



Módulo 2. Análisis de series temporales



En el curso anterior, destacamos las ventajas de poder realizar cálculos con el *raw data* que proveen ciertas herramientas tecnológicas de recogida de datos como los GPS, las plataformas de fuerza y los acelerómetros. También hicimos referencia, en múltiples contenidos, a los conceptos frecuencia de muestreo o Hz (número de datos por segundo que la herramienta registra). Este tipo de datos, dada su estructura de registro continuo en intervalos temporales, se puede clasificar en un grupo específico de tipo de datos. Se trata de las series temporales, aquellas observaciones registradas a lo largo de distintos intervalos de tiempo.

Aunque el análisis de series temporales en ciencia de datos habitualmente se asocia a ámbitos como las finanzas y la economía, en este módulo pretendemos describir cuáles son las particularidades de algunos de los datos que se recogen en nuestro contexto profesional que cumplen con algunas de las características de las series temporales y ver qué opciones tenemos para utilizar y tomar decisiones a partir de su análisis.

No vamos a hablar de métodos avanzados para el análisis de series temporales, sino que pretendemos acercarnos a contextos reales dentro de nuestro ámbito, así como presentar ideas de situaciones específicas donde trabajamos con estos datos.

Para abordar estos conceptos, vamos a diferenciar el tipo de serie temporal según la duración total de su registro, es decir, queremos diferenciar aquellos múltiples puntos de registro o datos que recogemos en un día o un test (GPS o test de salto) de aquellas evaluaciones periódicas que queremos evaluar más a medio o largo plazo (test físicos, respuesta cardiaca, etc.). Ambos fenómenos cumplen con la premisa de ser datos obtenidos de manera repetida a lo largo del tiempo; la diferencia reside en el tiempo entre observaciones.

☰ **1. Series temporales micro**

☰ **2. Series temporales meso**

☰ **Actividades**

☰ **3. Variabilidad como factor fundamental en el contexto de rendimiento deportivo**

☰ **Actividades**

☰ **4. Series temporales macro**

☰ **Actividades**

☰ **Referencias**

1. Series temporales micro

Hemos decidido asignar el nombre de “series temporales micro” a aquellos datos que representan una acción o un conjunto de acciones registradas durante un periodo de tiempo corto y prácticamente ininterrumpido. Queremos remarcar que, para considerarlas series temporales, deben constar de múltiples registros de una señal de intensidad a lo largo del tiempo y con una frecuencia de registro constante.

Siguiendo las características de estas series temporales, podemos encontrar ejemplos claros en el contexto del rendimiento deportivo.

Saltos registrados en la plataforma de fuerza:

- Acciones registradas: 1-5 saltos, registro de manera continua.
- Señal de intensidad registrada: fuerza

- Frecuencia de muestreo: habitualmente, 1000 Hz (registros de la señal de intensidad cada segundo).

Test isométricos con galgas de fuerza:

- Acciones registradas: 1-5 contracciones, registro de manera continua.
- Señal de intensidad registrada: fuerza
- Frecuencia de muestreo: habitualmente, >100 Hz (registros de la señal de intensidad cada segundo).

Dispositivos GPS:

- Acciones registradas: duración total de la sesión, registro de manera continua.
- Señal de intensidad registrada: posición en dos coordenadas; a partir de ella, se calcula el resto de las métricas.
- Frecuencia de muestreo: habitualmente, 1-10 Hz (registros de la señal de intensidad cada segundo).

Acelerómetros:


- Acciones registradas: duración total de la sesión, registro de manera continua.
- Señal de intensidad registrada: posición en tres coordenadas; a partir de ella, se calcula el resto de las métricas.
- Frecuencia de muestreo: habitualmente, 100 Hz (registros de la señal de intensidad cada segundo).

Como vemos, todos estos ejemplos cumplen con las premisas de las series temporales micro. No entraremos en detalle, ya que en el curso anterior vimos algunas de las herramientas de análisis de las series temporales y también consideraciones para garantizar la calidad de los datos que tratamos (uso de RStudio para tratar con el gran volumen de datos su filtrado).

