

Diferencias en la dimensionalidad del electroencefalograma entre vigilia y sueño profundo

Xavier Rifà-Ros, Lluís Fuentemilla, Manel Viader-Junyent y Carles Grau
Universidad de Barcelona

La Teoría de Sistemas Dinámicos no Lineales proporciona herramientas para el análisis del electroencefalograma (EEG) en las distintas etapas de sueño. Su utilización podría permitir la monitorización de los estados de sueño-vigilia y aportaría un nivel explicativo de las diferencias entre etapas. El objetivo del presente trabajo es hacer una primera aproximación a este tipo de análisis, fijándonos en los dos estadios más dispares. Se pretende estimar la dimensionalidad de la señal EEG de seis sujetos comparando el estado de vigilia con la fase de sueño más profundo. Una mayor dimensionalidad implica más complejidad, es decir, el sistema recibe más influencias externas. Si esta dimensionalidad es máxima podemos considerar que la serie temporal es ruidosa. Una menor dimensionalidad implica menor complejidad puesto que el sistema recibe menos entradas. Nuestra hipótesis era que encontraríamos una mayor dimensionalidad en la situación de vigilia que en la situación de sueño profundo. Los resultados muestran que en la condición de vigilia la serie temporal es ruidosa, mientras que en la etapa de sueño la dimensionalidad es menor, confirmando nuestra hipótesis. Este resultado es congruente con los que han alcanzado otros autores.

Differences in dimensionality of electroencephalogram during awake and deeper sleep stages. The nonlinear dynamical systems theory provides some tools for the analysis of electroencephalogram (EEG) at different sleep stages. Its use could allow the automatic monitoring of the states of the sleep and it would also contribute an explanatory level of the differences between stages. The goal of the present paper is to address this type of analysis, focusing on the most different stages. Estimations of dimensionality were compared when six subjects were awake and in a deep sleep stage. Greater dimensionality involves more complexity because the system receives more external influences. If this dimensionality is maximum, we can consider that the time series is a noisy one. A smaller dimensionality involves lower complexity because the system receives fewer inputs. We hypothesized that we would find greater dimensionality when subjects were awake than in a deep sleep stage. Results show a noisy time series during the awake stage, whereas in the sleep stage, dimensionality is smaller, confirming our hypothesis. This result is similar to the findings reached previously by other authors.

La Teoría de Sistemas Dinámicos no Lineales (TSDNL) se gestó y ha evolucionado principalmente en el contexto de la física aplicada, concretamente en la especialidad de meteorología. Tras su aparición sus postulados han sido aplicados en muchas otras ciencias, entre las que destacan biología, economía, ingeniería y también psicología. En la actualidad, es frecuente encontrar estudios en los que los análisis de Series Temporales (ST) se basan en esta teoría.

Se puede considerar un enfoque dirigido al análisis de ST que se sustenta en tres características. En primer lugar se parte de la premisa que una ST que hemos registrado está inmersa en un Sistema Dinámico (SD), es decir, puede evolucionar conjuntamente con una o más variables. Al número de variables que conforman

este sistema lo denominamos «Dimensión de inmersión». La segunda de las características se refiere a que las relaciones que se establecen entre estas variables son no lineales y que, cuando se dan relaciones lineales, éstas son un caso particular. Finalmente, nos podemos encontrar que en una serie temporal aparezca el fenómeno de la Dependencia a las Condiciones Iniciales. Éste consiste en que, una vez que podemos realizar buenas predicciones, disminuye su precisión en el proceso de iteración a medida que aumenta el número de retardos. Por otro lado, la TSDNL ha desarrollado una serie de algoritmos para evaluar las características mencionadas.

Por lo que respecta a nuestra disciplina, destaca la aplicación de estas técnicas provenientes de la TSDNL en el estudio de la señal eléctrica cerebral registrada mediante el electroencefalograma (EEG). Su utilización se ha dirigido al análisis del EEG en multitud de contextos, como en estados cerebrales espontáneos en reposo, estados de coma, efectos de la anestesia, epilepsia, cognición normal, cognición en determinadas patologías degenerativas y en el estudio de las distintas fases del sueño (Stam, 2005), aplicación a la que dedicamos el presente trabajo.

