Finalmente, los dispositivos de medida de los que disponemos en la actualidad, son potentes fuentes de datos que podrían estar sirviendo de entrada a redes de datos pre-entrenadas, que mejoren la predicción personalizada de ciertos parámetros relacionados con el estado de forma de una persona.

5. DESCRIPCIÓN DE LA BASE DE DATOS

La base de datos que se ha utilizado en este TFG fue proporcionada por el Profesor Luis Enrique Roche, actual docente e investigador en la Universidad San Jorge de Zaragoza en el área de Biomecánica humana y Biomecánica deportiva. Además, Luis es uno de los componentes de *iBiomechanics*, empresa dedicada a la investigación, innovación, desarrollo, transferencia y formación en biomecánica que trabaja para aproximar la biomecánica desde los más altos estándares de calidad científica y académica al uso diario en clínica.

Estos datos fueron medidos en la clínica de la empresa bajo la supervisión de profesionales con experiencia en investigación, en entorno clínico y deportivo.

La base de datos consta de 405 sujetos que fueron sometidos a correr en cinta a distintas velocidades desde los 3 km/h hasta los 22 km/h. De estos sujetos fueron medidos 7 parámetros: edad, sexo, altura, masa, longitud de zancada y cadencia (pasos por minuto) para cada una de las velocidades a las que fueron sometidos.

Obviamente, debido a la gran variedad de sujetos, no todos llegaban a correr a todas las velocidades expuestas de modo que la base de datos carece de algunos datos a velocidades altas en torno a 21 o 22 km/h e incluso carece de los datos correspondientes a 7 km/h ya que no fueron medidos.

Las condiciones de medida fueron con los sujetos sobre un tapiz rodante (cinta de correr), a velocidades determinadas. Con este parámetro fijo, se determinaba longitud de paso y la cadencia que fueron medidos con el *sensor Optogait*. Se trata de un sistema de obtención óptica de datos que está compuesto por un conjunto de cámaras y unas barras con sensores. *Optogait*, es el sistema de medición que combina todos los datos que nos ofrecen las barras junto con las imágenes de las cámaras y da lugar a un informe que permite corregir y mejorar, con una precisión de una milésima de segundo, la forma de correr o caminar hacia una forma más efectiva. Este sistema permite registrar el movimiento biomecánico, los tiempos de vuelo y de contacto durante la ejecución de la acción de locomoción, evaluar las condiciones físicas del sujeto (potencia, velocidad, resistencia...), identificar deficiencias musculares...

La altura fue medida con un *Estadiometro Seca* que se trata de un aparato de medida que permite determinar la estatura de los pacientes. Se compone de una sólida placa base y un

separador que contiene un tallímetro, que se trata del instrumento graduado en centímetros que se emplea para medir la altura del sujeto.

6. MODELO RUIZ Y TORICES

Como se ha comentado, los modelos físicos para marcha y carrera difieren entre ellos. Pero dada la sencillez del modelo MPF y la disponibilidad de datos, se ha preferido en este trabajo comparar la capacidad de predicción de las redes neuronales entrenadas con un modelo de tipo MPF corregido.

El modelo se describe en la Ref. [4]. Es un modelo semiempírico, en el que la velocidad depende únicamente de la gravedad, la zancada y la altura de la pierna, como el modelo descrito por la ecuación (4). Sin embargo, en el modelo semiempírico los coeficientes que aparecen en esa expresión difieren.

Este modelo da lugar a la expresión de dependencia de la velocidad en función de parámetros espacio-temporales y a diferencia del modelo teórico, tiene un factor añadido de $\frac{1}{4}$ y los coeficientes α y β distintos, cambiando así la expresión de la velocidad. En este trabajo, tomaremos como referencia la siguiente expresión del ajuste experimental que realizaron en el modelo Ruiz y Torices [4].

$$v = \frac{\sqrt{g} L^\alpha}{4 h^\beta} \begin{cases} \alpha = 1.67 \\ \beta = 1.17 \end{cases} \quad (5)$$

donde v es la velocidad, L la longitud de zancada, h la altura de la pierna y α y β en este caso, los coeficientes obtenidos del ajuste para el modelo experimental de Ruiz y Torices.

Una consecuencia directa a esta expresión es que un aumento de la longitud de zancada del animal implica un aumento de su velocidad.

Cabe destacar que en la base de datos del profesor Roche disponemos de la altura del sujeto y no de la altura de la pierna. Utilizaremos la relación encontrada por Winter et al.(Ref.[10]). La altura del sujeto está directamente relacionada con la altura de la pierna. Esta relación expresa que un 53% de la altura del sujeto (H) corresponde a la altura de la pierna (h). Además, en la base de datos disponemos del parámetro longitud de paso (l) y en el modelo se considera la longitud de zancada (L) que es la distancia en un ciclo completo como hemos mencionado antes, entonces $L=2l$.

En la Ref.[4] se plantea que el cálculo de la velocidad a partir de fósiles de huellas es un estudio fundamental que propone que los animales vivos y los extintos comparten algunas propiedades mecánicas comunes. El objetivo de este artículo era analizar la precisión de los cálculos de velocidad de los vertebrados fósiles (humanos incluidos) basándose en los fósiles de huellas.

Una de las imprecisiones de artículo que consideraron sus autores se basaba en que se requieren supuestos sobre el tamaño y proporciones de los animales, ya que no podían comprobar estos parámetros biológicos. Para ello, utilizaron datos de un experimento con

humanos que caminaban y corrían en la misma playa donde se encontraban los fósiles de huellas, de modo que las condiciones de medida no variaron.

