



PREDICCIÓN A LARGO PLAZO DE SERIES DE TIEMPO ALTAMENTE NO LINEALES USANDO INTELIGENCIA COMPUTACIONAL



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

Departamento de Computación
CIMAT
29 de Mayo 2015

Esta presentación está disponible en:
<http://ccc.inaoep.mx/~pgomez/conferences/PggCIM15.pdf>

- ① Introducción
- ① Retos de la predicción de series de tiempo no lineales
- ① Herramientas basadas en Redes Neuronales Artificiales
- ① Nuestros modelos
- ① Perspectivas

EL INAOE, MI CENTRO DE TRABAJO

Ubicación de los Centros de Investigación Conacyt

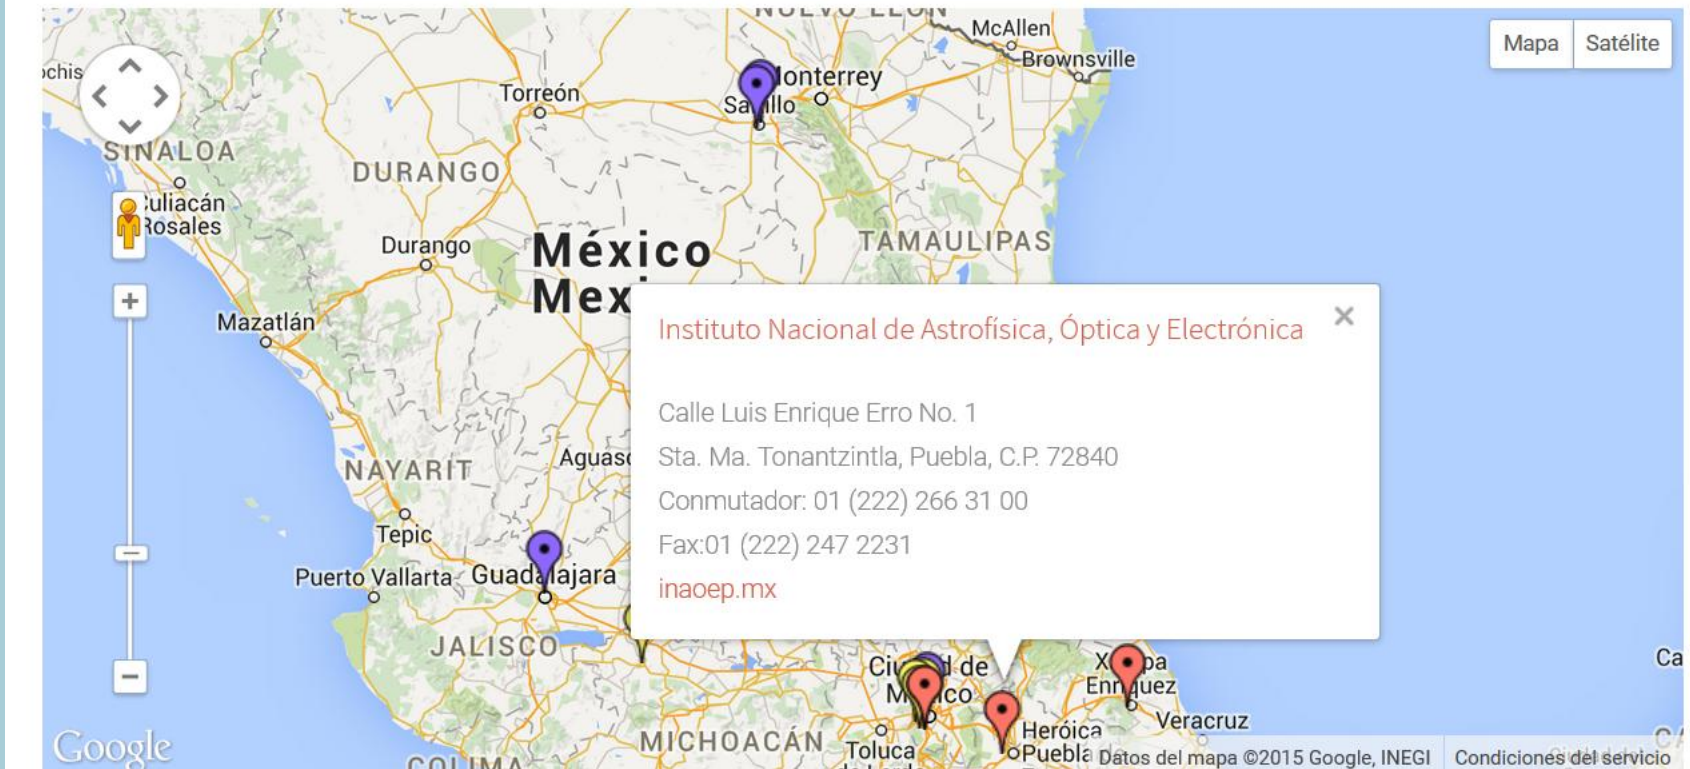


Imagen tomada de: <http://www.conacyt.gob.mx/index.php/el-conacyt/centros-de-investigacion-conacyt>

EL CIMAT, HERMANO DE MI CENTRO DE TRABAJO

Ubicación de los Centros de Investigación Conacyt



Imagen tomada de: <http://www.conacyt.gob.mx/index.php/el-conacyt/centros-de-investigacion-conacyt>

CARACTERÍSTICAS DE MI INVESTIGACIÓN

OBJETO DE ESTUDIO	AREAS DEL CONOCIMIENTO	AREAS DE APLICACIÓN
<p>DATOS:</p> <ul style="list-style-type: none"> • ruidosos • con clases sobrepuestas • muy pocos • difíciles de caracterizar • se requieren fusionar • etcétera... 	<ul style="list-style-type: none"> • Clasificación estática • Clasificación temporal • Predicción • Teoría y diseño de Redes Neuronales Artificiales 	<ul style="list-style-type: none"> • Reconocimiento de escritura • Interfaces Humano – Computadora (BCI) • Biométrica • Diagnóstico médico • Economía y Finanzas • Astrofísica • <i>Mobile Phone sensing</i> • etcétera...

SOBRE ESTA PLATICA...

- ③ El proyecto esbozado aquí, gira alrededor de la construcción de sistemas basados en redes neuronales artificiales, capaces de aproximar el modelado de sistemas dinámicos.
- ③ Con esta aproximación, se estiman varios valores futuros de series de tiempo altamente no lineales.

SERIE DE TIEMPO

- ⊙ Conjunto de valores escalares, obtenidos del sensado de un fenómeno continuo en periodos de tiempo regulares, u obtenido de un fenómeno inherentemente discreto.