Hemos dirigido nuestra atención al análisis de la dimensionalidad de la señal EEG en dos estados cerebrales claramente diferenciados del sueño-vigilia. Esta característica es muy relevante cuando se analiza una ST desde el punto de vista de la TSDNL, dado que se considera que una ST es determinista cuando el SD en la que está inmersa tiene una baja dimensionalidad. En cambio, se considera que ésta tiene apariencia aleatoria o de ruido cuando éste tiene una alta dimensionalidad (Casdagli, 1991; Bascompte, 1995). Debemos considerar que cuando la dimensionalidad es alta hay un número elevado de grados de libertad, es decir, hay un número elevado de variables que pueden influir en la ST que estamos analizando. En el caso contrario, es decir, cuando hay baja dimensionalidad, debemos considerar que hay pocas variables relacionadas con la ST que estamos analizando y, por lo tanto, hay un número de grados de libertad limitado considerando entonces que ésta es determinista. De hecho, hay ejemplos en los que mediante herramientas estadísticas tradicionales, por ejemplo, la función de autocorrelación, una ST tiene apariencia de ruido y, en cambio, ésta es determinista (Sugihara y May, 1990; Bascompte, 1995). Para realizar nuestros análisis hemos escogido una de las técnicas más populares en este contexto, la Dimensión de Correlación de Grassberger y Procaccia (1983a, 1983b).

Ya hemos mencionado que una ST siempre está inmersa en un SD, éste lo forman una serie de variables que evolucionan de forma interrelacionada a lo largo del tiempo (Solé y Manrubia, 1996). Estos sistemas evolucionan de forma continua, pero el registro de las variables se realiza de forma discreta escogiendo, en función del tipo de variable que estamos estudiando, un determinado número de registros por intervalo de tiempo, que se conoce con el nombre de «tasa de registro».

Muchas de las herramientas de análisis que se han gestado en nuestro ámbito se basan en un concepto clave, el atractor del SD. Éste está formado por una serie de puntos representados en el espacio de k dimensiones, donde k es la Dimensión de Inmersión del SD, que surgen de proyectar en este espacio los valores de las diferentes ST (Bascompte, 1995). Este atractor no es más que una serie de localizaciones «privilegiadas», en este espacio de k dimensiones, que contienen mucha información de las características del sistema y que, por extensión, tienen una marcada influencia en la evolución a lo largo del tiempo de las diferentes variables interrelacionadas.

Cuando un SD está completamente especificado y se conocen todas las variables que lo contienen es factible la construcción de este atractor. Ello es posible normalmente con ST simuladas, ampliamente utilizadas en el contexto de la TSDNL. Cuando se estudian ST observadas no es posible la construcción de este atractor y hay que realizar su reconstrucción.

Para ello nos podemos basar en el teorema de Withney, desarrollado por Takens (Abarbanel, 1996). Éste afirma que podemos reconstruir los puntos $X(t)$, para un número determinado de componentes al que designaremos por k , de un atractor con las mismas características que el ideal utilizando los valores de la ST registrada. Así los puntos de este atractor estarían constituidos por coordenadas establecidas a partir de la regla $X(t) = (x(t), x(t+1), x(t+2), \dots, x(t+k-1))$, donde t indica la ordenación a lo largo del tiempo de las puntuaciones de la ST registrada.

El algoritmo para el cálculo de la Dimensión de Correlación requiere la reconstrucción del atractor a partir de la ST observada. Una vez reconstruido el atractor para distintos valores de k tenemos que calcular la Integral de Correlación para cada uno de estos

atractores reconstruidos mediante la siguiente expresión (Grassberger y Procaccia, 1983a; Bascompte, 1995),

$$C(r) = \frac{1}{N^2} \sum_{t,s}^N \theta(r - |X(t) - X(s)|)$$

donde $\theta(x)$ es una función caracterizada con el siguiente enunciado,

$$\theta(x) = 0 \text{ si } x < 0 \text{ y} \\ \theta(x) = 1 \text{ si } x > 0,$$

donde $X(t)$ y $X(s)$ son dos puntos del atractor, y donde r es una distancia arbitrariamente pequeña dado que en este último caso tenemos que,

$$C(r) \propto r^v$$

Puesto que existe esta proporcionalidad y que v es un valor aproximado de la Dimensionalidad para un valor k determinado, si aplicamos logaritmos a ambos lados de la expresión podremos estimar la Dimensionalidad del atractor calculando la pendiente de la recta que describen $\log(C(r))$ y $\log(r)$ para diferentes valores suficientemente pequeños de r .

