

ANÁLISIS DE SERIES TEMPORALES APLICADO AL ESTUDIO DE LA EMOCIÓN Y DE LA CONDUCTA EN UN ATLETA

L. CAPDEVILA ORTÍS; J. CRUZ FELIU
Universidad Autónoma de Barcelona

Resumen

En este trabajo se desarrolla un instrumento estadístico basado en el análisis de series temporales que permite el estudio longitudinal y continuo de variables emocionales y conductuales. Se usa la metodología ARIMA con dos finalidades: a) analizar los efectos de una intervención psicológica, y b) comparar diferentes curvas de datos obtenidas bajo el mismo diseño experimental. Para este segundo objetivo, la Técnica de Superposición de Curvas desarrollada permite obtener información mucho más precisa que la estadística convencional. A efectos ilustrativos, se desarrolla la técnica en un ejemplo que corresponde a una investigación de laboratorio, dentro del ámbito de la Psicología del Deporte. Se comparan las curvas de frecuencia cardíaca obtenidas en dos pruebas de esfuerzo idénticas sobre una cinta ergonómica, correspondientes a un atleta medio-fondista de alto nivel sometido a un entrenamiento psicológico para controlar su eficiencia cardiorrespiratoria.

Abstract

In this paper we develop a statistical instrument based on Time Series Analysis, that allows the longitudinal and continuous study of emotional and behavioral variables. We use the ARIMA methodology with two purposes: a) to analyze the effects of a psychological intervention, and b) to compare different data curves obtained under the same experimental design. For the second purpose, we developed the Curve Superposition Technique, which provides a much more precise information than conventional statistics. As an illustrative application, we develop the afore mentioned technique with one example from a laboratory research in the field of Sport Psychology: in this experiment we compare heart rate's curves of a peak performance middle distance runner, which were monitored on two identical treadmill run. This athlete received a psychological training in order to control his cardiorespiratory efficiency.

Introducción

En Psicología del Deporte se acostumbra a evaluar el afrontamiento de la competición deportiva por medio del análisis de los indicadores cognitivo, motor y fisiológico-bioquímico de la conducta de los atletas (Crocker, Alderman y Smith, 1988; Hackfort y Schwenkmeier, 1989). Sin embargo, la evaluación continua de dichos indicadores es un problema muy difícil de solucionar, igual como sucede en otras áreas de la Psicología. Se trataría de tener medidas a intervalos pequeños de tiempo de variables emocionales y conductuales durante toda la competición. La dificultad reside en recoger medidas no invasivas que en ningún momento alteren la concentración del deportista. Así, por ejemplo, no podemos perseguir a un atleta cada medio minuto

para que responda a cuestionarios de ansiedad o escalas de atención. Con la tecnología actual pensamos que resulta más factible recoger medidas continuas o casi-continuas de los indicadores motor y fisiológico-bioquímico de la conducta competitiva, que del indicador cognitivo. Tal como señalan Grzib, García, Briales y Fernández Trespalcacios (1989), «lo que se busca en una cuantificación de la conducta de forma que ésta constituya una variable casi-continua en el tiempo, formalmente equivalente a las variables fisiológicas, como, por ejemplo, la tasa cardíaca» (Grzib y cols., 1989, pág. 14).

De este modo se pueden registrar variables como el consumo de oxígeno (VO) y la frecuencia cardíaca (FC), parámetros que se relacionan directamente con el esfuerzo físico y son un índice fiable de la eficiencia cardiorrespiratoria (Fox, 1984). Además,

estas variables tienen un aspecto psicofisiológico, al relacionarse con estados emocionales, como la relajación o la activación subjetiva, en situaciones donde el esfuerzo físico está bajo control (Benson, 1975; Suinn, 1980; Ziegler, Klinzing y Williamson, 1982). La medida continua a lo largo del tiempo de la FC puede aportar información valiosa sobre algunos aspectos del afrontamiento competitivo de los deportistas (Capdevila, 1989b). En situación de competición o entrenamiento deportivos, por medio de la telemetría, la tecnología actual permite recoger medidas de esta variable a intervalos constantes de tiempo, sin interferir en la conducta del atleta. De esta manera, el psicólogo del deporte puede evaluar la eficacia de una posible intervención —por ejemplo, un entrenamiento psicológico para mejorar una habilidad específica— sobre el componente psicofisiológico —FC como índice de relajación, activación o rendimiento fisiológico— en algún momento de la competición.

Una vez recogidas las medidas repetidas de variables como la FC, a intervalos constantes de tiempo, la siguiente dificultad reside en disponer de algún instrumento estadístico que proporcione un criterio objetivo para evaluar la eficacia de una posible intervención. Más concretamente, nos puede interesar: a) conocer si la intervención ha producido un cambio significativo en la evolución a lo largo del tiempo de la variable estudiada, y b) comparar dos o más curvas de datos obtenidas en iguales condiciones, correspondientes a diferentes sesiones o a diversos deportistas. En este trabajo se desarrolla un tratamiento estadístico adecuado para el estudio de la FC de atletas sometidos a una prueba de esfuerzo sobre la cinta ergométrica (Capdevila, 1989a). Este tratamiento estadístico es el Análisis de Series Temporales según modelos ARIMA.

Análisis de series temporales

Este nombre no hace referencia a ninguna técnica en concreto —aunque muy a menudo se hace sinónimo de la técnica de análisis desarrollada por Box y Jenkins (1970)—, sino que indica un tipo general de tratamiento que parte de la ordenación de los datos en el tiempo. En general, las técnicas de análisis de series temporales aplicadas a la investigación conductual pretenden evaluar cambios de nivel o de tendencia en los datos, como efecto de una intervención en un momento temporal dado (Kazdin, 1984; Gottman y Glass, 1978).