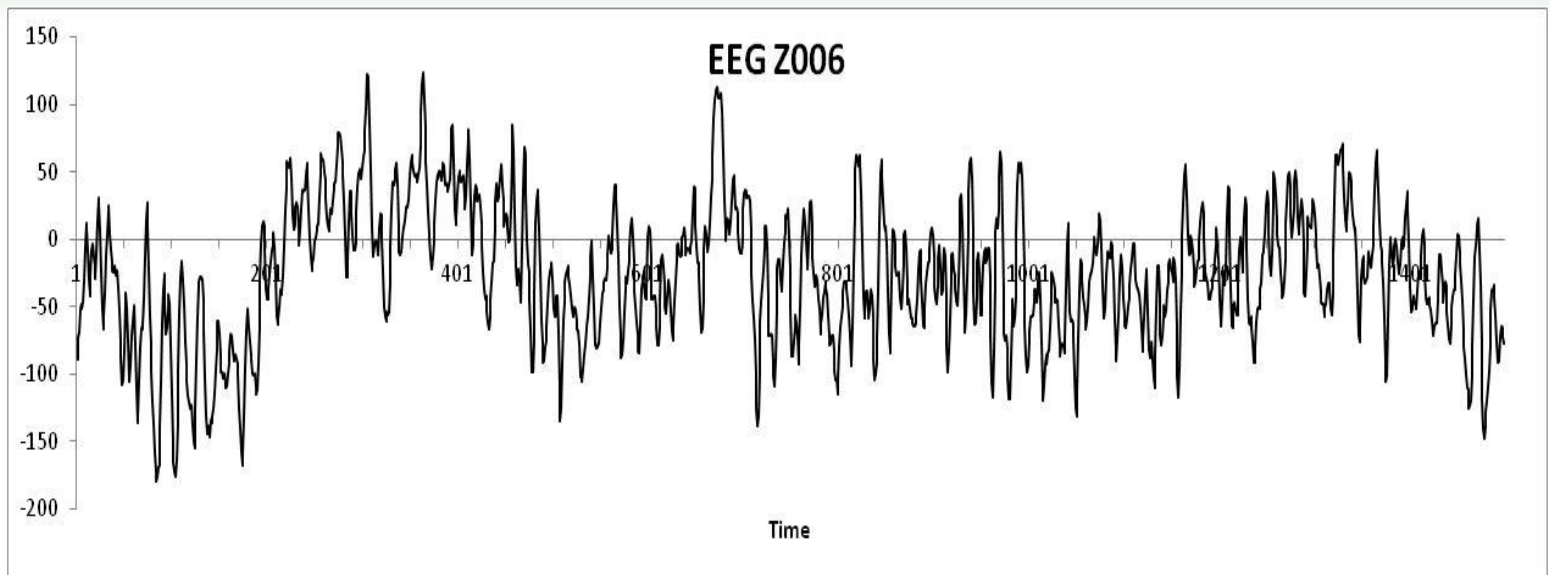
- ⊙ Una serie de tiempo comúnmente se representa como:

$$\{s_1, s_2, s_3 \dots\} \quad \text{ó}$$

$$s(1), s(2), s(3) \dots$$


- ⊙ Llamamos “series de tiempo no lineales” a aquellas que suponemos provienen de sistemas dinámicos no lineales

EJEMPLOS DE SERIES DE TIEMPO NO LINEALES (1/2)



Electro-encefalograma de una persona sana, tomado de la base de datos De la universidad de Bonn; razón de muestreo: 173 Hz (Bonn, 2003)

EJEMPLOS DE SERIES DE TIEMPO NO LINEALES (2/2)



Serie NN5-101, representando retiros diarios de cajeros automáticos en diferentes ciudades de Inglaterra, tomada de (Crone, 2008)

LA PREDICCIÓN DE SERIES DE TIEMPO

- ③ 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.
- ③ Este un problema complejo cuando se intenta aplicar sobre sistemas altamente no lineales o caóticos.
- ③ 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.

TIPOS DE PREDICCIÓN DE SERIES DE TIEMPO (1 / 3)

- ⊙ 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:

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

TIPOS DE PREDICCIÓN DE SERIES DE TIEMPO (2/3)

- ⊙ La predicción a largo plazo puede obtenerse de diferentes maneras.
- ⊙ La manera “inmediata”, la predicción a largo plazo puede definirse como:

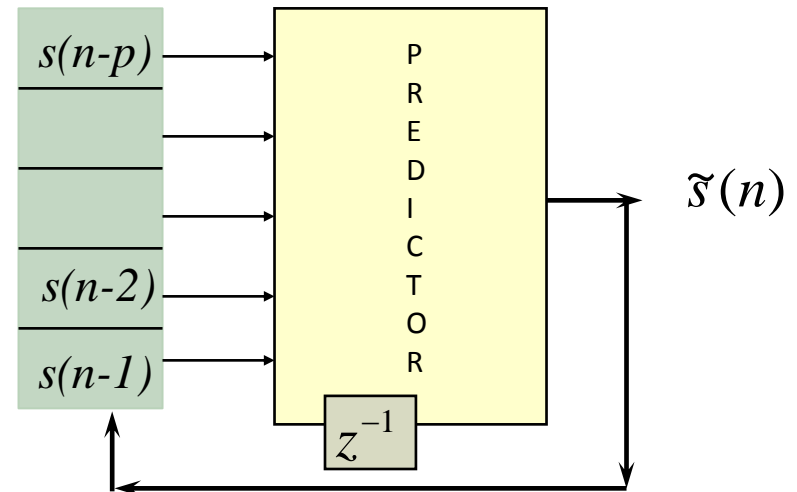

$$\tilde{s}_{n+h} \dots \tilde{s}_{n+1}, \tilde{s}_n = \Phi(s_{n-1}, s_{n-2} \dots s_{n-p})$$

h se conoce como el horizonte de predicción.

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

TIPOS DE PREDICCIÓN DE SERIES DE TIEMPO (3/3)

- *Predicción de un paso, o de “siguiente valor” (a corto plazo)*
- *Predicción recursiva de largo plazo*



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

SISTEMAS EMBEBIDOS (1 / 2)

- ⊙ El estado de un sistema dinámico que produce una señal, está formado por variables desconocidas, que pueden representarse en un vector de estado $\mathbf{x}(n)$ donde:

$$\mathbf{x}(n+1) = \mathbf{F}(\mathbf{x}(n))$$

- ⊙ Existe una regla desconocida que establece una relación entre las observaciones y las variables de estado:

$$s(n) = h(\mathbf{x}(n))$$

SISTEMAS EMBEBIDOS (2/2)

- ⊙ Para predecir los valores futuros de s , se tiene que estimar $F(\cdot)$. Para esto, se requiere crear un espacio de estados d -dimensional, de vectores que son un “proxy” del espacio desconocido $\mathbf{x}(n)$
- ⊙ De acuerdo con Takens (1981) este puede definirse como:

$$\mathbf{z}(n) = [s(n), s(n - T_L), s(n - 2T_L), \dots, s(n - (d - 1)T_L)]$$

donde T_L se conoce como “retraso de tiempo”, y permite que los componentes de $\mathbf{z}(n)$ sean independientes; d se conoce como la “dimensión embebida


INTELIGENCIA COMPUTACIONAL

- ◎ Cubre una gran cantidad de modelos, los mas comunes incluyen:
 - ◎ 1) Sistemas inspirados en la naturaleza. Ejemplos de estos son las redes neuronales artificiales y los algoritmos evolutivos
 - ◎ 2) Sistemas que representan conocimiento incierto, vago o incompleto. Ejemplos de éstos son los sistemas difusos y las redes bayesianas
- ◎ Es muy común combinar las soluciones, creando sistemas híbridos, ejemplo sistemas neuro-difusos.
- ◎ La inteligencia computacional (IC) permite trabajar con sistemas imprecisos y encontrar soluciones en tiempos razonables, aunque no exactas


LAS REDES NEURONALES ARTIFICIALES

- ⊙ Son **modelos matemáticos** capaces de adaptar su comportamiento en respuesta a ejemplos presentados por el medio ambiente de manera supervisada o no supervisada (**aprendizaje automático, basado en ejemplos**)
- ⊙ Están inspiradas en la construcción del cerebro y las neuronas biológicas.
- ⊙ 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).

