



PREDICCIÓN DE SERIES DE TIEMPO ALTAMENTE NO LINEALES USANDO REDES NEURONALES RECURRENTE

 *Coordinación de
Ciencias Computacionales*

Dra. María del Pilar Gómez Gil
Coordinación de Computación
Instituto Nacional de Astrofísica, Óptica y Electrónica
Tonantzintla, Puebla.

13 de Junio 2012
Instituto de Física
Universidad Autónoma de Puebla (IFUAP).

Esta presentación está disponible en: <http://ccc.inaoep.mx/~pgomez/IFBUAP-12.pdf>

CONTENIDO:

- ⊙ Introducción
- ⊙ Predicción de Series de tiempo
- ⊙ Redes Neuronales Artificiales para predecir
- ⊙ Perspectivas

INTRODUCCIÓN

- ⊙ El pronóstico de series de tiempo ha sido de fuerte interés en los últimos años, debido a la gran variedad de aplicaciones en que se necesita.
- ⊙ Algunas estrategias de predicción buscan aproximar un modelo a un sistema dinámico analizando solamente la información contenida en una serie de tiempo, suponiendo que ésta es suficientemente detallada para contener toda la información requerida.
- ⊙ Este un problema complejo cuando se intenta aplicar sobre sistemas altamente no lineales o caóticos.

SISTEMAS DINÁMICOS NO LINEALES

- ⊙ Pueden ser representados como:

$$\frac{d\mathbf{y}(t)}{dt} = \mathbf{F}(\mathbf{y}(t)), \quad \mathbf{y}(t) = [y_1(t), y_2(t), \dots, y_d(t)],$$
$$\mathbf{y}(0) = \mathbf{y}_0.$$

- ⊙ El campo vectorial \mathbf{F} es no lineal; d es la dimensión del sistema
- ⊙ Esta ecuación describe el movimiento de un punto en un espacio de estado d -dimensional, conocido como espacio de fase

PREDICCIÓN DE SERIES DE TIEMPO (1/2)

- ⊙ Consiste en estimar valores futuros de una serie utilizando valores pasados.
- ⊙ Hay 2 tipos fundamentales: predicción a un paso (o a corto plazo) y predicción a largo plazo.
- ⊙ Si no se consideran variables exógenas , la predicción a corto plazo se puede definir como:

$$\hat{x}_n = \varphi(x_{n-1}, x_{n-2} \dots x_{n-p})$$

PREDICCIÓN DE SERIES DE TIEMPO (2/2)

- ⊙ Predicción a largo plazo puede definirse como:


$$\hat{x}_{n+h} \dots \hat{x}_{n+1}, \hat{x}_n = \Phi(x_{n-1}, x_{n-2} \dots x_{n-p})$$

donde h se conoce como el horizonte de predicción.


- ⊙ La predicción a largo plazo también puede obtenerse aplicando recursivamente predicción a un paso, alimentando al predictor con valores previamente calculados por él mismo.

TIPOS DE PREDICCIÓN

- *Predicción de un paso, o de “siguiente valor”*




- *Predicción recursiva de largo plazo*




REDES NEURONALES ARTIFICIALES

- ⊙ Una red neuronal artificial es un procesador paralelo y distribuido, hecho de varios procesadores simples, que puede almacenar y utilizar conocimiento adquirido de la experiencia (Haykin 2009)¹.
- ⊙ Están inspiradas en el diseño del cerebro y en las neuronas biológicas.
- ⊙ Son modelos matemáticos capaces de adaptar su comportamiento en respuesta a ejemplos presentados por el medio ambiente de manera supervisada o no supervisada (**aprendizaje basado en ejemplos**)

EL CONTEXTO DE REDES NEURONALES



EL COMPONENTE FUNDAMENTAL: NEURONA




Las variables w_i son valores reales que contienen el conocimiento de la red neuronal