La inspección visual de los datos puede proporcionar criterios específicos sobre la relación causal entre la intervención efectuada y los cambios de conducta observados. Pero este método no proporciona información válida para determinar si una intervención ha tenido un efecto relevante o no sobre la conducta (Kazdin, 1982). En este sentido, existen varios métodos de análisis de series temporales que permiten extraer conclusiones. Normalmente, estos métodos parten del ajuste de un modelo matemáti-

co a los datos, posibilitando la extracción de ecuaciones y parámetros a nivel explicativo y predictivo.

La estadística de series temporales se puede basar principalmente en dos aspectos diferentes de los datos, que originarán dos análisis también diferenciados: a) la frecuencia, y b) la secuenciación temporal. Dentro del primer tipo, las técnicas más utilizadas han sido el análisis espectral y el análisis de covariación entre espectros. Podemos encontrar un ejemplo de esta metodología en Grzib y colaboradores (1989), quienes relacionan variables fisiológicas como la tasa cardíaca y la frecuencia respiratoria, basándose en un estudio previo de Porges y colaboradores (1980). El primer paso en este tipo de análisis es el cálculo de la función de densidad espectral, que permite conocer la varianza asociada a cada frecuencia. En cambio, dentro del segundo tipo de análisis —basado en la secuenciación temporal de los datos—, el modelo a ajustar estará en función de un factor crítico: la dependencia serial de las observaciones (Bowerman y O'Connell, 1979; Hartmann y colaboradores, 1980). Esta última metodología es la que desarrollaremos en el presente trabajo.

De acuerdo con Kazdin (1984), en el caso de medidas continuas o repetidas a lo largo del tiempo, a menudo no se cumple con la suposición de independencia de las observaciones. Es decir, las observaciones sucesivas en una serie temporal tienden a mostrar autocorrelación. Muchas veces puede interesar conocer los parámetros estadísticos de esta dependencia serial entre los datos. De todas formas, hay que tener presente que ésta no es una característica necesaria de los datos recogidos como medidas repetidas a intervalos constantes de tiempo, pero sí que es un hecho muy probable que puede determinar la inadecuación de pruebas estadísticas convencionales.

Cuando no hay autocorrelación entre los datos podemos ajustar un modelo estadístico utilizando técnicas cuantitativas, como el ajuste de curvas, la regresión múltiple o el suavizado exponencial (Bowerman y O'Connell, 1979). En ellas el tiempo se utiliza como regresor y el modelo obtenido permite hacer predicciones de valores futuros de la serie en un momento de tiempo dado. No obstante, la principal condición de aplicación de todas estas técnicas es la independencia serial de las observaciones. Pero cuando la autocorrelación está presente entre los datos, una metodología más adecuada es el ajuste de modelos ARIMA —autorregresivos, integrados y de medias móviles— (Bowerman y O'Connell, 1979; Box y Jenkins, 1970; Gottman y Glass, 1978). El resultado final también es un modelo que permite hacer estimaciones en momentos puntuales y predicciones de valores futuros, pero ya no en función del tiempo, sino de los valores anteriores de la serie.

En el ámbito psicológico se ha observado que las medidas repetidas a nivel conductual en humanos es mucho más fácil que presenten dependencia serial (Bryan, 1987; Kazdin, 1984; Zaichkowsky, 1980), a pesar de que en algún estudio se opine lo

contrario (Huitema, 1985). En el caso concreto de la FC, creemos que es bastante coherente el suponer la dependencia serial entre puntos de datos sucesivos en el tiempo, correspondientes a un mismo sujeto o a un conjunto de sujetos. Esta variable ha mostrado una fuerte autocorrelación cuando se evalúa bajo condiciones donde el esfuerzo físico es el factor que la determina (Capdevila y Cruz, 1988a, 1988b).

Hay que decir, sin embargo, que los análisis según modelos ARIMA requieren principalmente de dos condiciones de aplicación difíciles de cumplir en la mayoría de investigaciones conductuales: 1) un número elevado de observaciones, recomendándose un mínimo de 50 (Bowerman y O'Connell, 1979; Glass, Willson y Gottman, 1974), 60 (Uriel, 1985) o incluso 100 puntos de datos (Box y Jenkins, 1970), y 2) un intervalo de tiempo siempre constante entre las observaciones. Un problema asociado con la aplicación de los análisis de series temporales es la complejidad de las pruebas estadísticas y los numerosos pasos que incluyen.

Partiendo del trabajo de Box y Jenkins (1970), hay un acuerdo general en cuanto a las etapas principales que se han de secuenciar al ajustar un modelo ARIMA a una serie temporal de observaciones (Bowerman y O'Connell, 1979; Uriel, 1985): 1) *Identificación del modelo*; 2) *Estimación de parámetros*; 3) *Validación del modelo*, y 4) *Predicción de valores futuros*. Pasemos a continuación a describir brevemente estas etapas:

1. *Identificación del modelo*. En esta etapa se identifica el tipo de modelo ARIMA que se tendrá que ajustar a los datos. Éste podrá tener componentes autorregresivos, de integración, de medias móviles, o la combinación entre ellos. La identificación se realiza a partir de los gráficos de autocorrelación y de autocorrelación parcial de la serie original. El estudio de estos gráficos también determina la posible diferenciación de la serie. Esta etapa es muy importante porque determinará la bondad del ajuste posterior, jugando un papel crítico la decisión del investigador.

2. *Estimación de parámetros*. Una vez identificado el modelo ARIMA, el siguiente paso es estimar los parámetros correspondientes y calcular su significación. Los métodos de estimación que se utilizan habitualmente son el de mínimos cuadrados o el de máxima semejanza (Uriel, 1985). Con ellos podremos obtener una ecuación representativa del comportamiento de la serie temporal, y podremos disponer de las estimaciones que realiza el modelo para cada observación, así como de los valores residuales correspondientes.

