

Módulo 3. Introducción a los modelos estadísticos



Acá va la introducción a la lectura (justificar texto).

☰ Introducción

☰ 1. Particularidades del contexto del Sport Scientist

☰ Referencias

Introducción

Hemos destacado, en cursos anteriores, los tipos de análisis estadísticos que existen y que nos servirán para cumplir el propósito de interpretación de los datos que deseemos. Estos análisis cumplen distintas funciones, desde la descripción de los datos utilizando distintas medidas, hasta análisis de mayor complejidad, como pueden ser los análisis prescriptivos.

Repasemos, a continuación, cuál es el proceso a seguir en el análisis de datos y los pasos a seguir para beneficiarnos del uso de los datos recogidos y utilizarlos en la toma de decisiones.

- Observar: particularidades de cada uno de los contextos, conocimiento del deporte y área de experiencia del profesional.
- Construir pregunta o hipótesis: aquello que queremos resolver para tener un impacto positivo en el equipo en el que trabajamos o en la estructura deportiva/académica.

- Recolección de datos: puede también incluirse el tipo de diseño (experimental en el caso de que el contexto lo permita, habitualmente si hablamos del ámbito académico u observacional). Elección de herramientas, calidad del dato y su almacenamiento.
- Tratamiento de los datos: dar el formato adecuado para su posterior análisis, decidir cómo solventar los datos vacíos, agregar variables o cálculos.
- Análisis de los datos: elección de la herramienta adecuada para responder la hipótesis inicial.
- Comunicación/aplicación de los resultados: visualización, extracción de los resultados y toma de decisiones.

Este proceso se realizará de nuevo al finalizar el último paso, en caso de que la nueva observación no resulte satisfactoria.

Los pasos de observación e hipótesis no pertenecen a la temática de este curso, pero son la pieza clave de todo proceso, especialmente en el análisis de datos. Lo mismo ocurre con la recolección de datos, para lo que remarcamos de nuevo la idea de recoger datos con un propósito, ya que el éxito y eficiencia de un proyecto depende del plan que tengamos en cada uno de los pasos.

Podemos recurrir a módulos anteriores donde describimos el proceso de tratamiento de datos con detalle y también vimos la introducción a la visualización, donde se destacan los principios y bases a seguir para comunicar resultados mediante esta herramienta.

Queda, por lo tanto, un paso fundamental en el proceso a desarrollar, el análisis en sí de los datos. La elección de la herramienta que nos permita responder con mayor precisión la pregunta planteada. En un módulo anterior destacamos los tipos de análisis estadísticos y el tipo de funciones que cumplen cada uno de ellos, pero es necesario profundizar en ellos para conocer cuáles son las ventajas y también las limitaciones de cada uno. De esta manera, no solamente vamos a decidir qué tipo de análisis queremos realizar, sino qué herramienta es la más adecuada para ello.

Cuando hablamos de herramientas nos referimos a test estadísticos, algunos de los cuales veremos a continuación. El tipo de datos que tengamos, el diseño del estudio y la respuesta que queramos conocer marca el test más adecuado para el análisis.

Para ilustrarlo con un ejemplo, si queremos conocer si nuestro equipo ha mejorado en la altura de salto durante un periodo de la temporada, deberemos optar por un análisis diagnóstico y según el diseño de nuestro estudio, deberemos optar por una herramienta (o test estadístico) u otra. Sin embargo, si la pregunta que queremos responder es cómo afecta la carga de entrenamiento a los valores de

salto pos-sesión, hablaremos de un análisis predictivo, ya que queremos utilizar esta información para poder conocer cómo responden nuestros jugadores a los estímulos de entrenamiento o ver cómo se adaptan. Las herramientas, de nuevo, también variarán según el tipo de datos recogidos y el diseño que se haya planteado.

[CONTINUAR](#)

1. Particularidades del contexto del Sport Scientist

Cuando hablamos de diseños de estudio, podemos dividirlos en dos grandes grupos.

Estudios experimentales: aquellos estudios en los que podemos controlar las variables de estudio. Modificar y controlar estas variables, permitirá una mayor confianza en los resultados que obtenemos. Algunas de las características de un buen estudio experimental pueden ser la división del grupo en un grupo control y un grupo experimental o la división de grupos de manera aleatoria.