El objetivo de nuestro análisis marcará el tratamiento de los datos y la extracción de características de este. Un ejemplo puede ser el gráfico de la figura 1: a partir de la serie temporal de la fuerza registrada en un salto, utilizamos RStudio para determinar las distintas fases del salto (marcadas por colores); a partir de ahí, podemos determinar

características en cada una de ellas (producción de fuerza total, incrementos, picos, etc.).


Figura 1: Fases de salto



Fuente: elaboración propia.

Con el desarrollo de la tecnología en los últimos años, los ejemplos de este tipo de series temporales y sus análisis derivados siguen creciendo. Actualmente, disponemos de tecnología capaz de registrar la posición de los distintos segmentos corporales y de articulaciones a lo largo de acciones o movimientos, lo que hace que no haga falta utilizar dispositivos externos ni marcadores.

Figura 2: Ejemplo de una herramienta de análisis de movimiento mediante captura de video



Fuente: Captura de pantalla de Uplift (<https://www.uplift.ai/>).

CONTINUAR

2. Series temporales meso


En los cursos iniciales, también destacamos la importancia de registrar de manera estructurada aquellos elementos relacionados con la pregunta que queremos responder, establecer evaluaciones periódicas para detectar cambios, o conocer la variabilidad de nuestros jugadores para determinar intervenciones o cambios en nuestra periodización o prescripción de entrenamiento. En deportes donde el periodo competitivo es de duración extensa, queremos conocer los cambios del jugador a lo largo del tiempo, ya que tenemos la capacidad de registrar datos de manera continua diariamente (GPS), semanalmente (test de salto), etc. A este tipo de series temporales le asignamos el término de “series temporales meso”, pues se han registrado de manera periódica, pero no de continua, en un espacio de tiempo que puede durar entre semanas y meses.

Una pregunta habitual para responder cuando valoramos este tipo de datos es si existen cambios en la respuesta de los jugadores, pues puede ser un indicativo de adaptación a la carga por parte del jugador y, por lo tanto, consistir en una mejora, o bien de un posible estado de

fatiga si estos valores se han visto reducidos o si ha ocurrido algún evento que provocó modificaciones en la respuesta del jugador.

A continuación, vemos el ejemplo de registro de un valor a lo largo de distintas sesiones de entrenamiento, por lo tanto, registrado de forma diaria. Una de las principales aplicaciones del análisis de series temporales es el análisis de tendencia de los datos, es decir, qué dirección siguen los datos a lo largo de los registros. En este caso, vemos dicha tendencia representada por la línea azul.

Figura 3: Registro de un valor a lo largo de distintas sesiones de entrenamiento




Fuente: elaboración propia.

Si queremos utilizar un ejemplo aplicado al contexto de los datos de rendimiento deportivo, estos valores registrados podrían tratarse, por ejemplo, de una variable registrada por un dispositivo GPS. Este gráfico podría estar indicando que un jugador ha experimentado un aumento de su demanda condicional a lo largo de las sesiones registradas.

La tendencia representa los datos “suavizados” de tal manera que resume lo que está pasando, utilizando datos de múltiples sesiones a la vez, en lugar de fijarse en valores o picos individuales. De esta manera, podemos visualizar claramente que ha habido un cambio hacia valores superiores en algún punto de la serie temporal (sesiones). Como veremos en el curso, podemos utilizar diferentes herramientas de suavizado de datos como los promedios móviles. Estas herramientas pretenden resumir lo que ha pasado en un periodo temporal más largo que un solo punto o sesión, pero más corto que la duración total del registro o temporada. Aplicando distintas ventanas de análisis a los promedios móviles (resumen cada 3/5/10 sesiones, por ejemplo), podemos ver con más detalle qué es lo que está sucediendo en cada uno de esos periodos con las demandas condicionales del jugador.

Figura 4: Valles y picos en la señal del promedio móvil



Fuente: elaboración propia.