Una vez calculada la pendiente de la recta que describen $\log(C(r))$ y $\log(r)$ para cada atractor reconstruido, con un número de componentes finito, representaremos en un gráfico la pendiente calculada en el eje de ordenadas y el número de componentes en las abscisas. Una aproximación de la Dimensionalidad de la ST es el primer valor de la pendiente a partir del cual éste permanece constante aunque añadamos nuevas componentes del atractor reconstruido. En la figura 1 podemos observar esta representación gráfica, donde mostramos la forma de interpretar resultados simulados de determinismo, baja dimensionalidad y ruido.

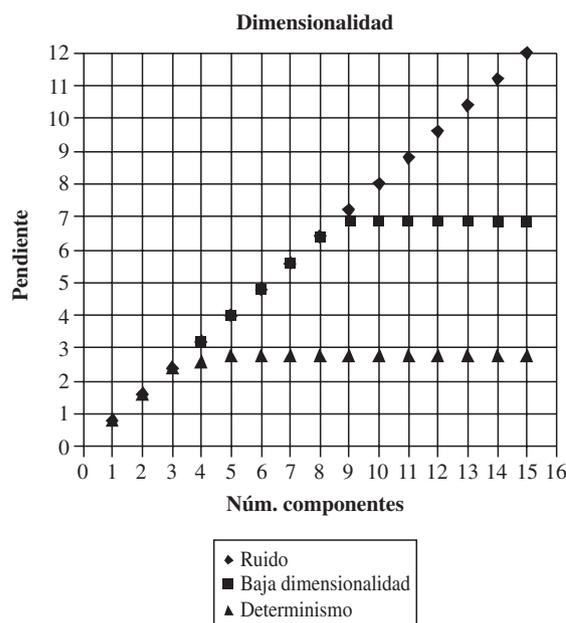


Figura 1. Representación gráfica de la Dimensión de Correlación para ejemplificar la interpretación de resultados con determinismo, baja dimensionalidad o ruido

Ya hemos mencionado que la Dimensión de Correlación ha sido utilizada en el contexto del análisis de la señal EEG. El análisis del EEG en los estados de sueño-vigilia permitiría detectar diferencias respecto a su dimensionalidad. Esta supuesta capacidad de diferenciar la dimensionalidad del SD subyacente es muy prometedora puesto que permitiría sentar las bases para la posible monitorización automatizada de esta señal y, por otro lado, tendríamos un indicador que sería un punto de partida en el conocimiento de la naturaleza de los procesos del Sistema Nervioso Central (SNC) durante los distintos estados de sueño-vigilia (Stam, 2005).

En este sentido, puesto que el registro de EEG es un indicador de la dinámica cerebral, estaría justificada la idea de que en situación de vigilia la señal de EEG debería estar caracterizada por un mayor número de grados de libertad ya que el sistema está influenciado por su propia dinámica interna y por variables externas a éste en forma de entradas de información. Por el contrario, en la situación de sueño profundo la señal de EEG denotaría que hay un menor número de grados de libertad puesto que las entradas provenientes del medio externo se eliminarían del sistema (Stam, 2005; Coenen, 1998).

El objetivo de nuestra investigación es la realización de una primera aproximación al análisis de dimensionalidad aplicado al registro del EEG durante dos estados cerebrales muy dispares. El primero corresponde a la fase de vigilia que se da justo antes del adormecimiento del sujeto. El segundo corresponde a la fase de sueño profundo (Fases III y IV) que se manifiesta por ondas lentas en el EEG.

Teniendo en cuenta las posibles diferencias que encontraríamos respecto a la dimensionalidad de la señal, creemos que a partir de los registros en el laboratorio del sueño (polisomnograma, PSG), una vez seleccionadas dos ventanas temporales de vigilia y sueño profundo y calculada la Dimensión de Correlación, los resultados deberían mostrar una mayor dimensionalidad en la fase de vigilia que en la de la etapa de sueño profundo.

Método

Participantes

La muestra estaba formada por diez sujetos, seis mujeres y cuatro hombres, con edades comprendidas entre los 20 y 30 años. Al llegar al laboratorio se procedía a la colocación de los electrodos y se les daba a los participantes la consigna de acostarse y relajarse para alcanzar el sueño.