Estudios observacionales: en la mayoría de los contextos de un *Sport Scientist*, no se cumplen los requisitos para realizar diseños experimentales, ya que existen múltiples limitaciones. El calendario no permite periodos para aislar ciertas variables que puedan influir en el factor que queremos analizar, además tampoco es común dividir el grupo en dos intervenciones distintas y también partimos de la base de no poder modificar la población o grupo con el que trabajamos. Por lo tanto, habitualmente recogemos datos de las distintas variables a medida que van sucediendo.

Estos factores afectarán a lo que se llama validez interna y externa del estudio que realicemos. Simplificando ambos conceptos, la validez interna se refiere a la garantía de que las relaciones entre las variables de estudio sean causales. A menor validez interna, más precaución deberemos tener en la interpretación de resultados. La validez externa tiene repercusión en la influencia de los resultados en otros grupos que no sea el de nuestro estudio, por lo tanto, deberemos ser conscientes que lo que podamos aplicar con éxito a nuestro equipo, por ejemplo, puede no ser útil en otro grupo de distintas características.

En este módulo, nos centraremos en el segundo tipo de estudios, ya que son mucho más habituales en nuestro contexto. Teniendo en cuenta las descripciones anteriores, podemos afirmar que disponemos de datos observacionales en su mayoría.

¿Qué es un modelo estadístico?

Cuando queremos responder preguntas sobre el deporte en el que trabajamos, sobre el rendimiento físico de nuestros jugadores, sobre la influencia de ciertos factores en las lesiones, en esencia, lo que buscamos es poder explicar mejor aquello que observamos. Cómo se diferencian unos jugadores de otros, en qué se asemejan, qué relaciones existen entre parámetros físicos, etc. Todo esto, para poder predecir comportamientos similares, anticiparnos a esas predicciones y tomar acciones para conseguir los objetivos.

¿Qué posiciones en el equipo tienen demandas condicionales similares? ¿Deben entrenar juntos o separados?

¿Qué tareas tienen mayor influencia en la respuesta cardíaca del jugador?

Un modelo estadístico es aquella herramienta que nos permite conocer estas relaciones. Comúnmente los conceptos relacionados con la estadística (como los modelos estadísticos) parecen muy alejados de la aplicación práctica diaria en el contexto del *Sport Scientist* y parece que únicamente queda reservada para el ámbito académico. Debemos alejarnos de determinar cambios o relaciones al azar y utilizar modelos estadísticos, nos permitan utilizar los datos de los que disponemos con rigor y tomar decisiones con ellos con mayores garantías.

Un modelo es esencialmente una fórmula matemática que permite describir la relaciones entre una variable respuesta (también llamada objetivo/resultado/variable dependiente, *output*) y una o más variables que afectan a esa variable respuesta (también llamadas predictivas/variables independientes, *input*).

Un modelo no pretende explicar la complejidad de estas relaciones, ya que en un ámbito como el rendimiento deportivo es imposible (es muy probable que ni siquiera conozcamos algunas de las variables que afectan a las respuestas que queremos conocer), sino que pretende

simplificar las relaciones. Describe los parámetros esenciales de las relaciones para que se puedan realizar estimaciones en un futuro (Grolemund; Wickham, 2017).

RStudio, como describimos en el primer módulo, se trata de un *software* esencialmente estadístico, por lo que estará optimizado para cumplir las necesidades relacionadas con los modelos estadísticos y dispone de múltiples funciones para conseguir tratar los datos de esta manera.

Los modelos estadísticos solo se utilizan en el ámbito académico y no tienen aplicación práctica en el contexto del Sport Scientist.