3. *Validación del modelo*. Antes de poder utilizar el modelo ajustado para la predicción de valores futuros o para alguna otra finalidad, es necesario analizar si el ajuste se realiza de forma óptima. Si no se llegara a esta conclusión, tendría que volverse a la fase de identificación para intentar optimizar el ajuste. La etapa de validación se realiza básicamente a partir del análisis de los valores residuales.

4. *Predicción de valores futuros*. El modelo validado, si realmente explica el comportamiento de la serie de forma satisfactoria, podrá ser utilizado para la predicción de valores futuros. Teniendo en cuenta que los modelos ARIMA intentan explicar el comportamiento de una serie temporal en función siempre de valores precedentes en la misma serie, resultan muy adecuados para realizar predicciones.

Una consideración importante al utilizar modelos ARIMA para ajustar datos conductuales es que la técnica fue originalmente concebida para fines predictivos en el ámbito de la Economía. Por eso la última etapa nombrada, de predicción de valores futuros, es el resultado final de la técnica, una vez tenemos un modelo óptimamente ajustado a partir de las tres etapas anteriores. En el ámbito de las ciencias conductuales, en cambio, el interés puede recaer más en comparar diferentes conjuntos de observaciones repetidas y no tanto en la predicción de valores futuros de un conjunto de observaciones. Por tanto, la estrategia básica será la misma, siguiendo las tres primeras etapas para alcanzar un buen ajuste, y utilizando el modelo para nuestras necesidades. El principal problema radica en que no existe en la bibliografía revisada ninguna técnica o procedimiento que permita utilizar un modelo ARIMA bien ajustado para comparar diferentes curvas de datos. Por este motivo, en este trabajo se desarrolla un instrumento estadístico para tales finalidades. Por tanto, cuando analizamos datos conductuales y fisiológicos, podríamos sustituir la última etapa de «Predicción de valores futuros» por la de «Comparación de series temporales» (o «Comparación de curvas»).

Ejemplo ilustrativo

El ejemplo ilustrativo que se utilizará corresponde a una investigación realizada dentro del ámbito de la Psicología del Deporte (Capdevila, 1989b). Una de las finalidades de aquella investigación era probar la eficacia de dos programas de entrenamiento psicológico sobre el control de la FC, registrada a intervalos constantes de tiempo, durante una prueba ergométrica de esfuerzo en el laboratorio.

Método

Sujetos

Los datos de este ejemplo corresponden a un solo sujeto: un atleta masculino medio-fondista (800 y 1.500 metros lisos), de 18 años de edad, que participaba en competiciones de atletismo de alto nivel.

Aparatos

Los aparatos básicos utilizados han sido una cinta ergométrica para realizar pruebas de esfuerzo en el

laboratorio y un polígrafo para el registro continuo en el tiempo (cada 30 segundos) de la FC.

Procedimiento

El sujeto realizó dos pruebas de esfuerzo en la cinta ergométrica de idénticas características (Pretest y Postest), donde se registraba la FC cada 30 segundos, en las siguientes etapas:

- A) Tres minutos de reposo.
- B) Tres minutos de calentamiento (a 8 km/h).
- C) Veinte minutos de carrera constante, manteniendo la velocidad al 65 por 100 del consumo máximo de oxígeno (calculado en una prueba previa de esfuerzo máximo).
- D) Tres minutos de recuperación.

Entre las dos pruebas, separadas por 5 semanas, el atleta recibió un entrenamiento psicológico —basado principalmente en técnicas de condicionamiento clásico (Siegel, 1986)— con el objetivo de reducir los valores de FC en el Postest, especialmente en las etapas de reposo y de carrera constante.

Resultados

En la figura 1 se pueden observar las curvas de FC de las dos pruebas.

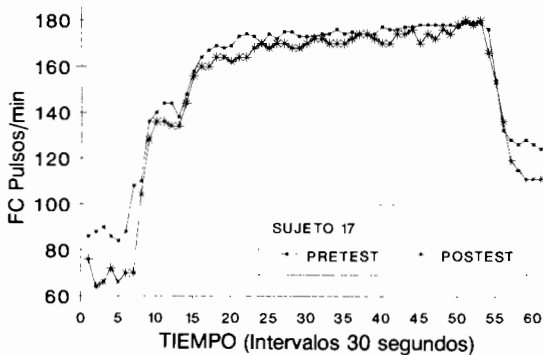


Figura 1. Frecuencia cardíaca (FC), a intervalos de 30 seg., presentada por el sujeto 17, en el Pretest y en el Postest.

Como estrategia en el análisis de series temporales, ajustaremos un modelo ARIMA a la curva de FC del Pretest. Una vez validado este modelo, graficaremos el intervalo de confianza del 95 por 100 estimado para el Pretest junto con la FC real mostrada por el sujeto en el Postest. A continuación se describen los pasos del análisis:

I. Ajuste de un modelo ARIMA a la FC del Pretest

Seguiremos las etapas tradicionales en los modelos ARIMA:

a) *Identificación del modelo.* En primer lugar analizaremos la autocorrelación de los datos. La figura 2 muestra el correlograma correspondiente a la curva de FC del Pretest. Los valores significativos elevados observados en los primeros retardos y la declinación exponencial en retardos sucesivos indican que la serie no es estacionaria (no muestra media ni varianzas constantes) y que es necesaria su diferenciación. Esto quiere decir que el análisis se efectuará sobre la serie diferenciada y que después se realizará la estimación integrando de nuevo la serie. Las figuras 3 y 4 muestran, respectivamente, los gráficos de autocorrelación y de autocorrelación parcial de la serie diferenciada. El estudio detallado de estos gráficos es el que nos ayuda a identificar el modelo que hemos de ajustar a los datos. Éste es posiblemente el punto más conflictivo de todo el análisis, ya que el criterio de decisión del examinador puede inducir a algún error importante en el ajuste. En este momento se decide el tipo de modelo ARIMA que se ha de ajustar; más concretamente, se decide el patrón autorregresivo, de integración y de medias móviles que sigue el modelo, o la combinación entre los tres patrones. Analizando la estructura que presentan los coeficientes significativos en




Figura 2. Autocorrelación de la FC correspondiente al Pretest del sujeto 17.