En el gráfico anterior, vemos que hay distintos valles y picos en la señal del promedio móvil (línea roja). Una forma de aplicar este tipo de análisis es usarlo para determinar si estas tendencias o estos ciclos están alineados con la periodización planteada del entrenamiento y constatar que estemos realizando una ondulación de la carga semana a semana (semanas de mayor volumen o intensidad alternadas con semanas de reducción de carga).

Imaginemos que el análisis anterior no sigue el patrón que habíamos planificado, es decir, vemos que hay cierta ondulación en los valores a lo largo de las sesiones. Sin embargo, el primer gráfico con la línea azul marca claramente que hay un aumento de la demanda física a lo largo de las sesiones, pero este aumento no estaba previsto en

nuestra periodización. En este caso, queremos determinar cuál ha sido la posible causa de ese aumento.

Uno de los enfoques que podemos utilizar (de nuevo, haciendo uso de herramientas aplicadas al análisis de series temporales) son los algoritmos de detección de cambios. Estas son funciones que podemos utilizar en RStudio para aplicarlas directamente en nuestros datos. La utilización de estas funciones permite determinar, en primer lugar, si ha habido algún cambio significativo en los valores registrados durante la serie temporal (sesión a sesión) y, en segundo lugar, conocer en qué punto se ha producido, algo fundamental en muchos casos. A continuación, vemos cómo se ha aplicado dicha función a la misma serie temporal.

Figura 5: Algoritmos de detección de cambios



El resultado nos muestra que se ha producido un cambio, representado por las dos líneas horizontales de distinto valor y en un punto concreto, en la sesión 129. Esta información nos puede servir como punto de partida para buscar los motivos que pueden estar causando este cambio. Siguiendo con el ejemplo de valores obtenidos mediante un dispositivo GPS que representen la demanda condicional del jugador, un motivo podría ser que el entrenador haya cambiado de posición al jugador en cierto momento de la temporada (en este ejemplo, a partir de la sesión 129). Este cambio podría haber generado un aumento de la carga, dadas las particularidades de la posición en la que ahora está jugando el jugador.

Los ejemplos de aplicación de este tipo de análisis son múltiples, y las ventajas y la información que aportan son fundamentales: valorar en qué momento el jugador tiene mayor o menor asimetría durante la carrera (lo cual puede haber estado relacionado con un golpe o molestia física), conocer en qué momento se han producido cambios mecánicos en movimientos más analíticos e indagar en su causa, entre otros.

CONTINUAR

Actividades

¿Cuáles de las siguientes afirmaciones son correctas acerca de las "series temporales meso" según el texto?

- Se registran de manera continua diariamente, como los datos de GPS.
- Se registran de manera periódica pero no continua.
- Permiten conocer los cambios del jugador a lo largo del tiempo en periodos de semanas a meses.
- Solo se registran semanalmente con test de salto.
- Se refieren únicamente a datos recogidos durante una competición corta.

SUBMIT

CONTINUAR

3. Variabilidad como factor fundamental en el contexto de rendimiento deportivo

En el contexto del rendimiento deportivo, debemos ser conscientes de que cualquier valoración que realicemos con nuestros jugadores o atletas tendrá una cierta variabilidad asociada al mismo test (conocida como “fiabilidad”) y al propio jugador (Hopkins, 2004), es decir, el jugador tendrá fluctuaciones consideradas “normales” en las valoraciones que realicemos. Estas variaciones también son específicas de la métrica analizada. Por ejemplo, un test de salto en el que utilizamos como medida de rendimiento el *Peak Power/BM* tendrá una cierta fluctuación test a test para cada jugador o grupo, mientras que en otra variable su variabilidad será distinta. Hay métricas que serán más estables (menos cambios sesión a sesión) y otras que tendrán mayor variabilidad. Este concepto lo vemos claramente en variables analizadas en dispositivos GPS en deportes como el fútbol. Hay que tener en cuenta que este último es un deporte con alta complejidad, donde sus factores contextuales (rival, formación, tipo de sesión de entrenamiento, etc.) afectan la variabilidad de las métricas registradas.

Clubb et al. (2022) analizan la variabilidad de las distintas métricas del equipo observado en múltiples tareas de entrenamiento y la variabilidad intrajugador. El objetivo de este análisis es determinar qué métricas tienen una menor variabilidad para utilizarlas como referencia y así establecer diferencias entre las distintas tareas planteadas.