TOPOLOGÍAS PRINCIPALES DE REDES NEURONALES ARTIFICIALES

- ⊙ Redes de un nivel
- ⊙ Redes de Varios niveles
- ⊙ Redes Recurrentes

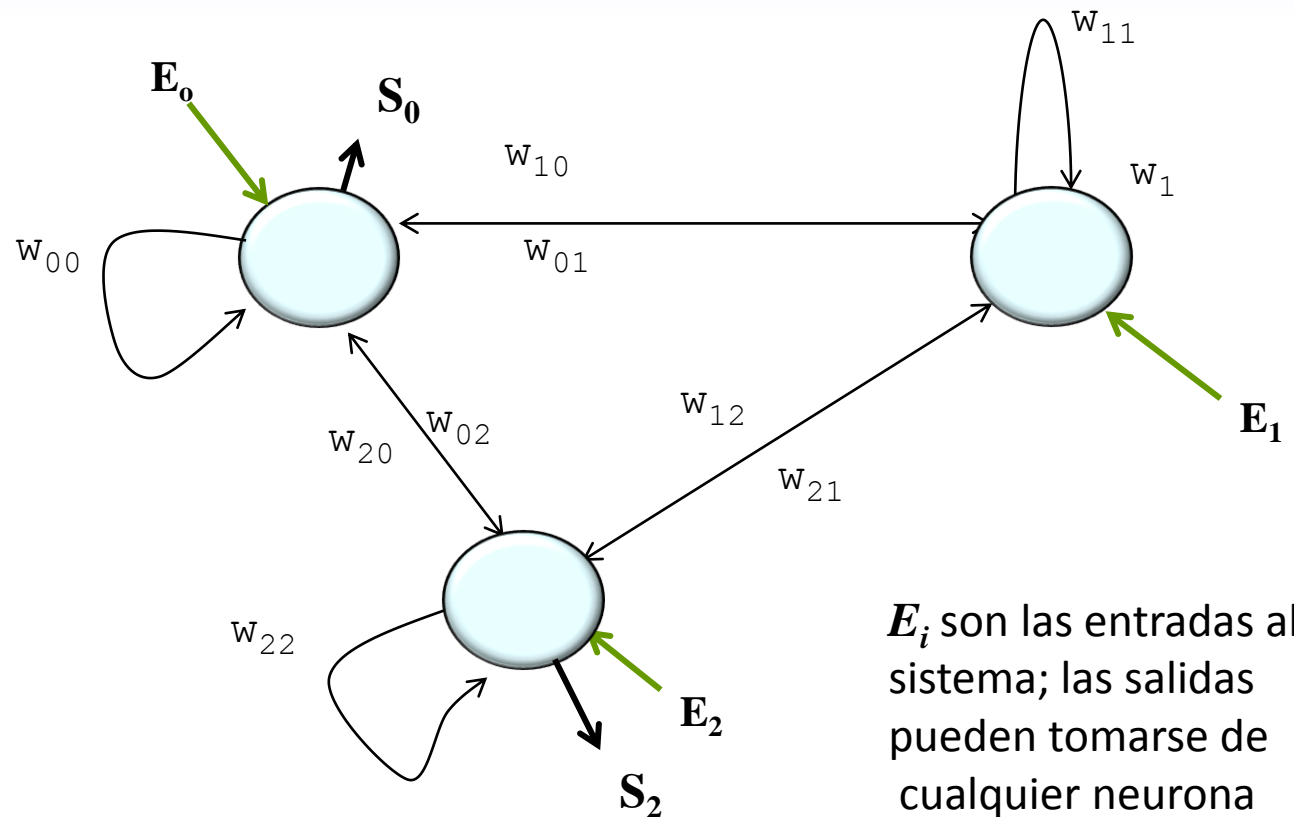
REDES DE UN NIVEL



REDES DE VARIOS NIVELES



REDES RECURRENENTES



LAS REDES NEURONALES RECURRENTES..