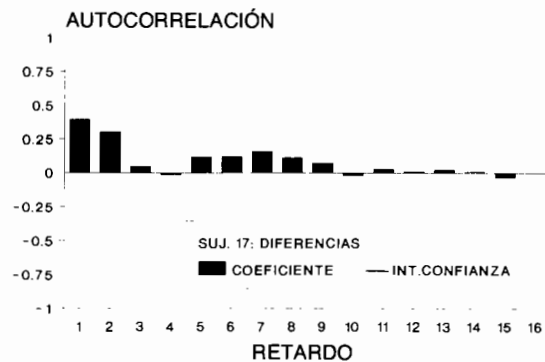


Figura 3. Autocorrelación de la FC diferenciada correspondiente al Pretest del sujeto 17.

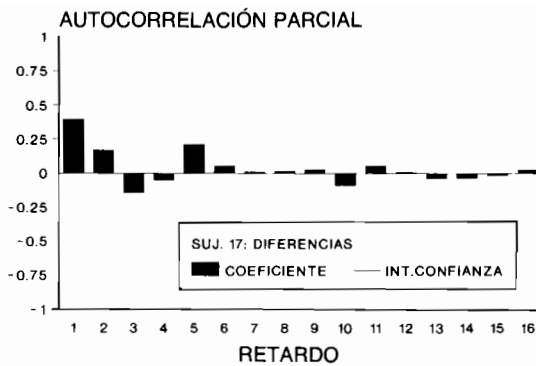


Figura 4. Autocorrelación parcial de la FC diferenciada correspondiente al Pretest del sujeto 17.

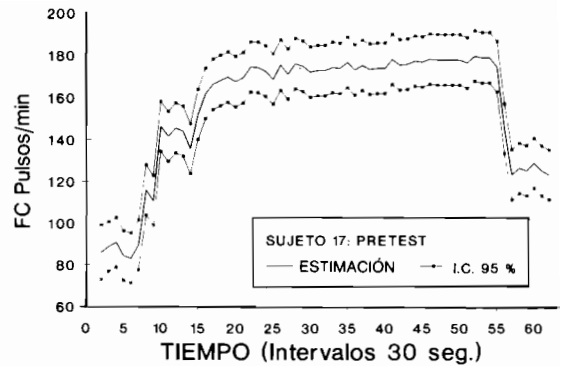


Figura 5. FC estimada por un modelo ARIMA (1,1,0) ajustado al Pretest del sujeto 17. También se representa el intervalo de confianza del 95 por 100 estimado por el modelo.

las figuras 3 y 4, nosotros nos inclinamos por la identificación de un proceso ARIMA (1,1,0) para la curva del Pretest. El primer valor 1 indica que se trata de un proceso autorregresivo de orden 1, esto es, que cada valor de FC correlaciona significativamente con el valor inmediatamente anterior. El segundo valor 1 representa el nivel de integración-diferenciación de la serie y nos indica que estamos analizando las diferencias entre cada valor y el valor inmediatamente precedente, al no mostrar la serie una varianza constante y una tendencia nula. El último valor 0 indica que no consideramos ningún efecto importante de medias móviles. Los posibles modelos competidores en este caso, que nos podrían hacer dudar en la identificación, son los modelos ARIMA (0,1,1) y ARIMA (1,1,1). En la fase de validación comprobaremos que el que nosotros hemos identificado es el más adecuado.

b) *Estimación de parámetros.* Un modelo ARIMA (1,0,0), sin ningún nivel de diferenciación, presenta una ecuación del tipo:

$$Y_t = C + b_1 \times Y_{t-1} + E_t,$$

donde Y_t representa el valor de FC en el momento t , C es una constante que indica la tendencia de la serie, b_1 es el parámetro autorregresivo de orden 1 y E_t es un término de error. Teniendo en cuenta la diferenciación efectuada en la serie según un modelo ARIMA (1,1,0), la ecuación general que sigue el modelo al integrar de nuevo la serie es la siguiente:

$$Y_t = C + (1 + b_1) \times Y_{t-1} - b_1 \times Y_{t-2} + E_t$$

Para estimar el valor de los parámetros se ha utilizado el algoritmo de Marquardt, una técnica iterativa basada en el método de estimación por mínimos cuadrados. Así, para el Pretest del sujeto 17, la estimación de la FC en el momento t viene dada por la ecuación:

$$Y_t = (1 + 0,39) \times Y_{t-1} - 0,39 \times Y_{t-2}$$

donde se ha realizado la integración y se ha eliminado la constante, al no ser significativa, reestimando

el parámetro autorregresivo. En la figura 5 se puede observar el ajuste del modelo ARIMA (1,1,0) a la curva de FC del Pretest. Nótese que el modelo ajusta peor en los puntos donde la FC cambia de nivel bruscamente.

c) *Validación del modelo.* La validación del modelo a partir del análisis de residuales y de algún índice de su bondad de ajuste nos dará criterios para comparar diferentes ajustes y escoger aquél más válido. Dada la subjetividad presente en la fase de identificación, es conveniente realizar diferentes tentativas de ajuste de aquellos modelos más probables, y quedarse con el modelo óptimo. Un buen ajuste habría de originar residuales sin autocorrelación y con tendencia a valer cero. En este trabajo, para el análisis de residuales utilizaremos: 1) el índice Durbin-Watson (un valor de 2 indica independencia total de los residuales); 2) el valor medio de los residuales (habría de ser cercano a cero para indicar un buen ajuste), y 3) el error estándar de los residuales (habría de ser mínimo). Por fin, utilizaremos el índice *Akaike Information Criterion* (AIC) que nos permite comparar diferentes modelos en cuanto a la bondad de ajuste. Este estadístico se basa en lo bien que ajusta un modelo a una serie observada y en el número de parámetros usados en la estimación. Para escoger entre diferentes tentativas de ajuste, seleccionaremos aquel modelo con un valor AIC más bajo. En la tabla 1 se pueden consultar los índices descritos correspondientes a un modelo ARIMA (1,1,0) que ha sido el modelo óptimo identificado y validado hasta este punto. A continuación veremos cómo podemos mejorar este ajuste a partir de la introducción en el modelo de regresores ficticios. En la misma tabla 1 se pueden comparar los índices de validación de este nuevo ajuste.