Figura 6: Diagrama de violín del CV intrasujeto para cada medida de carga de entrenamiento externa en tres formatos diferentes de SSG





Fig 1. A violin plot of the within-subject CV for each external training load measure across three different SSG formats. TD—Total distance; m/min—metres per minute; PL—PlayerLoad™; PL/min—PlayerLoad™ per minute; PL/metre—PlayerLoad™ per metre; PL_{AP} (%)—% contribution to PlayerLoad™ in the Anterior-Posterior plane; PL_{ML} (%)—% contribution to PlayerLoad™ in the Medial-Lateral plane; PL_V (%)—% contribution to PlayerLoad™ in the Vertical plane; CV%—Coefficient of variation.

Fuente: Clubb et al., 2022, <https://tinyurl.com/4f6vzn5m>.

Este análisis de la variabilidad es de gran utilidad cuando analizamos series temporales meso, ya que podemos utilizarlo para determinar cuándo se han producido cambios en la tendencia de los datos que estamos obteniendo. Podemos ver un ejemplo a continuación; se trata de una combinación de referencias para el análisis de la demanda condicional en la métrica de distancia recorrida por encima de 21 km/h a lo largo de las jornadas de competición.

Los puntos del gráfico representan la distancia por encima de 21 km/h de un jugador a lo largo de las jornadas que ha competido, y la línea vertical que atraviesa cada punto es la variabilidad del jugador. El área sombreada azul muestra los valores del equipo (promedio y rango de desviación estándar). De esta manera, podemos evaluar cuál ha sido la exigencia a nivel grupal (área azul) y así aportar a la información que tenemos sobre si el partido ha sido más o menos exigente. Con esta referencia, determinamos si el jugador ha estado por encima o por debajo de esos valores. Además, si las líneas verticales no están dentro de esa área azul, podemos entender que sus valores han estado muy por debajo o muy por encima de la exigencia grupal, ya que, ni considerando su variabilidad habitual entre partidos, el jugador seguiría estando fuera de ese rango del equipo. Podemos usar esta información para tomar las decisiones correspondientes si determinamos que esta variable es un factor de rendimiento clave para nuestro equipo y plan de juego.

Figura 7: Combinación de referencias para el análisis de la demanda condicional en la métrica de distancia recorrida por encima de 21 km/h a lo largo de las jornadas de competición



Fuente: elaboración propia.

Con este ejemplo, pretendemos mostrar las diferencias entre analizar el dato crudo (valor de distancia >21 km/h) jornada a jornada y analizarlo aportando información contextual. Si analizáramos únicamente los valores crudos, podríamos considerar que la jornada 7 ha sido una de las jornadas cuando el jugador ha tenido menor desempeño físico, pero si observamos lo que ha realizado el equipo, vemos que ha sido un partido de menor exigencia a nivel grupal. Sin

embargo, en la jornada 5 el jugador ha tenido una mayor distancia que en la jornada 1, pero esta ha estado mucho más alejada de lo que ha realizado el equipo.

Como sabemos, en la monitorización de la carga de entrenamiento, existen múltiples variables utilizadas para su análisis, lo mismo ocurre con otros tipos de medidas de rendimiento físico, como pueden ser test o variables cinemáticas. Por lo general, queremos analizar más de una variable a la vez, para así tener una mejor representación de lo que está ocurriendo en el entrenamiento o la competición. Si, además, queremos añadir el análisis de variabilidad a cada una de estas métricas, considerando las diferencias entre ellas, la complejidad de la comparativa aumenta, ya que podemos estar hablando de métricas o variables con distintas escalas (por ejemplo, RPE con una escala del 1 al 10 y distancia total con una escala de 200 a 12000 metros) y con variabilidades distintas entre ellas.