- Verdadero
- Falso

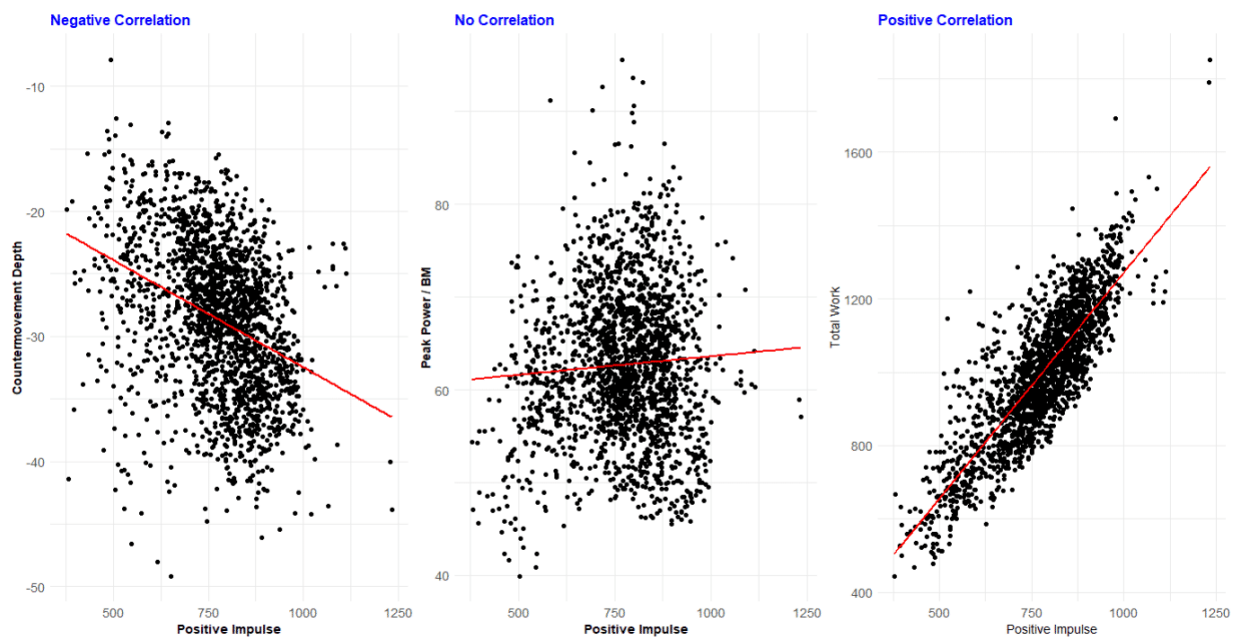
SUBMIT

El modelo lineal

Si creemos que dos variables están correlacionadas, significa que hay una relación entre ellas. Por lo tanto, podemos utilizar las variables independientes para predecir la variable objetiva.

En el siguiente gráfico (adaptado de Clark, 2020), podemos ver distintos tipos de correlaciones. Se muestra en qué casos las variables se mueven juntas en ambos ejes (incrementos en el eje «x» acompañados por incrementos en el eje «y» en el caso de la correlación positiva).