II. Optimización del ajuste incluyendo regresores ficticios en el modelo

En la figura 5, correspondiente al ajuste del modelo sobre la curva real, se puede comprobar que aque-

TABLA 1

Estadísticos que permiten comparar los modelos ajustados a la curva de FC del Pretest para el sujeto 17. El modelo más válido contiene seis regresores ficticios

| Regresores ficticios | Ninguno | Seis |
|-----------------------|---------|--------|
| Grados libertad | 60 | 54 |
| Índice AIC | 392,15 | 284,67 |
| Media residuales | 0,409 | 0,288 |
| Error est. residuales | 5,966 | 2,356 |
| Índice Durbin-Watson | 2,119 | 1,962 |

Los puntos temporales donde el modelo no ajusta de forma óptima se identifican con los intervalos de tiempos inmediatamente posteriores a las pocas variaciones bruscas de la FC observables en la curva real. Efectivamente, al tratarse de un modelo autorregresivo de orden 1, el valor estimado en un punto dado se calcula a partir del valor real precedente. Esto hace que la curva estimada parezca desplazada hacia la derecha en aquellos puntos donde la variación en la FC es importante. En nuestro caso, conocemos el factor que ha provocado estos cambios bruscos en la variable estudiada, ya que forma parte de las condiciones experimentales de la investigación. La variación en la velocidad de la cinta ergométrica provoca los cambios de nivel importantes observados en la evolución de la FC. Es un hecho lógico y observable dada la coincidencia temporal de los dos acontecimientos. Entonces podemos intentar mejorar el ajuste de nuestro modelo si tenemos en cuenta el impacto de los cambios de velocidad sobre la evolución en el tiempo de la variable estudiada. Estos cambios de velocidad se estimarían en el modelo a través de los parámetros correspondientes a los regresores ficticios.

Siguiendo una técnica denominada «Análisis de Intervención» (SPSS Inc., 1987), podemos conseguir un mejor ajuste del modelo ARIMA en aquellos momentos donde la FC sabemos que está afectada por los cambios de velocidad de la cinta. Sin entrar en detalle en el cálculo de los regresores ficticios, a continuación especificamos la ecuación de un modelo ARIMA (1,1,0) con 6 regresores que ofrece un ajuste óptimo de los datos:

$$Y_t = 1,036 \times Y_{t-1} - 0,036 \times Y_{t-2} + 19,78 \times R_7 + 25,78 \times R_9 + 10,21 \times R_{14} + 9,79 \times R_{15} - 21,89 \times R_{55} - 21,85 \times R_{56}$$

donde R_7 vale 1 sólo en el intervalo 7, R_9 en el intervalo 9, R_{14} en el intervalo 14, R_{15} en el intervalo 15, R_{55} en el intervalo 55, y R_{56} en el intervalo 56. Hay que decir que todos los cambios de nivel en la FC estimados en estos puntos son significativos, basándonos en la serie temporal entera ($p < 0,0005$ en todos los casos). No obstante, el parámetro autorregresivo (0,036) deja de ser significativo al incluir los seis regresores ficticios. Es como si la evolución de la FC quedara explicada sólo por los cambios de

velocidad en el tapiz rodante y éstos fueran los responsables de la autocorrelación observada en los datos. A pesar de no ser significativo, hemos optado por dejar el parámetro autorregresivo incluido en el modelo, ya que así nos informa del modelo que sigue la serie, antes de incluir los regresores ficticios. Además, los análisis posteriores de otros sujetos nos han indicado que prácticamente la totalidad siguen modelos autorregresivos.

En la figura 6 se grafica el modelo ARIMA (1,1,0) con seis regresores ficticios, ajustado a la curva de FC del Pretest. Se puede observar cómo el ajuste es mejor que en la figura 5, en los intervalos donde la FC cambia bruscamente. Asimismo, el intervalo de confianza del 95 por 100 se hace más estrecho alrededor de la estimación que realiza el modelo. En la tabla 1 observamos los estadísticos que permiten una comparación del ajuste original con el ajuste que contiene seis regresores ficticios. A la vista de estos resultados, se puede concluir de forma clara que el modelo ARIMA (1,1,0) con seis regresores ficticios ajusta mucho mejor los datos que el modelo original: presenta una mejor bondad de ajuste (índice AIC más bajo), el valor medio de los residuales es menor, así como su error estándar y el índice Durbin-Watson es óptimo. De hecho podríamos incluir en el modelo tantos regresores ficticios como quisiéramos, pero sólo tendrían sentido aquellos que resulten significativos teniendo en cuenta la evolución global de los datos, y para los cuales tenemos una explicación lógica (como es un cambio en las condiciones experimentales en un momento dado).

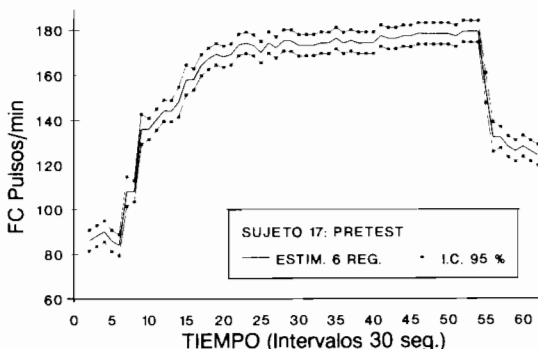


Figura 6. FC estimada por un modelo ARIMA (1,1,0) con 6 regresores ficticios, ajustado al Pretest del sujeto 17. Los regresores corresponden a los instantes de cambio de velocidad de la cinta ergométrica. También se representa el intervalo de confianza del 95 por 100 estimado por el modelo.