EL CONTEXTO DE REDES NEURONALES



EL COMPONENTE FUNDAMENTAL: NEURONA

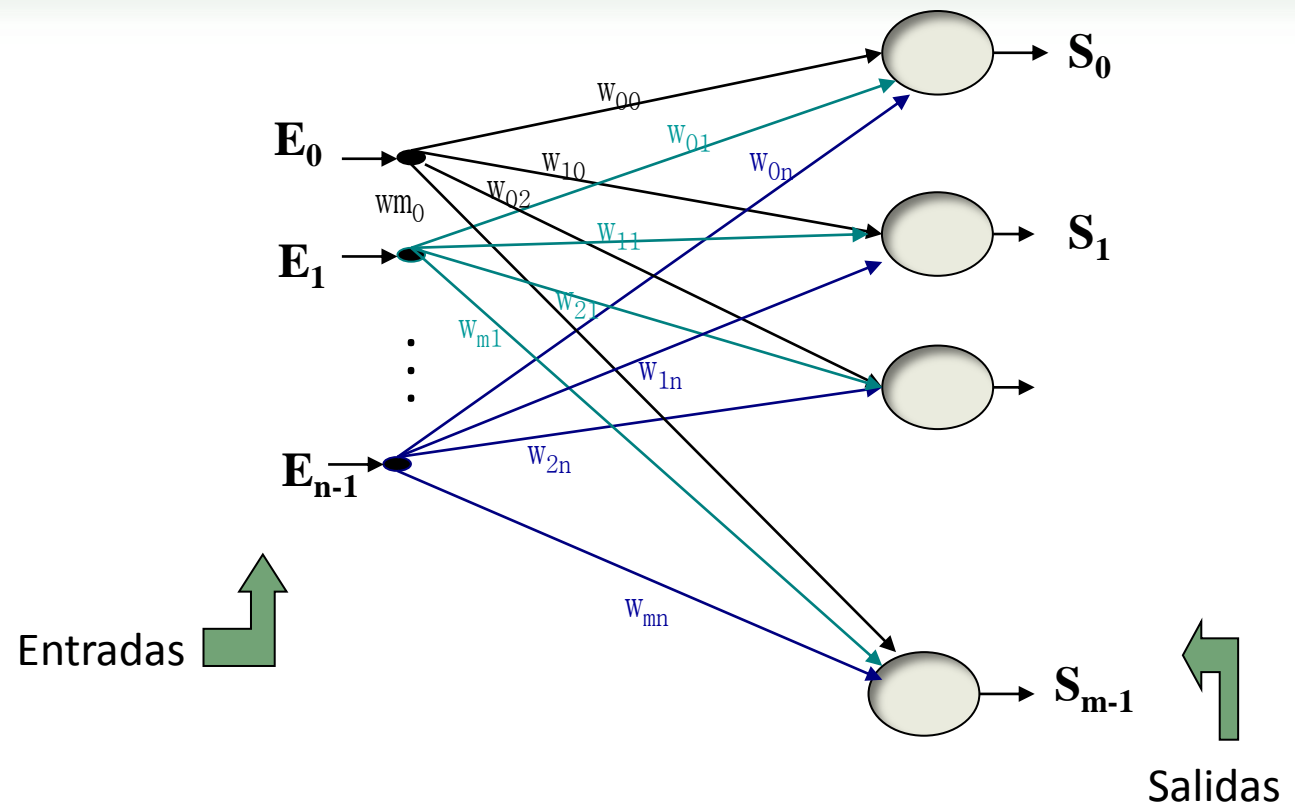


Las variables w_i son valores reales que contienen el conocimiento de la red neuronal


TOPOLOGÍAS PRINCIPALES DE REDES NEURONALES ARTIFICIALES

- ⊙ Redes de un nivel
- ⊙ Redes de varios niveles
- ⊙ Redes recurrentes


REDES DE UN NIVEL: MODELAN SISTEMAS LINEALES



REDES DE VARIOS NIVELES: MODELAN SISTEMAS NO LINEALES



REDES RECURRENTE: MODELAN SISTEMAS DINÁMICOS



E_i son las entradas al sistema; las salidas pueden tomarse de cualquier neurona

LAS REDES NEURONALES RECURRENTE

- ⊙ 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:

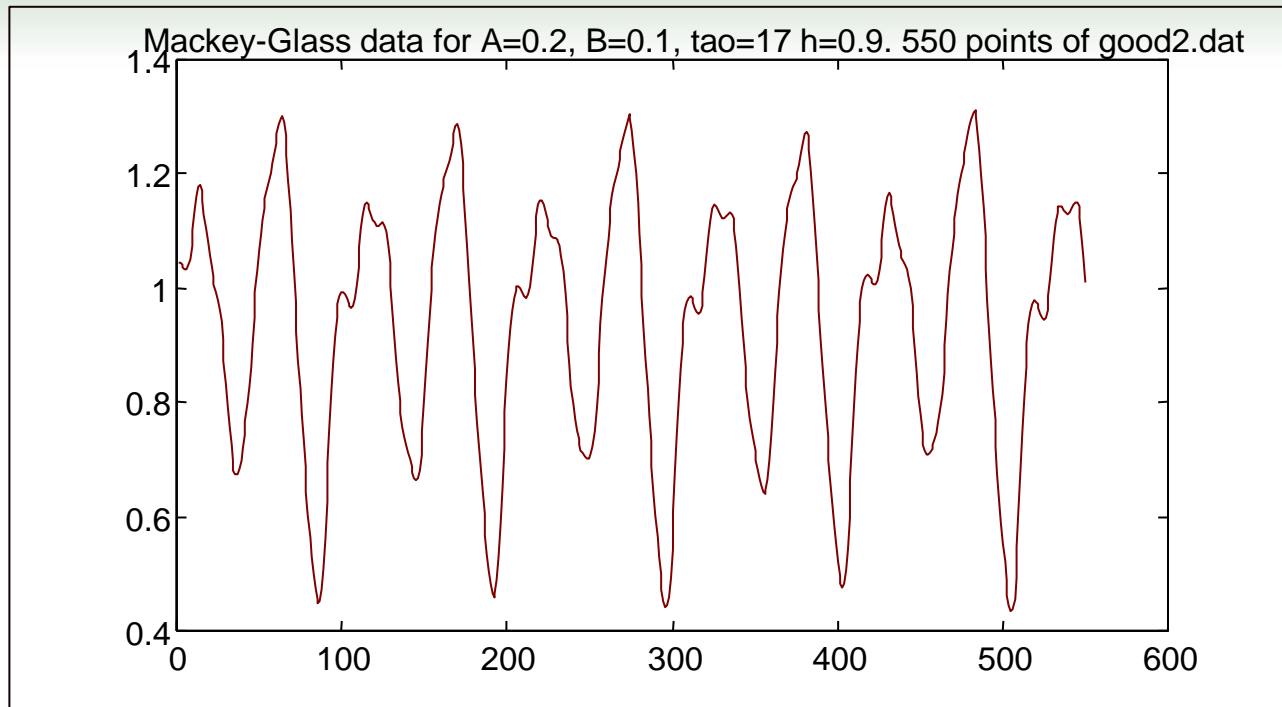
- ② Las trayectorias caóticas son aperiódicas y determinísticas,
- ② Los sistemas caóticos son extremadamente dependientes de las condiciones iniciales. Por lo tanto, pequeñas variaciones en las condiciones iniciales del sistema, harán que cambie de forma exponencial después de un determinado avance 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