Como hemos comentado, este modelo experimental viene dado por una expresión que da lugar a la relación entre velocidad y los parámetros espacio-temporales con coeficientes α y β distintos, ecuación (5).

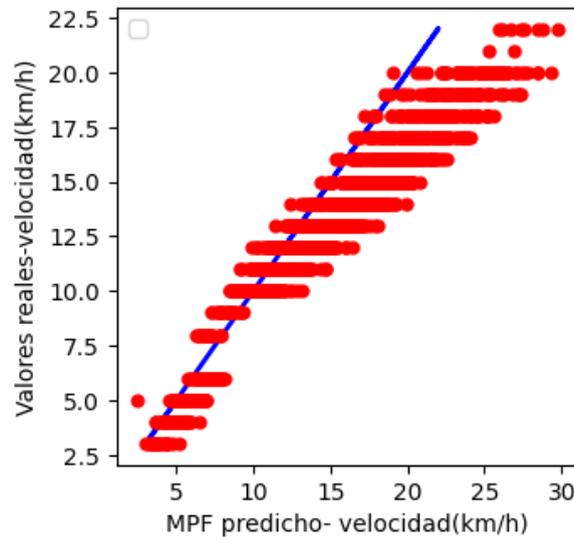


Figura 3. Representación de los valores de velocidad calculados en la ecuación (5) en función de los valores reales (puntos en rojo). Curva azul, predicción perfecta de la ecuación.

En la figura (3) podemos observar en rojo los datos reales pertenecientes a la base de datos proporcionada por el Profesor Roche en función de los predichos que han sido calculados por la ecuación (5) del MPF. Observamos la línea azul correspondiente a los valores predichos de velocidad en caso de que la ecuación fuese perfecta.

Como hemos comentado en la descripción de la base de datos, los valores reales de velocidad son discretos, ya que se fijó este valor en el tapiz rodante, por eso observamos prácticamente líneas horizontales para cada valor de velocidad real. En cambio, los valores predichos, calculados por la ecuación (5) son valores continuos a lo largo del rango completo de velocidades.

Nos encontramos con un *gap* (hueco) en los valores reales, representados en rojo en torno a 7 km/h. Esto se debe, como hemos mencionado, a que la base de datos no disponía de medidas concretamente para 7 km/h, luego no es posible la representación de estos datos.

Además, destacar que en la Figura (3), la tendencia de los valores predichos de velocidad se aproxima a la línea azul para valores entre los 2km/h y 10 km/h, exceptuando las altas velocidades.

Otra representación útil de los parámetros espacio-temporales del MPF se puede observar en la Figura (4). Se muestra la velocidad en km/h en el eje vertical, en función de la longitud de zancada en cm, en el eje horizontal. En esta representación encontramos de nuevo valores de

la base de datos, los reales en verde y los valores predichos en azul, calculados con la ecuación (5) de MPF.

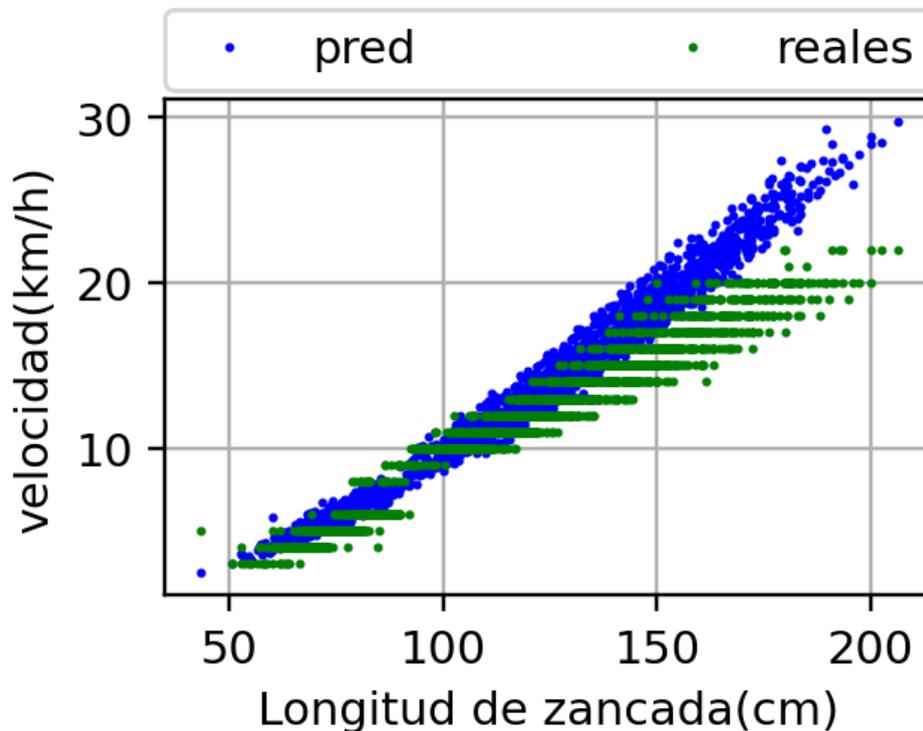


Figura 4. Velocidad (km/h) en función de la longitud de zancada (cm). En azul valores predichos por el modelo MPF y en verde los valores reales.

Análogo a lo mencionado para la figura (3), en la figura (4) observamos que para valores aproximadamente mayores a los 10km/h, la tendencia de los valores calculados (pred) cambia completamente y no se ajusta a los valores reales. Este resultado es justificable haciendo referencia al marco teórico, donde hemos definido que para valores aproximadamente de 8km/h se produce una transición de marcha a carrera que implica un cambio en el modelo a modelo masa muelle, para carrera y péndulo físico, para marcha. El artículo considera el mismo comportamiento biomecánico para todas las velocidades del sujeto, sin tener en cuenta esa transferencia de energía potencial y cinética a energía elástica y viceversa cuando nos encontramos en la acción biomecánica de carrera (velocidades mayores a 8 km/h).