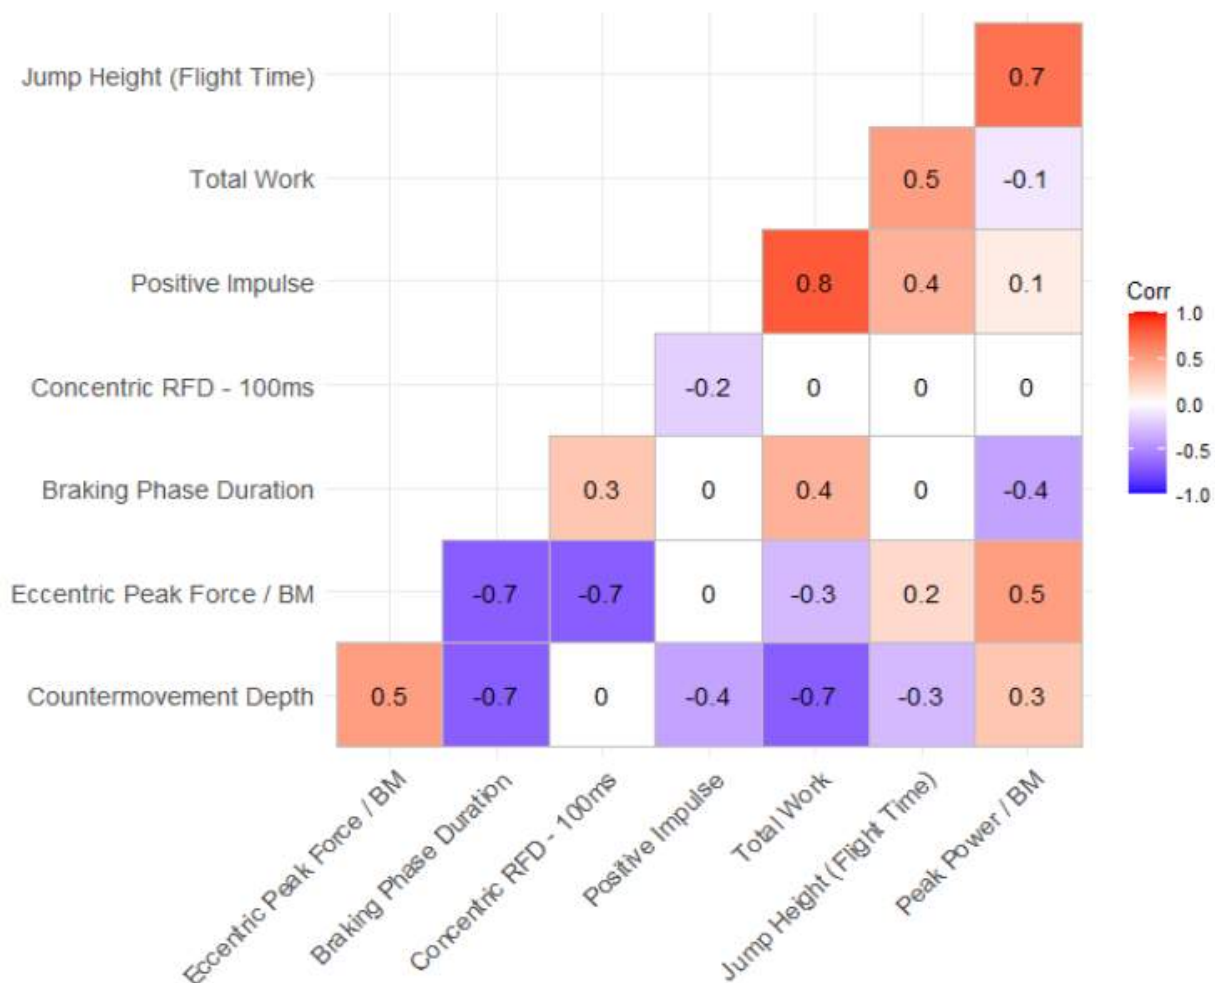
Figura 1: Correlaciones



Fuente: elaboración propia con base en Clark, 2020.

Las correlaciones se expresan mediante un valor numérico llamado coeficiente de correlación. Este número, de valor entre -1 y 1 expresa la magnitud de la relación, a valores más cercanos a 1. En el gráfico siguiente, vemos correlaciones entre distintos pares de variables GPS, con el valor numérico y la relación positiva o negativa correspondiente indicada también por el color.

Figura 2: Correlaciones entre distintos pares de variables GPS



Estas simples correlaciones sugieren una relación lineal, es decir, representada por una línea recta. Esta correlación indica únicamente el sentido en el que se mueven los valores y la magnitud de la correlación, es decir, en qué medida un cambio en el valor del eje x se relaciona con un valor en el eje y. Sin embargo, este valor por sí solo no es de mucha utilidad si queremos utilizar esta relación para establecer predicciones en nuevos valores que obtenemos. Para ello, deberemos utilizar un modelo lineal.

El modelo lineal se trata de uno de los modelos más simples que se usan para establecer relaciones entre variables. El objetivo de este modelo es encontrar la relación que destaque el impacto de las variables independientes o predictivas en la variable respuesta y aportar una fórmula a la cual podamos añadirle otras variables independientes y calcule la variable respuesta estimada.

La fórmula matemática que lo representa sería la siguiente:

$$y=b_0+b_1 x_1+b_2 x_2$$

en la cual:

- y es la variable respuesta;
- x_1, x_2, \dots son las variables independientes;
- b_0 es el valor base;
- b_1, b_2, \dots son los coeficientes o el peso de cada una de las variables independientes.


Creación del modelo

Vamos a ejemplificar los aspectos mencionados anteriormente. Para el control de la carga deportiva es de gran importancia el control, tanto de la carga externa como de la carga interna de nuestros jugadores (Gabbett et al., 2017). A modo de simplificación, la carga externa nos muestra qué o cuánto está realizando nuestro jugador (distancia, lanzamientos, repeticiones, etc.) según el deporte que analicemos y la carga interna muestra cuál es el estrés de esa carga externa (frecuencia cardíaca, marcadores de daño muscular, etc.).