- ⊙ Son sistemas dinámicos en sí mismas,
- ⊙ Pueden oscilar de manera acotada,
- ⊙ Tienen algoritmos de entrenamiento muy difíciles de ajustar y controlar,
- ⊙ ... pero tienen un potencial importante en la investigación sobre predicción a largo plazo y sobre caos

Según Kaplan y Cohen (1990), algunas características distintivas de caos son:


- ② Las trayectorias caóticas son aperiódicas y determinísticas,
- ② Los sistemas caóticos son extremadamente dependientes de las condiciones iniciales. Por lo tanto, pequeñas variaciones en las condiciones iniciales del sistema, harán que cambie de forma exponencial después de un determinado avance en la trayectoria,
- ② El comportamiento caótico está acotado por atractores extraños. Un **atractor** es el conjunto de puntos hacia los que se dirige una trayectoria cuando el estado transitorio del sistema termina.

EJEMPLO DE UN SISTEMA CAÓTICO


- ⊙ Hay sistemas caóticos cuyo comportamiento es conocido y está claramente definido a través de ecuaciones. Por ejemplo, la ecuación Mackey-Glass (Glass 1987) que se usa para modelar el comportamiento de algunos sistemas biológicos

$$\frac{dx(t)}{dt} = \frac{ax(t - \tau)}{1 + x^{10}(t - \tau)} - bx(t)$$

SERIE MACKEY-GLASS




MAPA DE RETORNO DE LA SERIE MACKEY-GLASS



SERIES DE TIEMPO CAÓTICAS

- ⊙ Muchos sistemas físicos, biológicos y sociales presentan un comportamiento caótico, pero desconocemos las ecuaciones que los describen. Algunos ejemplos son: la presión sanguínea, los latidos del corazón, el clima o el comportamiento de la bolsa de valores.
- ⊙ Sería de gran utilidad en varios campos del conocimiento el poder predecir el comportamiento de señales caóticas a largo plazo.



LA RED NEURONAL HIBRIDA COMPLEJA [GÓMEZ 1999]

- ⊙ Conocida como HCNN (*Hybrid Complex Neural Network*) y propuesta originalmente en (Gómez 1999)
- ⊙ Está basada en pequeñas redes de 3 nodos, totalmente conectadas y recurrentes, llamadas *generadores armónicos*, capaces de aprender y generar funciones seno indefinidamente y de manera autónoma.
- ⊙ Los generadores armónicos se conectan a otros neurones, a través de conexiones hacia adelante y recurrentes (de allí el nombre de híbrida)
- ⊙ El modelo incluye un mecanismo para obtener cierta información relacionada con la dinámica caótica de la señal de entrenamiento