Para poder estandarizar esas medidas y realizar comparativas entre variables y jugadores considerando la variabilidad, podemos utilizar las Z-scores. Estos valores miden la posición del valor crudo (por ejemplo, 200 m de distancia >21 km/h) respecto al promedio y dan un valor en desviación estándar. Por lo tanto, este valor será en las mismas unidades para cualquier métrica analizada con Z-score, habitualmente, entre -3 y 3. Los valores negativos indicarán un valor por debajo de los valores habituales del jugador, y los valores positivos indicarán valores superiores. Cuanto más alejados los valores de 0,


más extremo será el valor crudo que analicemos. Como observaremos en el material de video, RStudio permite realizar este tipo de cálculos de manera directa y eficiente.

Como vemos, no solamente podemos estandarizar y hacer comparaciones en las mismas unidades para distintas métricas, sino que también podemos determinar ese promedio y esa variabilidad. Con esto, nos referimos a que es posible que muchas veces no estemos interesados en utilizar el valor promedio de toda la temporada para determinar si el valor de un día puntual ha sido más o menos exigente. Como vimos, los jugadores experimentan cambios durante la temporada, y podríamos establecer, según nuestro contexto y enfoque como *sport scientists*, que el periodo óptimo como referencia para los datos más recientes debe contener, por ejemplo, únicamente los valores del último mes.

Vemos, a continuación, un ejemplo aplicado al control de la carga semanal para un equipo de fútbol. En la figura 8 se representan dos variables: una de carga interna (RPE), en el eje vertical, y otra de carga externa (número de aceleraciones), en el eje horizontal. El tipo de gráficos de scatterplot se utiliza para observar qué jugadores y en qué métrica los jugadores han obtenido mayores o menores valores, y también la relación entre las variables. En esta figura queremos representar cuán exigente ha sido la sesión para cada uno de los jugadores si la comparamos con los valores habituales; así, al acabar la sesión, podremos tomar decisiones en función de los resultados. Se

le ha aplicado una Z-score a cada uno de los valores, utilizando como referencia el promedio de cada uno de los jugadores (no el promedio grupal) y únicamente en el mismo tipo de sesión (MD-3, es decir, todas las sesiones realizadas 3 días antes de la competición). Se ha escogido este enfoque porque conocemos que existen diferencias entre tipos de sesiones según la proximidad al partido y porque cada jugador tiene variabilidad específica.

Figura 8: Variables de carga interna y de carga externa



Show entries Search:

Date	Session	Name	RPE	AlertaY	Acceleration B1-3 Total Efforts (Gen 2)	AlertaX	Alerta	Accion
2021-02-18	MD-3	Fazekas, Michael	NA		70	↑		Valores Bajos
2021-02-18	MD-3	Sherman, Aaron	4.5		71			Valores Bajos
2021-02-18	MD-3	Fox, Zechariah	9.0	↑	76			Revisar Carga Anterior
2021-02-18	MD-3	Brown, Eric	5.5		47	↑		Revisar Wellness de Mañana
2021-02-18	MD-3	Petrie, Brian	10.0	↑	65			Revisar Carga Anterior

Showing 1 to 5 of 21 entries Previous Next



Fuente: elaboración propia.

En el gráfico anterior vemos los jugadores que se sitúan con valores de Z-score altos: a la derecha para la variable de carga externa, y arriba para la variable de carga interna. Si nos fijamos en la tabla, vemos el valor crudo de cada una de las variables y podemos percibir la importancia de utilizar Z-scores en un caso como el del ejemplo. El jugador Eric Brown ha realizado 47 aceleraciones y se sitúa a la

derecha del gráfico para la variable de número de aceleraciones; por su parte, el jugador Aaron Sherman ha tenido un mayor número de aceleraciones (71), pero su valor se sitúa centrado. Esto indica que el jugador Eric Brown, en las sesiones MD-3, habitualmente realiza un número menor de aceleraciones y que la sesión de ese día concreto fue de mayor intensidad; no obstante, el Z-score de Brown, con un número mayor de aceleraciones, es 0. Esto puede indicar, por un lado, que el valor se sitúa cercano a su promedio y, por otro, que el jugador está acostumbrado a soportar esta carga en las sesiones de este tipo o se ha adaptado a ello.