III. Comparación de las curvas de FC del Pretest y del Postest a partir del modelo ajustado: Técnica de Superposición de Curvas

Una vez tenemos el modelo óptimo ajustado a la curva de la FC del Pretest, el siguiente paso es utilizarlo para averiguar si la curva observada en el Pos-

test sigue el mismo patrón en su evolución temporal. Nos convendría una estrategia estadística que permitiera comparar directamente dos curvas sometidas al mismo diseño experimental. Posiblemente, esta estrategia habría de tomar en consideración la sugerencia de Doménech (1985) de que aquello que realmente proporciona argumentos al investigador para evaluar la relevancia de un efecto observado es el intervalo de confianza que estima la magnitud del efecto y no un valor p de significación encontrado. Siguiendo esta consideración, no pretendemos encontrar un índice estadístico que a partir de un nivel de significación dado nos indique diferencias significativas entre las dos curvas o entre valores puntuales de FC. para comparar las dos curvas, nos basaremos en el modelo ajustado a la FC del Pretest y en el correspondiente intervalo del 95 por 100 estimado. Se parte de la base de que los residuales de un modelo ARIMA siguen un proceso de «ruido blanco» (Box y Jenkins, 1970; Bowerman y O'Connell, 1979), es decir, que presentan una distribución aleatoria alrededor de las estimaciones que realiza el modelo. Así, el uso del intervalo de confianza del 95 por 100 estaría justificado, ya que los residuales de un modelo ARIMA óptimamente ajustado han de cumplir unas condiciones similares a los residuales de los modelos de regresión lineal: a) independencia de la parte sistemática del modelo; b) media igual a cero y varianza constante, y c) distribución normal. La táctica que utilizaremos consistirá en graficar el intervalo de confianza estimado para que un modelo óptimamente ajustado al Pretest, y superponerle la curva real de FC observada en el Postest. A continuación, se podrán detectar visualmente aquellos momentos temporales en que la curva del Postest sobrepasa los límites del intervalo de confianza. En estos puntos, la FC observada en el Postest no sigue el mismo patrón que la del Pretest, con una probabilidad inferior al 5 por 100 de que esto sea debido al azar. Hemos denominado esta técnica como «Técnica de Superposición de curvas» (TSC). En este trabajo la utilizaremos con finalidades básicamente descriptivas, haciendo una interpretación gráfica de los resultados. Pero creemos que los mismos resultados se pueden analizar de forma analítica, por ejemplo, calculando e interpretando los residuales de la curva real de la FC observada en el Postest, respecto a la estimación realizada para la FC del Pretest. Dejaremos este tipo de tratamiento de los datos para posteriores investigaciones.

Volviendo a nuestro ejemplo, seguiremos los siguientes pasos para aplicar la TSC: a) cálculo del intervalo de confianza del 95 por 100 correspondiente a la estimación de la FC del Pretest, realizada a partir del modelo ARIMA con seis regresores (véase figura 6); b) superposición de la curva del Postest (véase figura 1) sobre el intervalo de confianza estimado. La representación conjunta de ambos elementos se puede observar en la figura 7. Se puede comprobar que la FC en el Postest está claramente por debajo del intervalo de confianza estimado para el Pretest, en los minutos de reposo iniciales y en los minutos de recuperación finales. También se

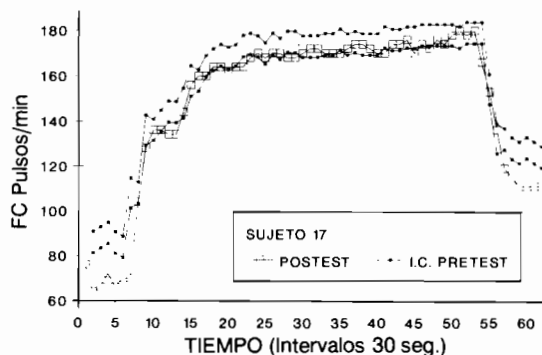


Figura 7. Técnica de superposición de curvas aplicada a las curvas FC del sujeto 17. Se representan el intervalo de confianza correspondiente a la estimación de la FC del Pretest a partir del modelo ARIMA (1,1,0) con 6 regresores, y la curva real de FC del Postest.

puede observar que el primer cambio de nivel en la serie, debido a la puesta en marcha de la cinta, se produce un intervalo de tiempo más tarde en el Postest. Asimismo, al parar la cinta, el descenso en la FC parece producirse antes en el Postest. Durante el resto de la curva se observan valores por debajo del límite inferior del intervalo de confianza, en algún momento del calentamiento y en bastantes puntos de la carrera constante. Se puede ver que en este período de carrera constante, aparte de los instantes finales, la curva correspondiente al Postest está muy próxima al límite inferior del intervalo de confianza.

Discusión

Los resultados expuestos parecen indicar que el análisis de series temporales basado en modelos ARIMA resulta muy adecuado para evaluar datos de tipo psicofisiológico como la FC. Esta metodología de análisis permite obtener conclusiones válidas respecto a la evolución individual de la curva de un sujeto, difíciles de obtener a partir de la estadística convencional.