DINÁMICA DE CADA NEURÓN

$$\frac{dy_i}{dt} = -y_i + \sigma(x_i) + I_i$$

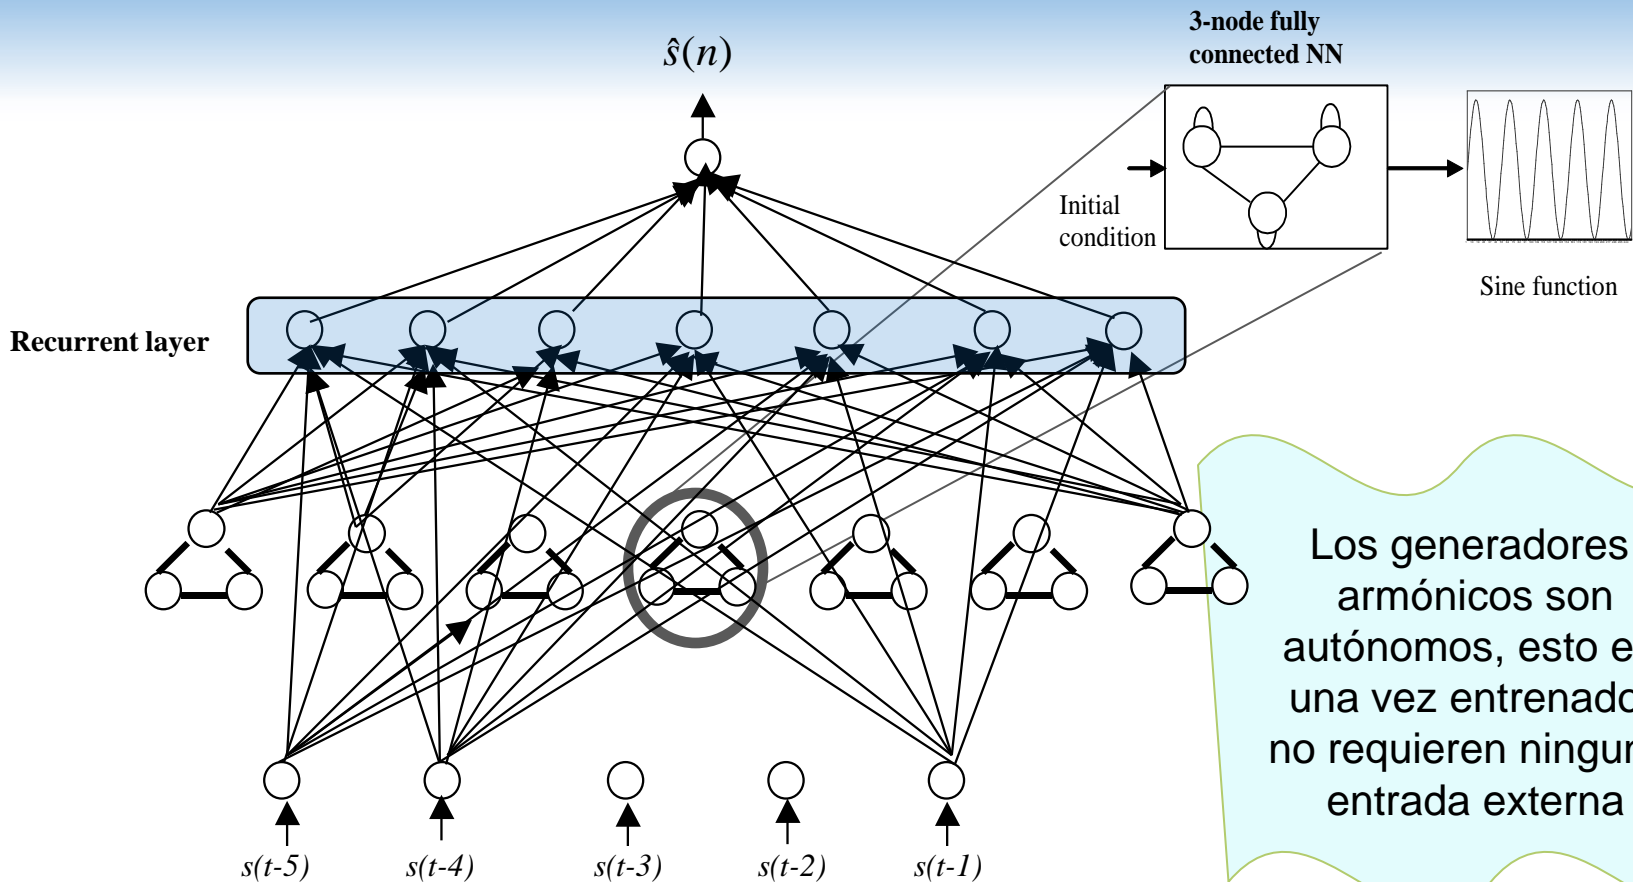
$$x_i = \sum_j w_{ji} y_j$$

Aproximada como:

$$y_i(n+1) = (1-\eta)y_i(n) + \eta\sigma(x_i(n)) + \eta I_i(n)$$

$$x_i(n) = \sum_{j=1}^m y_j(n)w_{ji}$$


TOPOLOGÍA DE UNA HCNN




Los generadores armónicos son autónomos, esto es, una vez entrenados no requieren ninguna entrada externa