El contexto en el que nos encontramos y el conocimiento de los parámetros que pueden estar afectando la variabilidad y los cambios de los datos de la serie temporal que analizamos son fundamentales para extraer conclusiones y tomar decisiones. En el siguiente ejemplo de Altini (2020) (figura 9), vemos cómo en el análisis de una variable como HRV (Heart Rate Variability), la cual tiene una gran variabilidad día a día, es fundamental establecer rangos de referencia en los cuales se tengan en cuenta esas fluctuaciones para no tomar decisiones erróneas. Una vez cumplido ese requisito, se puede considerar el resto de los factores que puedan estar afectando los valores analizados.

Figura 9: Análisis de una variable de HRV



HRV Training

Fuente: Altini, 2020.

CONTINUAR

Actividades

En el contexto del rendimiento deportivo, ¿qué factores contribuyen a la variabilidad en las valoraciones realizadas a los jugadores o atletas?

- La técnica del entrenador.
- La fiabilidad del test utilizado.
- Las condiciones climáticas.
- Las fluctuaciones normales del jugador.
- El tipo de deporte practicado .

SUBMIT

CONTINUAR


4. Series temporales macro

Finalmente, aunque hayamos visto ejemplos donde la recogida de datos es extensa en el tiempo y dure semanas y meses, queremos explicar una categoría más que engloba aquellas series temporales con las cuales se realizan análisis más complejos o donde el volumen y, sobre todo, la duración del registro es muy significativa. Este apartado pretende remarcar la importancia de establecer planes de recogida de datos a largo plazo, dentro de la estructura del equipo o de la organización en la que trabajemos. Estos datos históricos nos permiten grandes posibilidades de análisis en el futuro, incluso con herramientas que aún están en desarrollo, pero con las cuales podremos utilizar esos datos almacenados del pasado.

No pretendemos ver de nuevo algoritmos ni modelos avanzados para el análisis de datos. Únicamente se muestra el siguiente ejemplo (figura 10) para remarcar que se pueden aplicar metodologías de análisis específicas para las series temporales (en este caso, para predecir el estado de preparación antes de competir). Aunque pueda tratarse de un análisis en una ventana de tiempo no muy larga en la cual se aplican los resultados (140 días), se utilizaron 2 años de datos

para la elaboración del modelo, y, junto con el uso de algoritmos avanzados de análisis de datos, los podemos considerar dentro del análisis de series temporales macro.

Figura 10: Valores reales y predichos para la preparación de un jugador



Fuente: Kulakou et al., 2022, p. 9.

En el siguiente y último caso, de Mujika et al. (2023), se utilizan datos de los resultados de distintas pruebas de natación en competición oficial de los últimos años para realizar predicciones sobre los tiempos que van a conseguirse en los Juegos Olímpicos de París 2024 para cada una de las posiciones. Esto pretende establecer cuáles son las referencias en dicha competición y servir como guía para entrenadores

y profesionales que trabajan con los nadadores para realizar ajustes en sus programas en función de los resultados actuales del nadador. Como vemos, este tipo de información puede ser crucial para una competición de dichas dimensiones, con las implicaciones mediáticas, económicas y deportivas que puede tener un resultado u otro.

Tabla 1: Ejemplo de uso de datos para realizar ajustes en programas de entrenamiento

Table 1 Updated Predictions From Both Approaches for the Paris 2024 Olympic Games