Otra posible fuente de discrepancia entre la predicción del modelo MPF y las medidas experimentales se debe a la diferencia en las condiciones en las que los datos fueron tomados. En el artículo, como ya hemos mencionado, se mide la carrera en playa y en los datos obtenidos por el Profesor Luis el “experimento” se realizó en una cinta de correr. Como mencionan Ruiz y Torices en [4], la relación de la velocidad en carrera varía para cada tipo de superficie.

7. MODELOS DE LA RED NEURONAL

El modelo de péndulo físico forzado (MPF), como ya hemos visto, proporciona la velocidad a partir de dos únicos parámetros: la longitud de zancada y la altura de la pierna.

En el modelo de la red neuronal, al que llamaremos modelo simple, la base de datos consta de longitud de zancada, altura y velocidad. Estos tres parámetros son los que determinan la relación en el MPF, de modo que podremos comparar los dos modelos directamente.

La base de datos proporcionada por el Profesor Roche consta de parámetros extra que definen las características de cada sujeto como el sexo, la edad, la masa y la cadencia. El uso de estos parámetros nos va a permitir realizar un modelo completo en el que incluiremos un mayor número de variables en la entrada de la red.

Ambos modelos abordan el mismo problema de regresión lineal, que consiste en la predicción de una variable (velocidad) a partir de las variables de entrada. Distinguiremos las variables de entrada y la estructura de la red según el modelo simple o completo como podemos observar en el esquema detallado de la Figura (5).

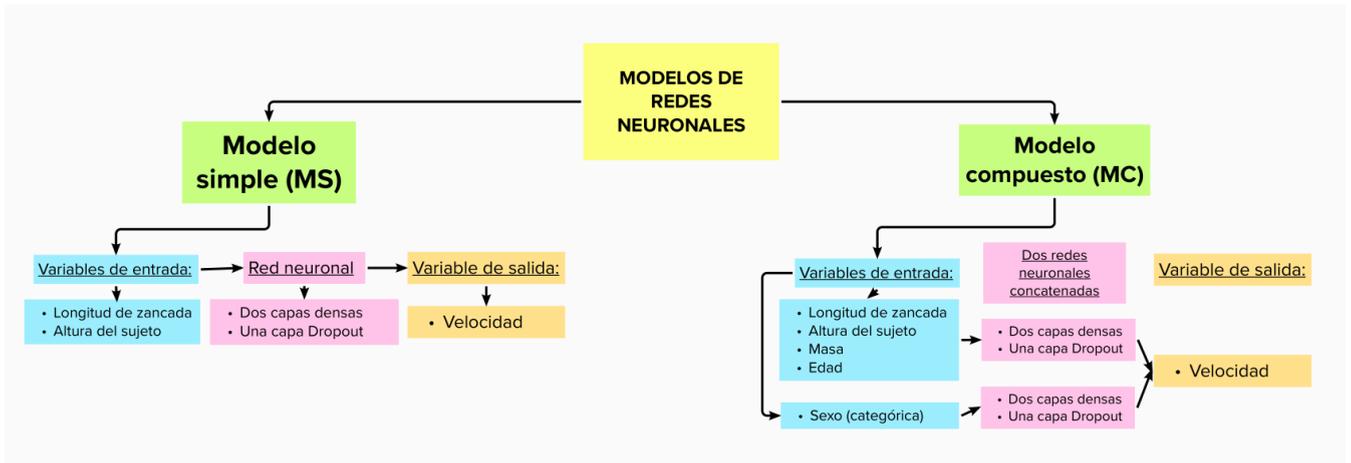


Figura 5. Esquema de la estructura de ambos modelos de redes neuronales creados.

7.1 Datos de validación y entrenamiento.

La entrada de la red neuronal es un vector definido por las siguientes componentes, edad, sexo, altura, masa y longitud de zancada en el modelo completo (MC) y por solo dos (longitud de zancada y altura) para el modelo simple (MS), directamente comparable con el modelo MPF. Hemos elegido la velocidad como parámetro de salida. Cabe destacar, que longitud de zancada, velocidad y cadencia son variables dependientes y únicamente con dos de ellas es suficiente para estimar la relación correspondiente al MPF.

$$ppm \propto \frac{v}{L} \quad (6)$$

donde, ppm es la cadencia, v la velocidad y L la longitud de zancada.

Disponemos de 2070 datos con la estructura que se ha definido en el anterior párrafo. Tomamos el 80% de ellos como datos de entrenamiento y el porcentaje restante para los datos de validación. Esto es una forma sencilla y estándar de separar nuestros datos donde los datos de entrenamiento son los proporcionados para que la red aprenda y los datos de validación sirven para comprobar que la red hace predicciones correctas con datos con los que no ha sido previamente entrenada. De esta forma se asegura que la red neuronal tenga la suficiente capacidad de abstracción y no sólo se limita a aprender los datos de memoria.

7.2 Modelo simple

El modelo simple (MS) se describe esquemáticamente en la Figura (5) (izquierda). Este modelo está compuesto por una red neuronal con dos capas densas ocultas, con 50 neuronas ocultas en cada capa y una capa *dropout* que ayuda a que no se produzca *overfitting*, fenómeno que ocurre cuando un modelo estadístico se ajusta exactamente a sus datos de entrenamiento, de modo que la red no aprende y no puede funcionar frente a otros datos introducidos no vistos.