A continuación, se muestra un gráfico donde vemos distintos sujetos (puntos) y sus dos valores de carga, interna en el eje «y» y externa en el eje «x». En este caso, hablamos de distancia en metros como medida de carga externa y TRIMPS (Edward's Training Impulse) como medida de carga interna. Las TRIP han sido calculadas mediante la

multiplicación, en minutos, de la duración en cada una de las zonas de frecuencia cardíaca por un factor de intensidad (Tometz et al., 2022).

Figura 3: Distintos puntos y valores de carga interna y externa



Fuente: elaboración propia

Los dos cuadros que se muestran en rojo y verde representan el concepto generalizado de adaptación o fatiga durante el entrenamiento, podríamos considerar que los jugadores que tienen una alta carga externa y una baja carga interna (cuadrado verde) están adaptados al entrenamiento, por otro lado, jugadores que tienen una carga externa baja, pero alta carga interna (cuadrado rojo), podría indicar que no están adaptados o que existe cierta fatiga,

ya que no hay eficiencia en la respuesta cardíaca con un mismo estímulo externo. Aunque estas suposiciones puedan ser válidas y tengan sentido, debemos percatarnos de la tendencia de ambas variables y conocer esa relación entre ellas. De ser así, podremos ser más precisos en nuestra constatación de cambios y estado de los jugadores.

Además, si queremos saber cuál es la carga necesaria a aplicar a nuestros jugadores para inducir cierta respuesta cardíaca, utilizar un modelo estadístico puede ayudarnos a responder esa pregunta.

Siguiendo el modelo lineal descrito antes, vamos a establecer esa relación. Queremos conocer el valor de carga interna sabiendo el valor de carga externa.

Esta es la fórmula anterior:

$$y = b_0 + b_1 x_1 + b_2 x_2$$

Traducida a nuestro ejemplo sería lo siguiente:

$$\text{Carga Interna} = b_0 + b_1 \text{Carga Externa}$$

En RStudio, lo establecemos de la siguiente manera:

```
model <- lm(Interna~Externa,data=data)
```

- *model*: es el objeto que recoge toda la información del modelo estadístico;
- `lm()`: es la función que aplica el modelo lineal;
- `Interna` y `Externa` son los nombres de las columnas de nuestra fuente de datos y `data` es el nombre de la tabla;
- la variable a la izquierda del símbolo «~» será la variable independiente (lo que queremos predecir), mientras que la variable a la derecha es la variable dependiente (la información de la que disponemos).

Sí, parece muy simple el modelo en RStudio, pero es todo lo que necesitamos. A partir de este momento, lo que deberemos tener en cuenta son los resultados de este modelo, lo que nos va a marcar si es útil y podemos confiar en él para realizar predicciones.

Utilizando la función `summary()` vemos los resultados que nos da RStudio en la siguiente figura.

Figura 4: Resultados de RStudio

Call:

```
lm(formula = Interna ~ Externa, data = data)
```

Residuals:

Min	1Q	Median	3Q	Max
-113.304	-33.756	-5.135	34.714	95.827

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	19.191898	14.237017	1.348	0.184
Externa	0.059363	0.002916	20.355	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 47.1 on 49 degrees of freedom

Multiple R-squared: 0.8942, Adjusted R-squared: 0.8921

F-statistic: 414.3 on 1 and 49 DF, p-value: < 2.2e-16

Fuente: elaboración propia.

De toda la información de la que disponemos, vamos a fijarnos, por ahora, en el apartado «*Coefficients*». Estos van a completar la parte de la fórmula que nos falta. Vemos en la columna «*Estimate*» como hay valores para la «*(Intercept)*», se trata del valor b_0 de nuestra fórmula, y para «*Externa*». De esta manera, la fórmula sería la siguiente.

Carga Interna = 19.19 + 0.059xCarga Externa

De esta manera, ya podemos realizar predicciones. El coeficiente en este modelo lineal indica que por cada incremento de 1 unidad de carga externa, habrá un incremento añadido de 0.059 en la carga interna. Por lo tanto, si queremos estimar la carga interna de una

sesión en la que el jugador ha recorrido 5 km (5000 m), la fórmula será la siguiente.


$$\text{Carga Interna} = 19.19 + 0.059 \times 5000$$

$$\text{Carga Interna} = 314.19$$

En el material de video veremos cómo aplicar predicciones a nuevos datos o mayor volumen, pero esta es la base del razonamiento detrás de todos los modelos lineales.

De modo visual, cuando tenemos una variable dependiente se puede representar con una línea, como en el siguiente gráfico.