En el ejemplo ilustrado se demuestra que un modelo ARIMA (1,1,0), con regresores ficticios aplicados en los momentos de cambio de velocidad de la cinta ergométrica, puede explicar satisfactoriamente el comportamiento de una curva de FC individual recogida según nuestro diseño. Con este ejemplo pretendíamos detallar todos los pasos seguidos hasta la obtención de un modelo ópticamente ajustado al diseño utilizado. Aunque, con el fin de justificar las etapas subsiguientes, muchos aspectos se discuten ya al analizar los resultados, queremos resaltar algunas consideraciones a tener en cuenta, a nivel metodológico:

1. El análisis de intervención se tiene que adaptar al diseño experimental. Sólo cuando sabemos realmente que en algún momento temporal concreto se

da una intervención conocida, es conveniente aplicar un regresor ficticio. Éste nos informará del cambio que sufrirá la serie temporal, considerando su evolución completa, debido a los efectos de la intervención. A la vez, producirá un reajuste de los parámetros ya estimados. Su inclusión tiene que proporcionar una optimización en la validación del modelo, hecho que se puede prever analizando la curva real de observaciones: en el punto de la intervención se tendría que observar un cambio de nivel o de tendencia destacable respecto al resto de la curva. En nuestro ejemplo consideramos que los cambios reales de la FC, observados en los intervalos donde se aplican los regresores ficticios, están relacionados con el cambio de velocidad de la cinta ergométrica.

2. *Una intervención puede afectar la dependencia serial de las observaciones.* En el ejemplo estudiado, el sujeto 17 presentaba en el Pretest un modelo ARIMA original con un parámetro autorregresivo de orden 1 significativo ($AR1 = 0,39$, $p < 0,05$). En cambio, al aplicar los seis regresores pierde su significación ($AR1 = 0,036$), hecho que nos indica que la dependencia serial de los datos ha variado al explicar los cambios más importantes de la serie, en los intervalos 7, 9, 14, 15, 55 y 56. Se puede interpretar que los cambios de velocidad en la cinta son los principales responsables de la autocorrelación de las observaciones. Nuestro enfoque de este problema contrasta con la postura de Hartmann y cols. (1980), que proponen la aplicación de los modelos ARIMA para eliminar la dependencia serial de los datos y analizar los residuales resultantes según la estadística convencional.

3. *Cuando utilizamos el análisis de intervención según modelos ARIMA para comparar curvas, éstas tienen que estar sometidas a las mismas condiciones experimentales.* Una de las principales condiciones de aplicación de los modelos ARIMA es la regularidad en los intervalos de tiempo en que se recogen las observaciones. Los cálculos de autocorrelación se basan en este hecho, y normalmente el análisis de intervención se ha utilizado para detectar efectos significativos dentro de una misma curva y a partir de un momento temporal concreto (Bowerman y O'Connell, 1979; Uriel, 1986). Si pretendemos comparar dos curvas diferentes según el método expuesto, se tienen que equiparar en el tiempo en todos sus puntos de datos. En nuestro caso, esto se cumple rigurosamente: las dos pruebas de esfuerzo a comparar están sometidas a un mismo diseño, en idénticas condiciones experimentales, y permiten extraer datos situables de igual forma en el tiempo. Así, recogiendo la FC cada medio minuto y controlando las condiciones experimentales en ambas pruebas, podemos atribuir las diferencias entre las respectivas curvas al efecto de la intervención.

4. *La técnica de superposición de una curva real de FC sobre el intervalo de confianza estimado para otra curva nos permite detectar diferencias en cualquier momento temporal.* Una condición básica para que esto sea cierto es que el intervalo estimado corresponda a un ajuste correcto de los datos originales. En nuestro caso, tenemos que estar seguros de

que los intervalos de confianza del 95 por 100 estimados representen de forma óptima la correspondiente curva de FC. Por ello, creemos que uno de los pasos críticos en el análisis de intervención es la identificación del modelo ARIMA adecuado. Es necesario reestimar el ajuste si se observa que la validación del modelo no es del todo correcta. Una vez obtenido el intervalo de confianza adecuado, podemos comparar las dos curvas a partir de dos procedimientos: a) analizar visualmente la superposición de la curva a comparar y detectar aquellos puntos temporales donde se sobrepasa de los límites del intervalo, y b) calcular numéricamente las distancias de la curva superpuesta a los límites del intervalo de confianza para obtener un índice analítico de las diferencias en cada momento temporal.

5. *Los coeficientes estimados para los regresores al aplicar el análisis de intervención nos permiten evaluar la magnitud del efecto de una intervención conocida.* En nuestro caso, el valor de un regresor nos informa del cambio estimado para aquel punto, en unidades reales de FC, debido al cambio de velocidad de la cinta. De esta forma, podemos saber si aquel cambio es significativo respecto a la curva total o podemos compararlo con el cambio estimado para otra curva. Así, en el Pretest del sujeto analizado no se estima ningún descenso significativo en el intervalo 54, mientras que en el Posttest el descenso es de unos 13 pulsos/minuto ($p < .005$). También podemos observar, por ejemplo, que en las dos pruebas se observa un aumento significativo similar en el intervalo 9.

Conclusiones

El análisis de series temporales según modelos ARIMA resulta una metodología muy adecuada para estudiar la evolución longitudinal de variables psicofisiológicas como la FC. Dentro de este tipo de análisis, la Técnica de Superposición de Curvas (TSC), desarrollada en esta investigación, permite evaluar objetivamente los efectos de una intervención, posibilitando la comparación de diferentes curvas de datos, siendo una técnica más precisa cuanto más óptimo sea el ajuste efectuado a los datos originales. En nuestro caso, se consigue un ajuste óptimo cuando consideramos en el modelo el efecto de los cambios de velocidad en la cinta ergométrica sobre las variaciones en el nivel de la FC estudiada.

El análisis de series temporales aporta una información muy sensible a los datos evaluados, permitiendo detectar aquellos momentos temporales en que las diferencias son relevantes. El estudio de la evolución continua en el tiempo de variables como la FC permite obtener mucha más información que un análisis convencional. En este sentido, el análisis de series temporales según modelos ARIMA, junto con la técnica de superposición de curvas, puede ser un instrumento muy valioso cuando analizamos indicadores de conducta como medidas repetidas, sobre todo en diseños de caso único.