Utilizamos *RMSprop* como optimizador. Como función de coste, se utiliza el error cuadrático medio, definido como el valor medio del cuadrado de la diferencia de los valores predichos y reales. La función de activación *relu* para una capa y *sigmoid* para la otra. Los valores de los hiperparámetros usados son el tamaño del *batch*=32, las épocas=200 y la tasa de aprendizaje=0.001. Una vez determinada la función de coste y entrenado el modelo, podremos evaluarlo.

En este modelo simple, la red neuronal aprende con los ya mencionados datos de entrenamiento y predice el parámetro de la velocidad. Una primera comparación, en la figura (6) es representar los valores reales (datos de entrenamiento) frente a los valores predichos por la red.

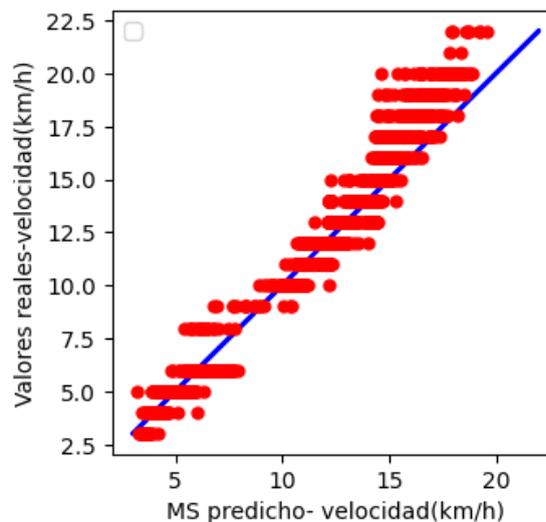


Figura 6. Representación de la predicción de la red en función de los valores reales (puntos en rojo). Curva azul, predicción perfecta de la red.

En la figura (6), los puntos en rojo corresponden a la predicción de la red en función del valor real y la línea azul simula una predicción perfecta de la red, es decir, $mse=0$. Para esta situación, todos los puntos rojos estarían sobre la línea azul.

Analizando la figura vemos que, por ejemplo, si el valor real es 5 km/h, la red predice valores entre los 2,5 km/h y los 6 km/h (aprox.). Individuos que en realidad corrieron a 5 km/h la red les asigna valores diferentes de velocidad. Este rango define la precisión con la que la red es capaz de predecir la velocidad de un sujeto.

La tendencia de los valores predichos de velocidad en la figura (6) se aproxima a la tendencia de la línea azul para valores entre los 2km/h y 12 km/h pero no se aproxima bien para velocidades altas, generando una tendencia distinta. Esto mismo sucedía en el MPF pero comparando esta figura (6) del MS con la figura (3) del MPF observamos que para el MS se ajusta mejor la velocidad predicha para velocidades altas que para el MPF.

A continuación, haciendo referencia al apartado de descripción de la base de datos, habíamos mencionado que para estimar la relación de dependencia de los parámetros espacio-temporales del MPF es suficiente con usar dos de las tres variables dependientes, ecuación (6). Así, representamos de nuevo velocidad frente a longitud de zancada para establecer una comparación directa con el MPF.

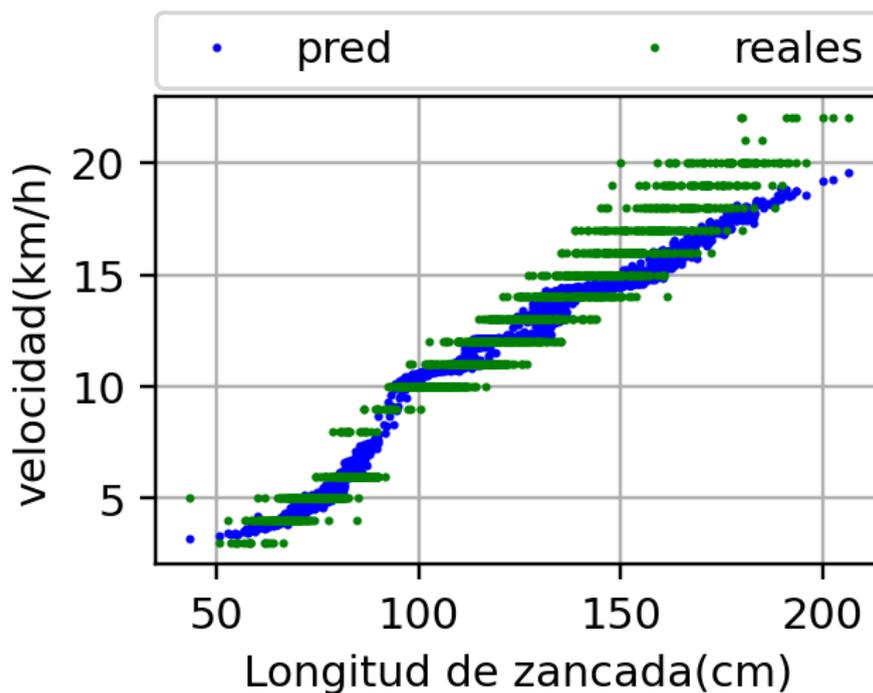


Figura 7. Velocidad (km/h) en función de la longitud de zancada (cm). En azul valores predichos por la red y en verde los valores reales.

Como observamos en la figura (7), la red es capaz de crear una nube de puntos (azules), que al contrario de los valores reales (verdes), son valores continuos a lo largo del rango de velocidades.

En esta figura (7), para los valores reales en verde, observamos que velocidad y longitud de zancada son variables directamente proporcionales, dato que ya conocíamos gracias a la fórmula proporcionada en el MPF. A su vez, la nube de puntos correspondiente a los valores de la red también da lugar a una proporcionalidad directa entre ambos parámetros. Observamos que al aumentar la velocidad, aumenta la longitud de zancada y viceversa.