Event	Wu et al ¹⁷		Crowley et al ¹⁶		
	Gold medal	Bronze medal	1st-3rd	4th-8th	9th-16th
Men's events					
50-m freestyle	00:21.09	00:21.43	00:21.38	00:21.63	00:21.87
100-m freestyle	00:47.01	00:47.40	00:47.49	00:47.89	00:48.22
200-m freestyle	01:43.73	01:44.55	01:44.16	01:45.15	01:46.09
400-m freestyle	03:41.25	03:42.35	03:42.97	03:44.70	03:46.61
800-m freestyle	NA	NA	07:40.17	07:46.65	07:49.63
1500-m freestyle	14:34.07	14:35.46	14:36.71	14:51.94	15:00.30
100-m backstroke	00:51.83	00:52.08	00:51.91	00:52.72	00:53.35
200-m backstroke	01:53.32	01:54.72	01:54.64	01:57.34	01:57.99
100-m breaststroke	00:57.40	00:58.23	00:57.75	00:58.81	00:59.49
200-m breaststroke	02:06.17	02:06.83	02:06.64	02:07.12	02:09.28
100-m butterfly	00:49.63	00:50.71	00:50.15	00:50.99	00:51.57
200-m butterfly	01:50.36	01:53.42	01:52.48	01:55.13	01:56.26
200-m individual medley	01:55.03	01:55.85	01:55.79	01:56.77	01:58.54
400-m individual medley	04:06.44	04:08.95	04:08.40	04:11.66	04:14.53
Women's events					
50-m freestyle	00:23.85	00:24.08	00:24.00	00:24.68	00:25.00
100-m freestyle	00:52.01	00:52.32	00:52.28	00:52.74	00:54.14
200-m freestyle	01:53.83	01:54.57	01:53.79	01:56.88	01:57.49
400-m freestyle	03:57.71	04:00.70	03:57.40	04:04.82	04:07.17
800-m freestyle	08:09.86	08:15.40	08:14.58	08:22.62	08:33.21
1500-m freestyle	NA	NA	15:40.16	16:04.48	16:17.26
100-m backstroke	00:57.84	00:58.18	00:58.06	00:59.38	01:00.12
200-m backstroke	02:04.27	02:06.01	02:05.53	02:07.71	02:11.51
100-m breaststroke	01:04.90	01:05.55	01:05.48	01:06.36	01:06.62
200-m breaststroke	02:20.04	02:21.60	02:21.19	02:24.31	02:26.23
100-m butterfly	00:55.51	00:55.98	00:55.49	00:56.44	00:57.85
200-m butterfly	02:04.53	02:05.60	02:05.70	02:07.85	02:10.67
200-m individual medley	02:07.33	02:08.30	02:08.27	02:10.27	02:11.86
400-m individual medley	04:30.41	04:32.88	04:34.99	04:38.39	04:52.44

Abbreviation: NA, not available. In the original work by Wu et al¹⁷ the men's 800-m freestyle and the women's 1500-m freestyle were not Olympic events. Therefore, no predictions were made for either event.

Fuente: Mujika et al., 2023, p. 5.

CONTINUAR

Actividades

¿Qué aspectos son importantes en el análisis de series temporales macro?

- El uso de datos de corta duración
- La realización de análisis complejos
- La recolección de datos a largo plazo
- El uso exclusivo de herramientas actuales
- La eliminación de datos históricos

SUBMIT

CONTINUAR

Referencias

Altini, M. (2020). *The Ultimate Guide to Heart Rate Variability (HRV): Part 2*. Medium. https://medium.com/@altini_marco/the-ultimate-guide-to-heart-rate-variability-hrv-part-2-323a38213fbc

Clubb, J., Towlson, C., y Barrett, S. (2022). Measurement properties of external training load variables during standardised games in soccer: Implications for training and monitoring strategies. *Plos One*, 17(1), e0262274. <https://doi.org/10.1371/journal.pone.0262274>

Hopkins, W. G. (2004). How to interpret changes in an athletic performance test. *Sportscience*, 8, 1-7. <http://www.sportsci.org/jour/04/wghtests.htm>

Kulakou, S., Ragab, N., Midoglu, C., Boeker, M., Johansen, D., Riegler, M. A., y Halvorsen, P. (2022). Exploration of Different Time Series Models for Soccer Athlete Performance Prediction. *Engineering Proceedings*, 18(1), 37. <https://doi.org/10.3390/engproc2022018037>

Mujika, I., Pyne, D. B., Wu, P. P., Ng, K., Crowley, E., y Powell, C. (2023). Next-Generation Models for Predicting Winning Times in Elite

Swimming Events: Updated Predictions for the Paris 2024 Olympic Games. *International Journal of Sports Physiology and Performance*, 18(11), 1269-1274. <https://doi.org/10.1123/ijsp.2023-0174>

CONTINUAR