Figura 5: Representación de variable dependiente



Fuente: elaboración propia

Esta línea representa los valores estimados de carga interna por cada valor de carga externa. Como vemos, la línea pretende representar de la mejor manera posible cómo se presentan los datos. Los modelos no son perfectos, es por este motivo que la línea roja no sigue todos los puntos, sino que intenta que las diferencias entre el valor real y el valor estimado sean lo menores posibles. A este concepto le llamamos error.

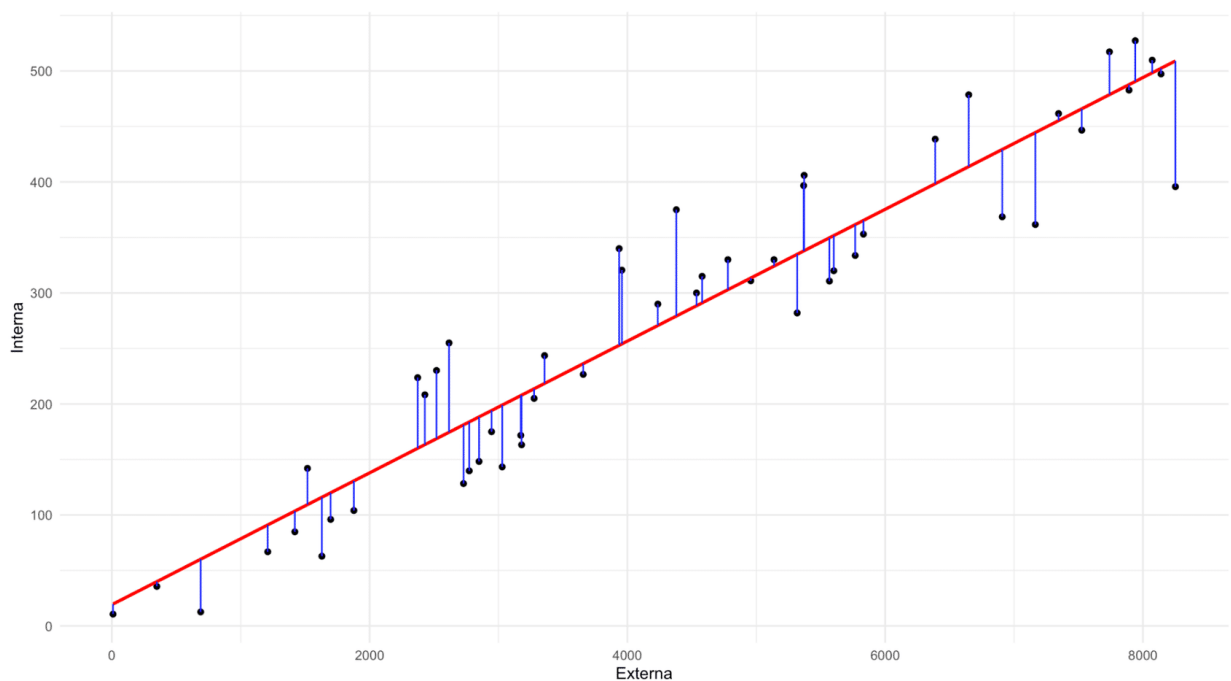
Evaluación del modelo

Acabamos de mencionar que todos los modelos tienen cierto error, ya que siempre buscamos conocer relaciones de elementos complejos en

nuestro contexto. Debemos tener en mente, al elaborar modelos, intentar que ese error sea el mínimo posible.

El error está representado por los «*residuals*», los cuales son las diferencias entre los valores actuales y los estimados por el modelo. Vemos las diferencias en el siguiente gráfico.

Figura 6: Diferencias entre los valores actuales y los estimados por el modelo



Fuente: elaboración propia

En los resultados que hemos visto antes, el error está representado por el valor «Residual standard error», el cual muestra cuál es la distancia

habitual entre los puntos, en este caso de 47.1, que, teniendo en cuenta las unidades de carga interna, es un valor muy bajo.

Los *residuals* representan las diferencias entre los valores actuales y los estimados por el modelo.

- Verdadero
- Falso

SUBMIT

Otro elemento para evaluar nuestro modelo es el valor R-Squared. Este valor, siempre entre 0 y 1 indicará qué proporción de la variable que queremos predecir está explicada por la variable independiente, en este caso, el valor es cercano a 1, lo que indica buenos resultados.