La nube de puntos azules y los valores reales siguen una tendencia prácticamente lineal pero no se ajustan muy bien entre ellas, sobre todo para los valores más altos de velocidad desde los 10 km/h hasta los 22 km/h donde la tendencia cambia.

Como ya hemos mencionado, el ajuste es mejor para MS que para el MPF ya que vemos cómo se solapan mejor los valores predichos por la red a los valores reales, sobre todo para altas velocidades.

Este MS, a pesar de tener dos únicos parámetros como variables de entrada, es capaz de aprender y predecir la velocidad con precisión como se observa en el análisis de distribución de velocidades para el modelo MPF y el modelo MS.

La estadística de ambos modelos nos permite representar la diferencia entre las observaciones de los valores reales y los valores predichos, con la finalidad de determinar cómo de bueno es el ajuste.

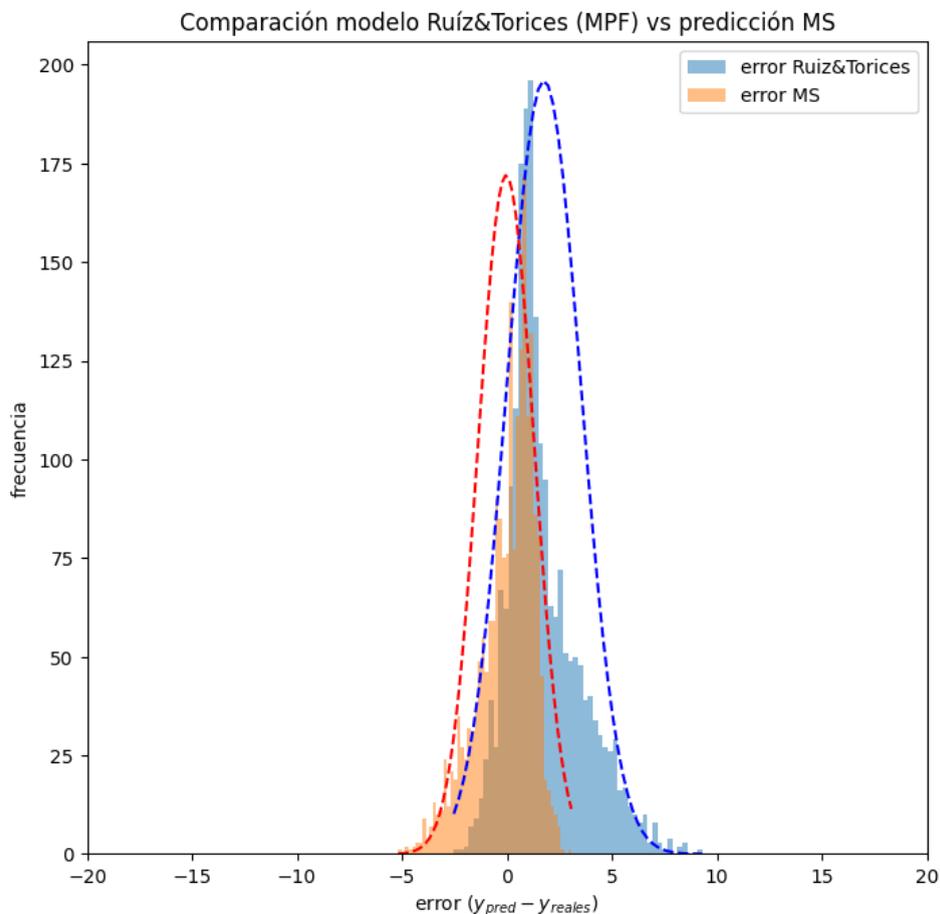


Figura 8. Distribución del error para el modelo MPF en azul y el MS de la red neuronal en naranja.

En la figura (8), vemos la representación de la distribución del error para el modelo de la red neuronal en naranja y para el modelo del péndulo físico en azul. Observamos que para el MS la predicción de la red tiene un valor picudo en torno a cero mientras que para el MPF no se produce esa centralización en cero.

La métrica mencionada anteriormente e implementada en el algoritmo nos sirve, junto con la figura (8) para comparar la predicción de los modelos MPF y MS.

Recordamos que el valor del error cuadrático medio nos proporciona el valor medio del cuadrado de la diferencia de los valores predichos y reales. El valor de *mse* obtenido para el cálculo de MPF es 6,19804 y para la predicción del MS es 1,24887. Como podemos comprobar, el valor de *mse* del MS es menor que el del MPF, con lo que concluimos que el MS es capaz de predecir la velocidad con mayor precisión.

7.3 Modelo completo

Este modelo completo (MC) desarrollado, a diferencia del MS, concatena dos redes, una en la que la variable de entrada incluye los datos categóricos, es decir, el sexo, variable que hemos codificado a 0 y 1 y otra red que incluye el resto de variables de entrada, edad, altura, masa y longitud de zancada. Como única variable output tendremos la velocidad.

Esto nos permite que la red pueda trabajar por dos vías diferentes donde cada vía tenga la interpretación correspondiente a la información introducida, en este caso, medidas experimentales y datos categóricos.

Análogo al MS, tenemos las redes con dos capas densas y una capa dropout. Respecto a la métrica usamos las mismas condiciones que el modelo simple exceptuando la función de activación.