SEÑAL ORIGINAL Y PREDICHA

Case K.2




CLOSE-UP DE LA SEÑAL PREDICHA

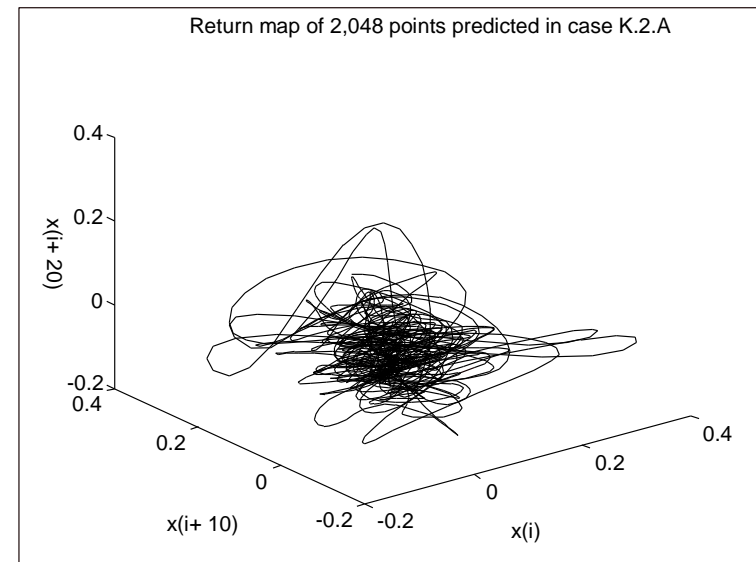


COMPARACIÓN DE MAPAS DE RETORNO

Embedding of the ECG Amplitude with lag = 10



Señal Original



Señal predicha


FORTALEZAS Y DEBILIDADES DE HCNN (GÓMEZ & RAMÍREZ 2006)

- ⊙ Las redes HCNN con capaces de oscilar de manera estable, y de generar señales caóticas (con exponentes de Lyapunov positivos) que semejan a un ECG “sin picos”
- ⊙ Las redes entrenadas no pudieron aprender completamente la magnitud de la señal ni la fase de manera exacta.


LA RED HWRN

- ⊙ Propuesta originalmente en (García-Pedrero 2009)
- ⊙ Es una red de conexiones híbridas basada en señales reconstruídas a través de funciones wavelets, de ahí su nombre HWRN (**H**ybrid and based-on-**W**avelet-**R**econstructions **N**etwork)
- ⊙ Contiene 3 fases de entrenamiento;
 1. Pre-procesamiento de la señal de entrenamiento y generación de señales reconstruídas
 2. Entrenamiento de subredes totalmente recurrentes
 3. Entrenamiento del modelo completo

ARQUITECTURA DE LA HWRN (GARCÍA-PEDRERO 2009)