Registro electroencefalográfico

Se colocaron cuatro electrodos EEG a cada uno de los sujetos en las localizaciones C3, C4, Fp1, O1, dos electrodos oculares (electroculograma, EOG) y dos electrodos auriculares de referencia (A1 y A2) con una tasa de registro de 512 Hz. Nuestros análisis se realizaron únicamente con el electrodo C4 en base a los criterios para la clasificación de las fases del sueño de Rechtschaffen y Kales (1968) y una tasa de registro de 64 Hz.

Procedimiento

Una vez realizado el registro PSG completo, dos especialistas en clasificación de la señal de sueño seleccionaron, mediante inspección visual, dos ventanas de 8 segundos libres de movimiento para cada sujeto. Una correspondía a la fase de vigilia justo antes

de que el sujeto se dormía y la otra a la fase de sueño profundo (Fases III y IV). Para su selección se siguieron los criterios de Rechtschaffen y Kales (1968).

Análisis de datos

Para poder estimar la Dimensión de Correlación mediante el método de Grassberger y Procaccia (1983a, 1983b) hay que realizar un pre-proceso de los datos. Éste consiste en la estimación del intervalo idóneo para la reconstrucción del atractor, con el fin de que éste contenga la información necesaria del SD. Para ello se ha propuesto emplear una medida de la Teoría de la Información de Shannon conocida como la Media de Información Mutua $I(s)$ (Abarbanel, 1996). Si tenemos dos registros $x(t)$ y $x(t+s)$ de una ST determinada, donde s es la separación entre ambos registros, se considera que hay cierta conexión entre ambas medidas. Para conocer el tamaño de esta conexión, en función de la información que aportan los valores $x(t)$ y $x(t+s)$, disponemos de la siguiente expresión

$$I(s) = \sum_{x(t),x(t+s)} P(x(t),x(t+s)) \log_2 \left[\frac{P(x(t),x(t+s))}{P(x(t))P(x(t+s))} \right]$$

Ésta nos indica que cuando $I(s)$ es relativamente grande la información que $x(t+s)$ aporta al sistema es redundante. Por este motivo se considera que el intervalo idóneo para la reconstrucción del atractor es el valor de s más pequeño que podemos encontrar en que la media de información mutua es mínima, punto en el que se considera que las puntuaciones de la ST son lo suficiente independientes la una de la otra, es decir, no redundantes, y lo suficiente próximas como para estar relacionadas. Según Fraser y Swinney (1986) esta medida, para diferentes valores de s , vendría a ser la función de autocorrelación no lineal de la ST (Abarbanel, 1996). En la figura 2 podemos ver el valor de la media de información mutua en función del intervalo de separación s para el registro de la Fase de Sueño Profundo del sujeto 1. En este ejemplo el valor establecido fue $s = 22$, puesto que corresponde al primer mínimo de la Media de Información Mutua. El cálculo de la Media de Información Mutua se ha realizado con el programa MATLAB R13[®]. Después de calcular la Media de Información Mutua para

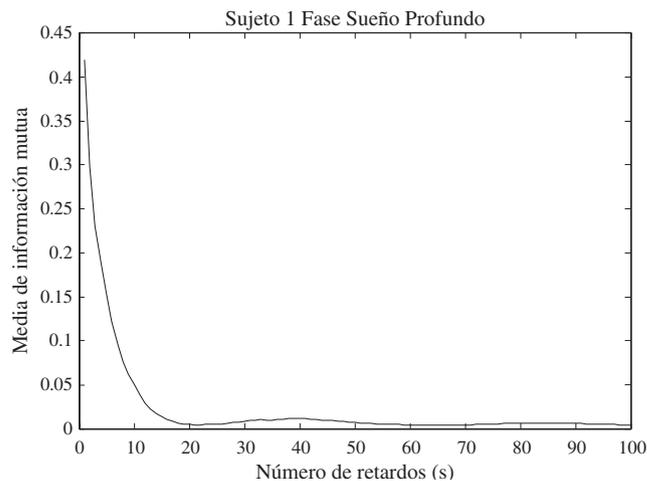


Figura 2. Media de Información Mutua en función del número de retardos (s) en el registro EEG durante la fase de sueño profundo del Sujeto 1

todos los sujetos en ambas fases, se desecharon los participantes cuyos registros no mostraban claramente este intervalo idóneo en alguna de las dos ventanas de registro, quedando seis sujetos para los análisis completos.