Utilizamos *RMSprop* como optimizador. Como función de coste, se utiliza el error cuadrático medio *mse*. La función de activación para ambas capas es *relu* ya que *sigmoid* tiene como derivada máxima $\frac{1}{4}$ lo que implica un aprendizaje más lento. Los valores de los hiperparámetros usados son el tamaño del *batch*=32, las épocas=200 y la tasa de aprendizaje=0.0001, diez veces menor que para el MS. Una vez determinada la función de coste y entrenado el modelo, podremos evaluarlo.

Una red neuronal permite incluir mucha más información, incluyendo todo tipo de variables, incluso categóricas (sexo). Esto da lugar a un vector de entrada con mayor número de variables. En este modelo completo, vamos a hacer uso de todos los parámetros biomecánicos que nos proporcionó el Profesor Roche es su base de datos exceptuando la cadencia que como ya hemos visto en la ecuación (6), es dependiente de la velocidad y longitud de zancada, de modo que la desestimamos para evitar que la red memorice y no se produzca overfitting.

Una primera comparación, al igual que con el modelo simple, es representar los valores reales (datos de entrenamiento) frente a los valores predichos por la red.

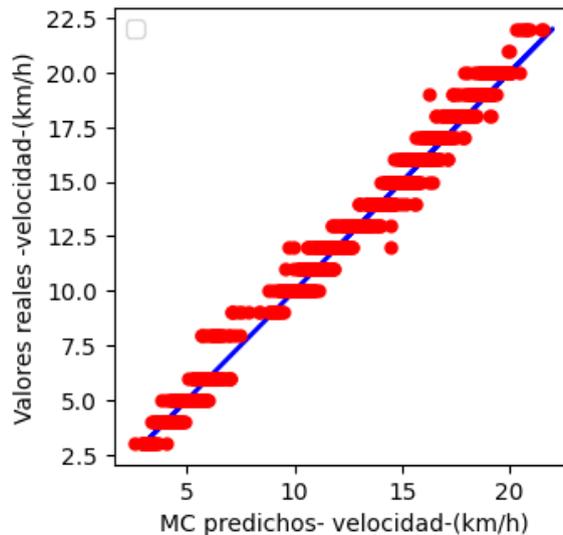


Figura 9. Representación de la predicción de la red en función de los valores reales (puntos en rojo).
Curva azul, predicción perfecta de la red.

En la figura (9), de nuevo los puntos en rojo corresponden a la predicción de la red en función del valor real y la línea azul simula una predicción perfecta de la red, que como hemos mencionado para esta situación todos los puntos rojos estarían sobre la línea azul.

Analizando la figura en este caso y poniendo el mismo ejemplo que para el MS, vemos que, para el valor real de 5 km/h, la red ahora predice valores entre los 3,7 km/h y los 5,3 km/h (aprox.). Como hemos definido anteriormente, este rango nos proporciona la precisión con la que la red es capaz de predecir la velocidad. Comparando las Figuras (6) y (9) nos encontramos con que el MC abarca rangos menores de velocidad predicha para cada valor de velocidad real.

La tendencia de valores predichos de velocidad en la Figura (9) se aproxima a la tendencia de la línea azul en todo el rango de velocidades, esto se observa ya que los puntos rojos se encuentran superpuestos sobre la tendencia lineal, que coincidiría con la situación de predicción perfecta por parte de la red.

Como hemos visto en los casos anteriores de MPF y MS la predicción no se ajustaba a los valores reales para velocidades altas, figuras (3) y (6).

Por analogía del MS, para el MC, tendremos la representación de velocidad y longitud de zancada, pudiendo así comparar gráficamente con los otros dos modelos MS y MPF.

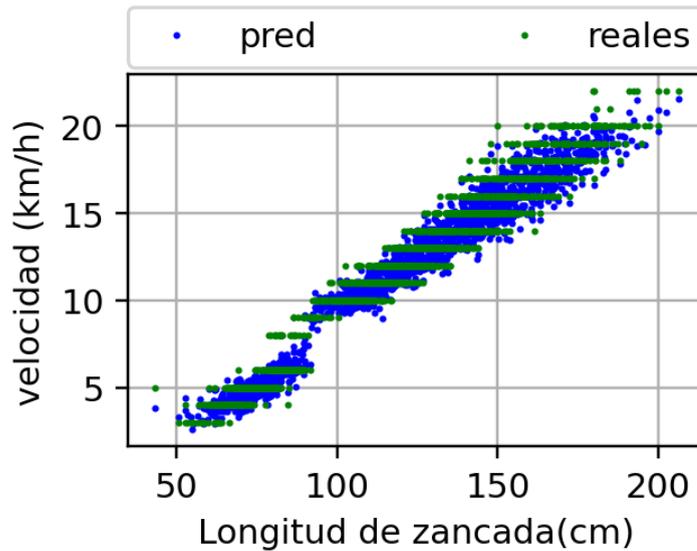


Figura 10. Velocidad (km/h) en función de la longitud de zancada (cm). En azul valores predichos por la red (pred) y en verde los valores reales (reales).

Como observamos en la figura (10), la red del modelo completo es capaz de aprender y generar una nube de puntos (azules), que al contrario de los valores reales (verdes), son valores continuos a lo largo del rango de velocidades.

A su vez, la nube de puntos correspondiente a los valores predichos da lugar a una proporcionalidad directa entre velocidad y longitud de zancada, al aumentar una aumenta la otra y viceversa.

La nube de puntos azules se ajusta bastante bien a los valores reales y ambos siguen una tendencia prácticamente lineal. Al contrario que en los modelos anteriores, para los valores más altos de velocidad desde los 18 km/h hasta los 22 km/h la red predice muy bien la velocidad para este rango. Observamos de nuevo el *gap* en torno a valores de 7 km/h como ya hemos justificado es debido a la ausencia de estos datos. En cambio, destacamos de nuevo que la red también es capaz de predecir los valores en torno a ese valor de 7 km/h ya que se observa que ha generado puntos azules donde se encuentra el *gap* de los valores reales de la base de datos.