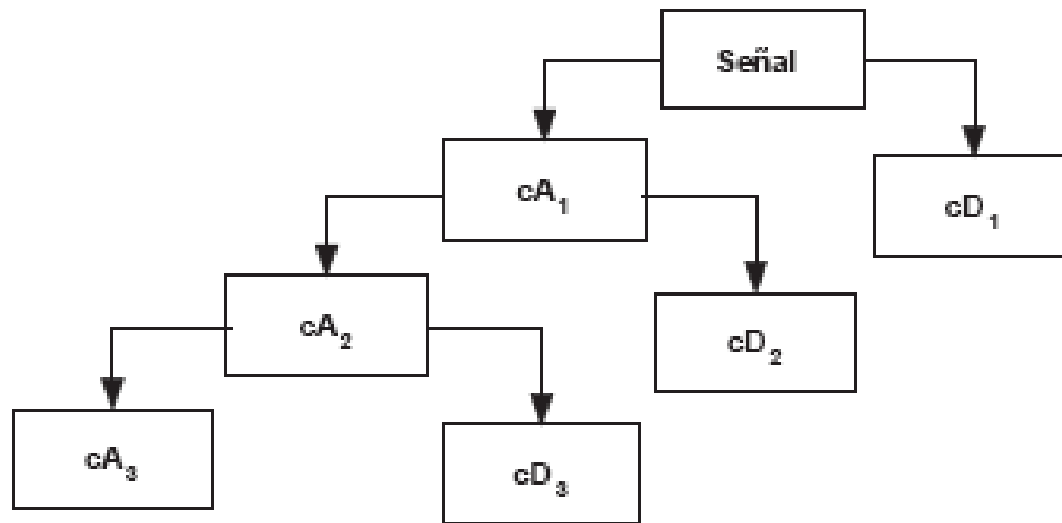
EJEMPLO DE UNA SERIE FINANCIERA: NN5-001 (CRONE 2006)




DESCRIPCIÓN GENERAL DEL MODELO

1. La señal de entrenamiento se descompone utilizando el método de multi-escala de la transformada discreta Wavelet (DWT) basado en filtros
2. Los coeficientes wavelet resultantes se utilizan para generar cuatro señales, una de aproximación y 3 de detalle , de éstas se seleccionan las 3 mas representativas
3. Estas señales se utilizan para que sean autónomamente reproducidas por pequeñas redes recurrentes totalmente conectadas (SRNN)
4. Una vez entrenadas, las SRNN son insertadas en la arquitectura completa, y todo el sistema se entrena usando la señal original


ÁRBOL DE DESCOMPOSICIÓN WAVELET A 3 NIVELES




EJEMPLO DE SEÑALES RECONSTRUIDAS USANDO WAVELETS (SERIE NN5-001)




Señal de Aproximación mas general



Señal de detalle mas general




Señal de detalle a nivel 2



Señal de detalle a nivel 3

ARQUITECTURA DE LA HWRN (GARCÍA-PEDRERO 2009)



PROMEDIO DE DESEMPEÑO DE HWRN Y OTRAS ARQUITECTURAS


Series	Métrica	Arquitectura Neuronal		
		Feed-forward	Recurrente	HWRN
Once Series del conjunto NN5	MSE	250.12 ± 226.05	198.69 ± 131.12	34.05 ± 20.12
	SMAPE	49.28% ± 12.36	60.75% ± 13.05	27.22% ± 8.27
	MASE	517.50 ± 1,079.68	546.31 ± 1,218.95	194.99 ± 387.22

$$MSE = \frac{1}{n} \sum_{t=1}^n (s_t - \hat{s}_t)^2$$

$$SMAPE = \frac{1}{N} \sum_{n=1}^N \left(\frac{|s_n - \hat{s}_n|}{(s_n + \hat{s}_n)/2} \right) (100\%)$$

$$MASE = \frac{1}{N} \sum_{s=1}^N \left| \frac{s_n - \hat{s}_n}{\frac{1}{N-1} \sum_{i=2}^N |s_n - \hat{s}_{n-1}|} \right|$$

MEJOR CASO DE PREDICCIÓN DE LA HWRN SOBRE *BENCHMARK SERIES NN5*



FUTURO DE LA PREDICCIÓN



- ⊙ Según Smith (2000), hay 3 factores importantes que actualmente limitan nuestra capacidad de predecir
 - ⊙ Modelado del error
 - ⊙ Observaciones inciertas de las condiciones iniciales
 - ⊙ Poder computacional (aún!)
- ⊙ De éstos, el modelado del error parece ser el problema principal
- ⊙ Los sistemas basados en redes recurrentes pueden ofrecer una manera de “aprender de errores” y ajustar los modelos
- ⊙ Se requiere investigar sobre mejores algoritmos de entrenamiento y topologías más eficientes

CONCLUSIONES

- ⊙ Existe una importante necesidad de modelar lo mejor posible sistemas dinámicos altamente no lineales o caóticos.
- ⊙ Las redes neuronales artificiales recurrentes con arquitecturas especializadas han mostrado los mejores resultados para predicción a largo plazo de series caóticas
- ⊙ Aún existen problemas para su uso, debido a los tiempos de entrenamiento involucrados

PARA SABER MAS...