Con este modelo, se abren nuevas posibilidades para el análisis inicial que habíamos planteado. Conocemos la fórmula para estimar nuevos valores, conocemos el error de nuestro modelo y, si hemos hecho una

correcta exploración de nuestros datos, también conoceremos la variabilidad de nuestras medidas. Con estos aspectos en cuenta, estaremos en una mejor posición para evaluar las respuestas de nuestros jugadores. Valores más alejados de la estimación indicarán respuestas distintas al entrenamiento y podemos dejar de lado el análisis por cuadrados que hemos mostrado al inicio de esta sección.

¿Cuáles de las siguientes afirmaciones sobre el valor de *R-Squared* son correctas?

- El valor *R-Squared* indica la cantidad de error en el modelo.
- El valor *R-Squared* representa las diferencias entre los valores actuales y los estimados por el modelo.
- El valor *R-Squared* siempre está entre 0 y 1.
- Un valor *R-Squared* cercano a 0 indica que la variable independiente explica bien la variable que queremos predecir.

Un valor *R-Squared* cercano a 1 indica buenos resultados.

SUBMIT

Complejidad de los modelos

El modelo lineal y la regresión que hemos mostrado en el ejemplo se trata del modelo más simple, deberemos conocer los datos con los que tratamos, realizar la exploración correspondiente y elaborar la pregunta que queremos responder para después escoger la clase de modelo que queremos utilizar y luego, el que mejor se ajusta a esos datos para obtener los resultados deseados.

Anteriormente, hemos mostrado un modelo con una sola variable dependiente, donde los resultados fueron bastante buenos. Es habitual que en los modelos lineales queramos utilizar más de una variable para estimar la variable respuesta, siguiendo la misma fórmula presentada anteriormente, añadiremos más variables con sus coeficientes correspondientes a cada una de ellas. De la misma manera que hemos interpretado el modelo anterior para realizar estimaciones, lo haríamos con los siguientes.

Podríamos tener un modelo en el que quisiéramos estimar la velocidad de un golpe de tenis, por ejemplo. Las variables que podríamos utilizar para este ejemplo son la edad del jugador, la altura y un valor llamado «potencia», que podría representar valores obtenidos en un *test* de fuerza para este jugador.

Figura 7: Ejemplo

Coefficients:	
	Estimate :
(Intercept)	88.1567
edad	-0.8582
altura	1.3402
potencia	0.9881

Fuente: elaboración propia

La fórmula en este caso sería la siguiente.

$$y = 88.15 - 0.85x_{\text{edad}} + 1.34x_{\text{altura}} + 0.98x_{\text{potencia}}$$


Se trata de un ejemplo y con valores y variables no reales, pero se ha usado para observar el coeficiente negativo en el modelo. Este, representa cómo la edad tiene un impacto negativo en los valores que

vamos a estimar. Es decir, el modelo nos indicaría que un jugador de mayor edad, con la misma altura y valores de potencia que un jugador más joven, tendrá una velocidad de saque menor.

Podemos hablar también de modelos lineales en los cuales la línea que relaciona ambas variables no es recta.

Un ejemplo serían los períodos de máxima intensidad. Estos períodos, ya utilizados en algún otro ejemplo del curso, muestran aquellas fases en las que un jugador expresa valores de intensidad (en este caso reflejados mediante la variable potencia metabólica) superiores a los valores promedio de partido. También, podemos simplificarlos y referirnos a velocidades. En el eje horizontal está representada la duración. Como vemos, a menor duración del esfuerzo de los jugadores, en este caso, de un equipo de fútbol profesional, son capaces de alcanzar mayores intensidades, a medida que la duración aumenta esas intensidades son menores. El mismo concepto se aplica a la velocidad, no somos capaces de mantener la misma velocidad en un esfuerzo de 6 segundos que en un esfuerzo de 2 minutos.

Figura 8: Ejemplo de períodos de máxima intensidad



Fuente: elaboración propia

Como describe Delaney et al. (2018), esta relación es captada por un modelo lineal, en el cual deberemos realizar algunas transformaciones a las variables para obtener la fórmula del modelo y realizar predicciones mediante la fórmula correspondiente.