Un resultado importante en esta figura (10), a diferencia del modelo simple, es que se observan dos rangos de velocidades en los que la red es capaz de ajustarse muy bien a los valores reales. Se observa un ajuste para velocidades bajas, menores que 8km/h y otro para velocidades altas, mayores a 8km/h aproximadamente. Volviendo al marco teórico, hemos introducido el número de Froude y hemos mencionado que para un valor $N_{fr}=0,5$ correspondiente a 7,56 km/h (aprox.), se produce la transición de marcha a carrera. Esta transición provoca un cambio en el modelo, para velocidades menores a 7,56 km/h, modelo de péndulo físico y para velocidades mayores a 7,56 km/h, modelo masa-muelle.

En el modelo del artículo MPF, consideran que para todas las velocidades la pierna actúa como péndulo físico forzado, esto es uno de los errores que influye en la tendencia observada en la

Figura (4) para velocidades altas. En cambio, la red es capaz de aprender que existe esa transición en torno a 7,56 km/h y que el comportamiento varía para velocidades altas, ajustando así la nube de puntos a la nueva tendencia. Esto se debe al incremento de los parámetros en el vector de entrada para el MC, dando lugar a una minimización en el error y generando un buen ajuste.

El valor del *mse* y la distribución del error confirman el buen ajuste del MC debido a la centralización de la distribución en cero como observamos en la figura (11)

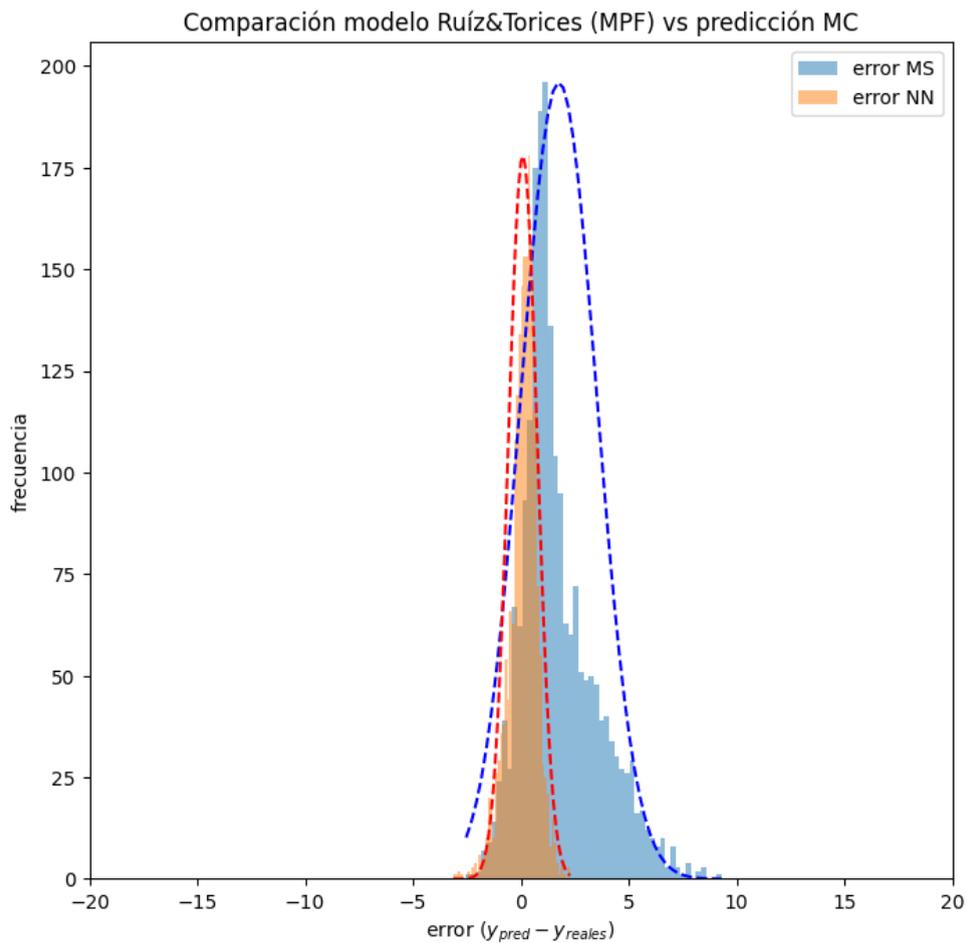


Figura (11). Distribución del error para el modelo MPF en azul y el MC de la red neuronal en naranja.

En la figura (11), observamos de nuevo en azul que la distribución del error para el MPF no está centrada en cero, a diferencia de la distribución del MC en naranja, que se encuentra centrada en cero. La distribución del error del MC, tiene un valor muy picudo en torno a cero con una anchura de pico menor que la del MPF e incluso menor a la anchura de la distribución del MS de la Figura (8) del apartado anterior.

De nuevo, la métrica implementada en el algoritmo nos lleva a comparar el *mse* de ambos modelos, obteniendo un valor de 6,19804 para el MPF y un valor de 0,00063 para el MC. Como podemos comprobar, el valor de *mse* del MC es cuatro órdenes de magnitud menor que el del MPF, con lo que concluimos que el MC es capaz de predecir la velocidad con mayor precisión.

La métrica mencionada anteriormente nos sirve ahora para comparar la predicción de los tres modelos MPF, MS y MC. Comparando los valores de *mse*, concluimos con que la predicción del MC es la más precisa debido a la minimización del error como podemos observar en la Tabla (1).