Después de este preproceso de los datos se procedió al cálculo de la Dimensión de Correlación mediante el algoritmo de Grassberger y Procaccia (1983a, 1983b). Para ello se utilizó la rutina D2 del paquete TISEAN, que es un programa de libre distribución dedicado al análisis de ST desde la óptica de la TSDNL (Hegger, Kantz y Schreiber, 1999).

Resultados

Los resultados muestran claras diferencias entre la fase de sueño profundo y la fase de vigilia. Concretamente hemos encontrado que para todos los sujetos la Dimensión de Correlación permite discriminar entre las dos fases, encontrando que en la fase de vigilia la señal es ruidosa y, por el contrario, en la fase de sueño profundo la señal indica que está caracterizada por una baja dimensionalidad. En la figura 3 se representan los resultados del sujeto 3, los cuales se repiten para los otros cinco sujetos. Se puede observar que al calcular la pendiente de la recta $\log(C(r)) - \log(r)$ para cada atractor reconstruido de cada ventana, encontramos que en la fase de vigilia ésta aumenta para cada nueva componente añadida, mientras que en la fase de sueño profundo el valor de la pendiente acaba estabilizándose en un valor determinado.

Estos resultados se pueden observar en la tabla 1, donde se muestra claramente que para todos los sujetos el método permite discriminar entre las fases de sueño-vigilia. Hemos utilizado la Prueba de Signos (Siegel y Castellan, 1988) para contrastar las diferencias encontradas. Puesto que éstas son en la misma dirección para todos los sujetos, la probabilidad de encontrar la hipótesis nula de equilibrio entre posibles soluciones es de $p = 0,016$, por lo que podemos rechazar la hipótesis nula.

Tabla 1
Resultados en la dimensionalidad de las fases de sueño-vigilia para los seis sujetos

Sujetos	Fase de vigilia		Fase de sueño profundo	
	Pendiente	Señal	Pendiente	Señal
Participante 3	Creciente	Ruido	6,03	Baja dimensionalidad
Participante 4	Creciente	Ruido	5,87	Baja dimensionalidad
Participante 7	Creciente	Ruido	6,56	Baja dimensionalidad
Participante 8	Creciente	Ruido	6,17	Baja dimensionalidad
Participante 9	Creciente	Ruido	6,58	Baja dimensionalidad
Participante 10	Creciente	Ruido	6,63	Baja dimensionalidad

Discusión y conclusiones

Nuestros resultados muestran que hay una mayor dimensionalidad en la fase de vigilia que en la fase de sueño profundo, encontrándose estas diferencias al comparar los registros correspondientes a cada fase y para todos los sujetos. Es importante destacar que estas diferencias lo son también en cuanto a características de la señal. Es decir, la señal de la fase de vigilia es ruidosa, mientras que la de la fase de sueño profundo es de baja dimensionalidad, por lo que nos lleva a pensar que las diferencias entre ambas fases son importantes. En este sentido nuestros resultados concuerdan con los de otros investigadores (Stam, 2005; Coenen, 1998).

Hemos mencionado que el hecho de disponer de un método para estimar estas diferencias puede ser un paso más hacia el objetivo de ser capaces de automatizar la monitorización de señales electrofisiológicas. Por otro lado, en cuanto a las implicaciones sobre el conocimiento del SNC durante las distintas fases del sueño, su utilización aportaría información al respecto del número de variables implicadas a lo largo de este proceso, puesto que mediante esta técnica podemos identificar diferencias en la dimensionalidad de la señal (Stam, 2005; Coenen, 1998).

Por lo que respecta a los resultados de la fase de vigilia, el hecho de que la señal tenga apariencia de ruido estaría en la línea de lo previsible. Si estamos en esta situación es evidente que el sistema recibe más entradas. Si miramos estos resultados desde la óptica de la TSDNL debemos pensar que el SD subyacente tiene tantas variables que el comportamiento de cada una de ellas tiene esta apariencia de ruido (Coenen, 1998).