También existe la posibilidad que la variable que queramos describir no sea numérica. Por ejemplo, queremos construir un modelo para predecir si un servicio de tenis será servicio directo o no. En este caso, la predicción será binaria (hay dos posibilidades, sí o no). Para ello, queremos utilizar varias variables independientes (velocidad, localización, efecto, etc.). En este caso, vemos cómo las variables independientes también tienen particularidades, no todas se tratan de variables numéricas, sino que hay variables categóricas también, el

efecto tiene categorías limitadas, por ejemplo (liftado, plano, cortado). En muchos casos, las distribuciones de las variables no son normales, tampoco las de la variable respuesta. Para todos estos casos es necesario utilizar los modelos lineales generalizados. Estos modelos permiten trabajar con la variedad de los datos que hemos descrito. Aunque la función en RStudio que utilicemos sea diferente (`glm()`), la construcción del modelo será prácticamente la misma. Veamos un ejemplo de nuevo, a continuación.

Vamos a intentar predecir si un servicio ha sido directo o no (*ace*) utilizando las variables:

- velocidad del servicio (*speed*)
- efecto (*effect*). El efecto tiene 3 categorías:
 - *flat* (saque plano);
 - *slice* (saque cortado);
 - *spin* (saque liftado).

Elaboramos el modelo con la fórmula que se muestra a continuación, además de la función que especifica que es un modelo lineal generalizado (`glm`), añadimos que se trata de una variable respuesta

binaria (family="binomial"). Los resultados que obtenemos son los siguientes.

Figura 9: Resultados

```
Call:
glm(formula = ace ~ speed + effect, family = "binomial", data = training_data)

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-2.0140  -0.8891  -0.3794   0.9222   2.3932

Coefficients:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)  -8.51644    2.20016  -3.871 0.000108 ***
speed         0.05007    0.01221   4.101 4.12e-05 ***
effectslice  -0.67241    0.43487  -1.546 0.122045
effectspin   -1.93588    0.53402  -3.625 0.000289 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 193.82  on 139  degrees of freedom
Residual deviance: 158.40  on 136  degrees of freedom
AIC: 166.4
```

Fuente: elaboración propia.

En este caso, vemos cómo el modelo asigna coeficientes o pesos a cada una de las categorías, por defecto, el modelo omite una de las categorías, la cual sirve como referencia, pero el razonamiento es el mismo. También, deberemos considerar que se trata de un modelo binario, por lo que los resultados los obtendremos en formato de probabilidad que se cumpla una condición u otra y deberemos escoger

cuál es el umbral para determinar si ha sido servicio directo o no. Estos modelos habitualmente se evalúan usando la precisión del modelo, es decir, el éxito que han tenido determinando si casos positivos y negativos.

Existen funciones en RStudio que permiten hacer predicciones, utilizar las fórmulas de los modelos y evaluar su rendimiento de forma eficiente sin entrar en detalle, pero es importante tener un concepto claro de lo que pretende cada uno de ellos.

Conocer las particularidades de los modelos lineales es la base para la construcción de modelos más complejos.

CONTINUAR

Referencias

Clark, M. (2020). *Model estimation by example*. Demonstrations with R. <https://m-clark.github.io/models-by-example/>

Delaney, J. A.; Thornton, H. R.; Rowell, A. E.; Dascombe, B. J.; Aughey, R. J.; Duthie, G. M. (2018). Modelling the decrement in running intensity within professional soccer players. *Science and Medicine in Football*, 2(2), 86–92. <https://doi.org/10.1080/24733938.2017.1383623>

Gabbett, T. J.; Nassis, G. P.; Oetter, E.; Pretorius, J.; Johnston, N.; Medina, D.; Rodas, G.; Myslinski, T.; Howells, D.; Beard, A.; Ryan, A. (2017). *The athlete monitoring cycle: a practical guide to interpreting and applying training monitoring data*. *British Journal of Sports Medicine*, 51(20), 1451-1452. <https://doi.org/10.1136/bjsports-2016-097298>

Grolemund, G.; Wickham, H. (2017). *R for Data Science*. O'Reilly Media

Tometz, M. J.; Jevas, S. A.; Esposito, P. M.; Annaccone, A. R. (2022). Validation of Internal and External Load Metrics in NCAA D1 Women's Beach Volleyball. *Journal of Strength and Conditioning Research*, 36(8), 2223-2229. <https://doi.org/10.1519/JSC.00000000000003963>

CONTINUAR