Asimismo se abre un interesante campo de estu-

dio de cara al futuro, ya que el instrumento desarrollado se puede afinar mucho más en cuanto al análisis de intervención, pudiendo ser aplicado también al análisis continuo de curvas de datos en diseños de grupo. Además, ofrece la oportunidad de analizar la conducta multidimensionalmente: por ejemplo, al evaluar el indicador fisiológico-bioquímico de la conducta competitiva de un deportista, se podría ajustar un modelo mucho más completo a una curva de FC, incluyendo como regresores reales en el modelo otros parámetros fisiológicos, bioquímicos o motores registrados simultáneamente.

Referencias

- Benson, H. (1975). *The Relaxation Response*. New York: William Morrow.
- Box, G. E. P. y Jenkins, G. M. (1970). *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.
- Bowerman, B. L. y O'Connell, R. T. (1979). *Time series and forecasting*. Belmont, California: Duxbury Press.
- Bryan, A. J. (1987). Single-subject designs for evaluation of sport psychology interventions. *The Sport Psychologist*, 1, 283-292.
- Capdevila, L. (1989a). Anàlisi de sèries temporals aplicada a la freqüència cardíaca en una prova d'esforç. *Apunts. Medicina de l'Esport*, 100, 79-83.
- Capdevila, L. (1989b). *Efectos del entrenamiento psicológico sobre el estrés de competición y sobre la eficiencia cardiorrespiratoria, en atletas mediodondistas*. Tesis doctoral no publicada, Universidad Autónoma de Barcelona, Bellaterra.
- Capdevila, J. y Cruz, J. (1988a). Coping strategies in an athlete: a pilot study. Comunicación presentada en el // *European Meeting of the Experimental Analysis of Behavior*. Liège, Belgique. Juliol, 26-29.
- Capdevila, L. y Cruz, J. (1988b). Ajustament de models estadístics a variables psicològiques. En *Actas V Jornades de l'Associació Catalana de Psicologia de l'Esport* (pp. 188-192). Esplugues de Llobregat: A.C.P.E.
- Crocker, P. R. E., Alderman, R. B. y Smith, F. M. R. (1988). Cognitive-affective stress management training with high performance youth volleyball players: effects on affect, cognition, and performance. *Journal of Sport and Exercise Psychology*, 10, 448-460.
- Doménech, J. M. (1985). *Estimación de parámetros y comprobación de hipótesis*. Bellaterra: Universitat Autònoma de Barcelona.
- Fox, E. L. (1984). *Sports Physiology*. Buenos Aires: Panamericana.
- Glass, G. V., Willson, V. L. y Gottman, J. M. (1974). *Design an Analysis of Time-series Experiments*. Boulder: Colorado Associated University Press.
- Gottman, J. M. (1981). *Time-series Analysis: a Comprehensive Introduction for Social Scientists*. Cambridge: Cambridge University Press.
- Gottman, J. M. y Glass, G. V. (1978). Analysis of interrupted time-series experiments. En T. R. Kratochwill (Ed.), *Single-subject Research: Strategies for Evaluating change* (pp. 197-237). New York: Academic Press.
- Grzib, G., García, B., Briales, C. y Fernández Trespalacios, J. L. (1989). Emoción y conducta: estudio de la emoción desde un punto de vista conductual en humanos. *Revista de Psicología General y Aplicada*, 42, 11-22.
- Hackfort, D. y Schwenkmezger, P. (1989). Measuring anxiety in sports: perspectives and problems. En D. Hackfort y C. D. Spielberger (Eds.), *Anxiety in Sports: An International Perspective* (pp. 55-74). New York: Hemisphere P. C.
- Hartman, D. P., Gottman, J. M., Jones, R. R., Gardner, W., Kazdin, A. E. y Vaught, R. S. (1980). Interrupted time-series analysis and its application to behavioral data. *Journal of Applied Behavior Analysis*, 13, 543-559.
- Huitema, B. E. (1985). Autocorrelation in applied behavior analysis: a myth. *Behavioral Assessment*, 7, 107-118.
- Kazdin, A. E. (1982). *Single-case research designs: methods for clinical an applied settings*. New York: Oxford University Press.
- Kazdin, A. E. (1984). Análisis estadísticos para los diseños experimentales de caso único. En M. Hersen y D. H. Barlow (Eds.), *Single Case Experimental Designs* (pp. 285-324). New York: Pergamon Press. Traducción: *Diseños experimentales de caso único*. Barcelona: Martínez Roca, 1988.
- Porges, S. W., Bohrer, R. E., Cheung, M. N., Drasgow, F., McCabe, P. M. y Keren, G. (1980). New time series statistic for detecting rhythmic co-occurrence in the frequency domain: the weighted coherence and its application to psychophysiological research. *Psychological Bulletin*, 88, 580-587.
- Siegel, D. (1986). Reduction of test anxiety using pavlovian conditioning principles: a preliminary note. *Psychological Reports*, 59, 48-50.
- SPSS Inc. (1987). *SPSS/PC+ Trends*. Chicago: SPSS Inc.
- Suinn, R. M. (1980). Psychology and sports performance: principles and applications. En R. M. Suinn (Ed.), *Psychology in Sports: Methods and Applications* (pp. 26-36). Minneapolis, Minnesota: Burgess.
- Uriel, E. (1985). *Análisis de Series Temporales. Modelos ARIMA*. Madrid: Paraninfo.
- Zaichkowsky, L. D. (1980). Single case experimental designs and sport psychology research. En C. H., Nadeau, W. R., Halliwell, K. M., Newell y G. C., Roberts (Eds.), *Psychology of Motor Behavior and Sport*. 1979 (pp. 171-179), Champaign, Ill.: Human Kinetics.
- Ziegler, S. G., Klinzing, J. y Williamson, K. (1982). The effects of two stress management training programs on cardiorespiratory efficiency. *Journal of Sport Psychology*, 4, 280-289.