Ya se ha mencionado que este estudio es una primera aportación para conseguir un mejor conocimiento de los mecanismos cerebrales en el sueño desde la óptica de la TSDNL. Hemos empezado esta línea de investigación dirigida a la situación que podría parecer menos compleja en el sentido de escoger entre las fases de vigilia-sueño profundo más dispares en cuanto a características de la señal. De momento los resulta-

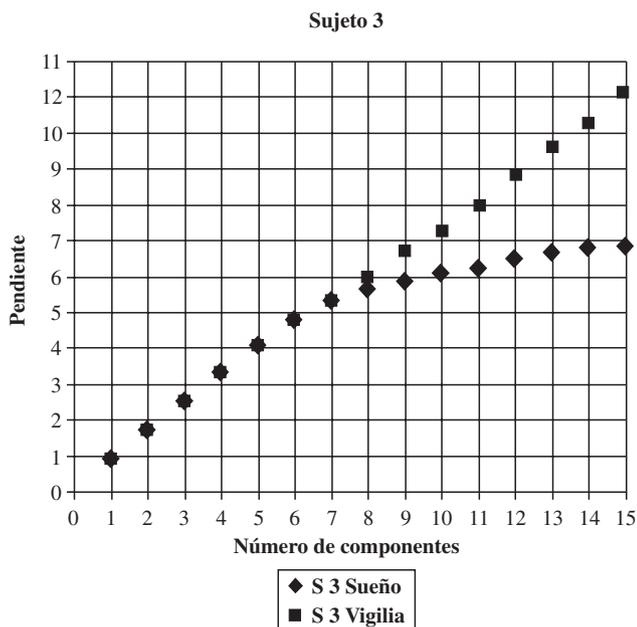


Figura 3. Resultados obtenidos con los datos del Sujeto 3 donde se aprecian las diferencias en la señal EEG entre las fases de vigilia-sueño profundo

dos son prometedores pero no cabe duda de que la muestra utilizada es limitada. Por otro lado, en un futuro próximo queremos añadir una nueva comparación, estudiando la dimensionalidad en fase REM (sueño paradójico), donde la señal de EEG se aproxima a la registrada en estados de vigilia a nivel de inspección visual. Su estudio nos permitiría observar si ambas señales podrían implicar diferencias en su naturaleza a pesar de su proximidad visual.

Agradecimientos

El tratamiento de los datos ha sido posible gracias a Ariadna Jacomet participando en la creación de las distintas ventanas de registro. El grupo de investigación consolidado de la Generalitat de Catalunya *Neurodinámica cognitiva y de los trastornos mentales* (NECOM) ha aportado parte de la infraestructura necesaria para realizar este trabajo. La recogida de datos ha sido financiada en el marco del proyecto Europeo SENSATION SGR2005-00831.

Referencias

- Abarbanel, H.D.I. (1996). *Analysis of observed chaotic data*. New York: Springer-Verlag.
- Bascompte, J. (1995). Buscant l'ordre ocult dels sistemes biològics. En J. Bascompte y J. Flos (Eds.): *Ordre i caos en ecologia* (pp. 313-170). Barcelona: Publicacions Universitat de Barcelona.
- Casdagli, M. (1991). Chaos and deterministic versus stochastic non-linear modelling. *Journal of the Royal Statistical Society B*, 54(2), 303-328.
- Coenen, A.M.L. (1998). Neuronal phenomena associated with vigilance and consciousness: From cellular mechanisms to electroencephalographic patterns. *Consciousness and Cognition*, 7(1), 42-53.
- Fraser, A.M., y Swinney, H.L. (1986). Independent coordinates for strange attractors from mutual information. *Physical Review A*, 33(2), 1134-1140.
- Grassberger, P., y Procaccia, I. (1983a). Characterization of strange attractors. *Physical Review Letters*, 50(5), 346-349.
- Grassberger, P., y Procaccia, I. (1983b). Measuring the strangeness of strange attractors. *Physica D*, 9, 189-208.
- Hegger, R., Kantz, H., y Schreiber, T. (1999). Practical implementation of nonlinear time series methods: The TISEAN package. *CHAOS* 9(2), 413-435.
- Rechtschaffen, A., y Kales, A. (1968). *A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects*. Los Angeles: UCLA Brain Information Service/Brain Research Institute.
- Siegel, S., y Castellan, N.J.J. (1988). *Nonparametric statistics for the 21 behavioural sciences (2ª ed.)*. McGraw-Hill Book Company.
- Solé, R.V., y Manrubia, S.C. (1996). *Orden y caos en sistemas complejos*. Barcelona: Edicions UPC.
- Stam, C.J. (2005). Nonlinear dynamical analysis of EEG and MEG: Review of an emerging field. *Clinical Neurophysiology*, 116, 2266-2301.
- Sugihara, G., y May, R.M. (1990). Nonlinear forecasting as a way of distinguishing chaos from measurement error in time series. *Nature*, 344, 734-741.