- © **2011.** Gómez-Gil P, Ramírez-Cortés JM, Pomares Hernández SE, Alarcón-Aquino V. “A Neural Network Scheme for Long-term Forecasting of Chaotic Time Series” Neural Processing Letters. Vol.33, No. 3, June 2011. pp 215-233. Published online: March 8, 2011. DOI: 10.1007/s11063-011-9174-0 (cited at JCR Science Edition—2009). *(preliminary PDF)*
- © **2007.** Gómez-Gil, P. “Long Term Prediction, Chaos and Artificial Neural Networks. Where is the meeting point?” Engineering Letters. Vo. 15, Number 1. August 2007. ISSN: 1816-0948 (online version), 1816-093X (printed version).
- © **2010.** Gómez-Gil P, Mendoza-Velázquez A. “Redes Neuronales Artificiales para calificar la capacidad de crédito de entidades Mexicanas de Gobierno”. *Komputer- Sapiens* Año 2, Vol. 2 Junio-Diciembre 2010, pp. ISSN 2007-0691.

Esta presentación está disponible en: <http://ccc.inaoep.mx/~pgomez/IFBUAP-12.pdf>



Gracias por su atención!

pgomez@inaoep.mx
ccc.inaoep.mx/~pgomez

Esta presentación está disponible en: <http://ccc.inaoep.mx/~pgomez/IFBUAP-12.pdf>

- © Crone S.F.: NN5 forecasting competition for artificial neural networks & computational Intelligence.” Available at: <http://www.neural-corecasting-competition.com/>. Last consulted at March 2009 (2008)
- © García-Pedrero, A. Arquitectura Neuronal Apoyada en Señales Reconstruidas con Wavelets para predicción de Series de Tiempo Caóticas (A neural architecture supported by wavelet’s reconstructed signals for chaotic time series prediction). Master Thesis (in Spanish), Computational Department, National Institute of Astrophysics, Optics and Electronics (2009)
- © García-Pedrero, A and P. Gómez-Gil. “Time Series Forecasting using Recurrent Neural Networks and Wavelet Reconstructed Signals”. Proceedings of the 20th. IEEE International Conference on Electronics, Communications and Computers. CONIELECOMP 2010. Puebla

- ⊙ Gomez-Gil, P, Ramírez-Cortés M. “Experiments with a Hybrid-Complex Neural Networks for Long Term Prediction of Electrocardiograms.” IEEE Proc. of the 2006 International Word Congress of Computational Intelligence, IJCNN 2006.
- ⊙ Gómez-Gil, P. [“Long Term Prediction, Chaos and Artificial Neural Networks. Where is the meeting point?”](#) Engineering Letters. Vo. 15, Number 1. August 2007. ISSN: 1816-0948 (online version), 1816-093X (printed version).
- ⊙ Glass, Leon. “Complex Cardiac Rhythms,” Nature, Vol. 330, No. 24/31, pp. 695-696, December 1987.
- ⊙ Haykin, Simon. Neural Networks and Learning Machines. Pearson, Upper Saddle River, 2009.
- ⊙ Kaplan, Daniel T. and Richard J. Cohen. “Is Fibrillation Chaos?” Circulation Research, Vol. 67, No. 4, October 1990.
- ⊙ Smith, L.A. “Limits to Predictability in 2000 and 2100.” Adaptive Systems for Signal Processing, Communications and Control Symposium 2000. AS-SPCC. The IEEE. 2000. pp. 129-134.