	<i>mse</i>
MPF	6,19804
MS	1,24887
MC	0,00063

Tabla 1. Valores del error cuadrático medio para modelo péndulo físico forzado (MPF), modelo simple (MS) y modelo (MC).

Hemos visto que ambos modelos MS y MC son capaces de predecir la velocidad a diferencia de que el MC ajusta sus valores predichos mucho mejor a los valores reales. Como hemos mencionado, este resultado se debe al incremento de parámetros en el vector de entrada.

Durante el trabajo, hemos mencionado en varias ocasiones el modelo masa-muelle, este modelo tal y como plantea el Profesor Luis en [5], tiene una dependencia distinta de la velocidad con los demás parámetros biomecánicos. Haciendo referencia a la definición en el marco teórico, este modelo está basado en considerar una masa (cuerpo) sobre un muelle (pierna) que da lugar a transferencias de energía distintas que involucran a un mayor número de parámetros como, por ejemplo el tiempo de contacto y de vuelo donde la transferencia de energía elástica influye de manera distinta en cada fase. A su vez, como menciona el Profesor Luis en [5] será necesario el parámetro de rigidez de la pierna, la frecuencia de paso, la masa del sujeto... para finalmente conseguir encontrar la expresión de la velocidad en carrera en función de esos parámetros más complejos.

Una de las principales diferencias expuestas entre el modelo simple y el compuesto ha sido el vector de entrada a la red neuronal donde el MC disponía de un mayor número de parámetros de entrada entre ellos la masa del sujeto. Haciendo referencia al artículo [11], se nos muestran los efectos en la longitud de zancada al añadir diferentes porcentajes de masa al mismo sujeto. En este artículo, a una velocidad determinada se va añadiendo gradualmente masa al sujeto y se observa que el tiempo de vuelo aumenta con la masa y el tiempo de contacto disminuye con ella. Otro de los resultados que muestra este artículo es que la longitud de zancada aumenta con el porcentaje de masa que se va incluyendo al sujeto, y tal y como hemos mencionado anteriormente, la longitud de zancada está directamente relacionada con la velocidad mostrando así que la masa es un parámetro que influye considerablemente en esta dependencia. La masa es uno de los parámetros biomecánicos que estamos incluyendo en la entrada de la red del MC, de modo que le estamos proporcionando un parámetro de gran influencia en la predicción de la velocidad.

Como podemos observar estamos hablando de una mejora en el error de varios órdenes de magnitud lo que concluye con que la red neuronal del MC es capaz de aprender y predecir la velocidad en carrera realizando una muy buena predicción y ajuste.

8. CONCLUSIONES

En este proyecto hemos utilizado herramientas propias de la IA para el estudio de cuestiones en el ámbito médico y deportivo, como es la biomecánica de la marcha y la carrera.

Hemos sido capaces de crear y entrenar una red neuronal que ha conseguido aprender y predecir la velocidad de un sujeto en función de otros parámetros espacio-temporales. Además, hemos sido capaces de desarrollar y entrenar otro modelo de red neuronal completo que mejoraba la predicción de la velocidad al añadir otros parámetros biomecánicos extra.

A lo largo de este trabajo, ha quedado claro que la IA juega un papel importante para el desarrollo de modelos biomecánicos. En general, la IA es una herramienta muy útil en la resolución de numerosos tipos de problemas y un gran avance en el desarrollo de numerosas áreas de conocimiento.

9. REFERENCIAS

- [1] Halilaj E, Rajagopal A, Fiterau M, Hicks JL, Hastie TJ, Delp SL. Machine learning in human movement biomechanics: Best practices, common pitfalls, and new opportunities. *J Biomech.* (2018)
- [2] Lapham A., Bartlett R. El uso de la inteligencia artificial en el análisis del rendimiento deportivo: una revisión de las aplicaciones en el análisis de la marcha humana y las direcciones futuras de la biomecánica deportiva , *Journal of Sports Sciences* 13. (1995)
- [3]. Khera P, Kumar N. Role of machine learning in gait analysis: a review. *Journal of Medical Engineering & Technology.* (2020)
- [4] Ruiz, J. & Torices, A. Humans Running at Stadiums and Beaches and the Accuracy of Speed Estimations from Fossil Trackways. *Ichnos* **20** (2013).
- [5] Seruendo, L. E. R. Análisis de las variables influyentes en el modelo masa- muelle aplicado a la carrera de larga distancia. (2018).
- [6]. Cavagna GA, Willems PA, Heglund NC. The role of gravity in human walking: pendular energy exchange, external work and optimal speed. *The journal of physiology.* (2000)
- [7] Alexander RM. Optimization and gaits in the locomotion of vertebrates. *Physiological reviews.* (1989).
- [8] Perl J., Weber K. Un enfoque de red neuronal para el aprendizaje de patrones en el deporte. *Revista Internacional de Ciencias de la Computación en el Deporte.*(2004).
- [9]Yan B., Wu Y. El modelo de análisis basado en ANN de las técnicas deportivas . *Actas del XVIII Simposio Internacional sobre Biomecánica en el Deporte* , Volumen 2 Hong Y., Johns D.The Chinese University of Hong Kong, Hong Kong SAR, China: (2000).
- [10] Winter, D. A. Biomechanics and motor control of human movement. Wiley (2009).
- [11] Luis E. Roche-Seruendo, Felipe García Pinillos, Isabel Auria-Martin, Ana V. Bataller-Cervero, Pedro A. Latorre Román & Victor M. Soto -Hermoso. Effects of different percentages of body weight support on spatiotemporal step characteristics during running, *Journal of Sports Sciences.* (2018).