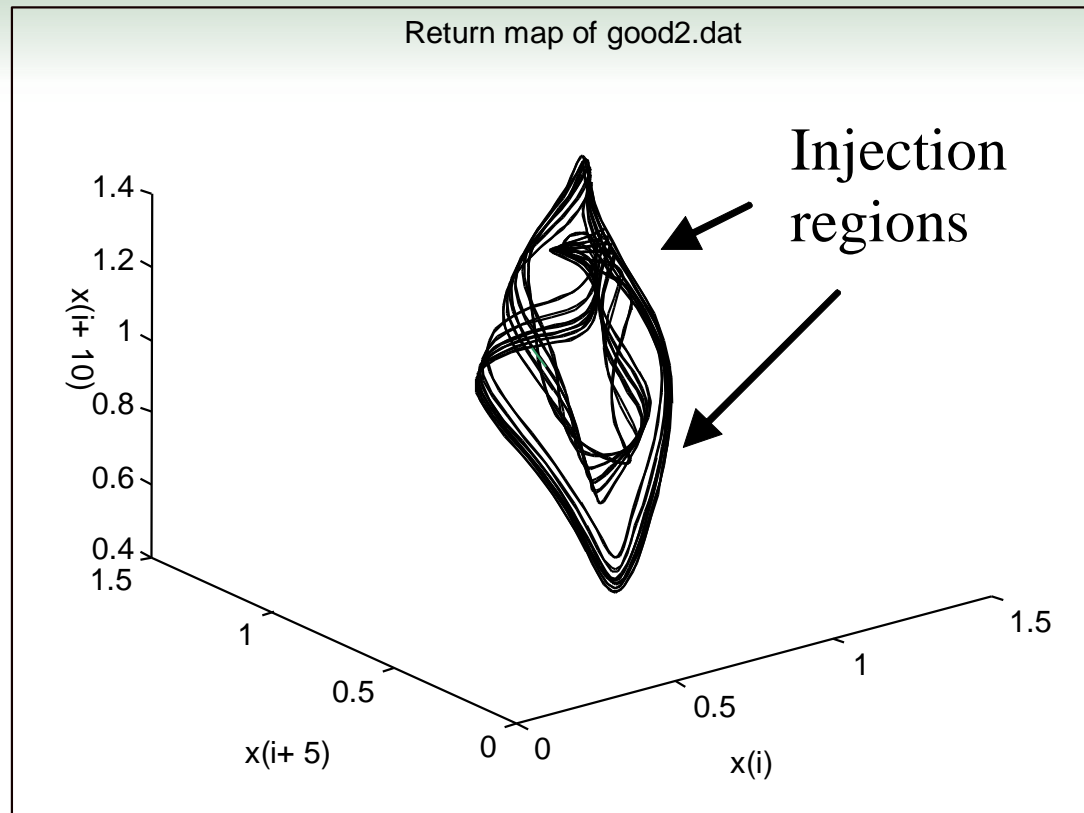
- ⊙ Hay sistemas caóticos cuyo comportamiento es conocido y está claramente definido a través de ecuaciones. Por ejemplo, la ecuación Mackey-Glass (Glass 1987) que se usa para modelar el comportamiento de algunos sistemas biológicos

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

SERIE MACKEY-GLASS

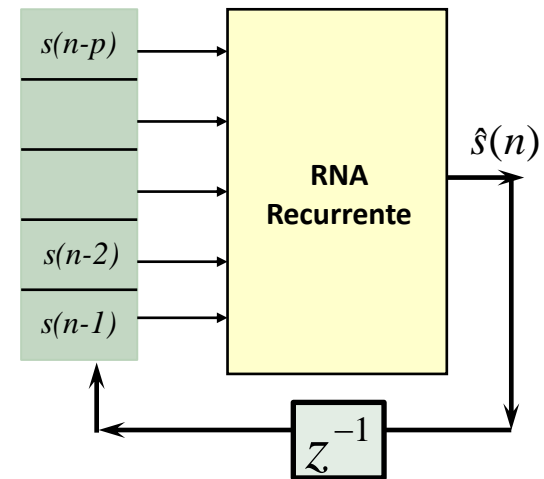


MAPA DE RETORNO DE LA SERIE MACKEY-GLASS



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.



NUESTROS MODELOS

LA RED NEURONAL HIBRIDA COMPLEJA

- ⊙ 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

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

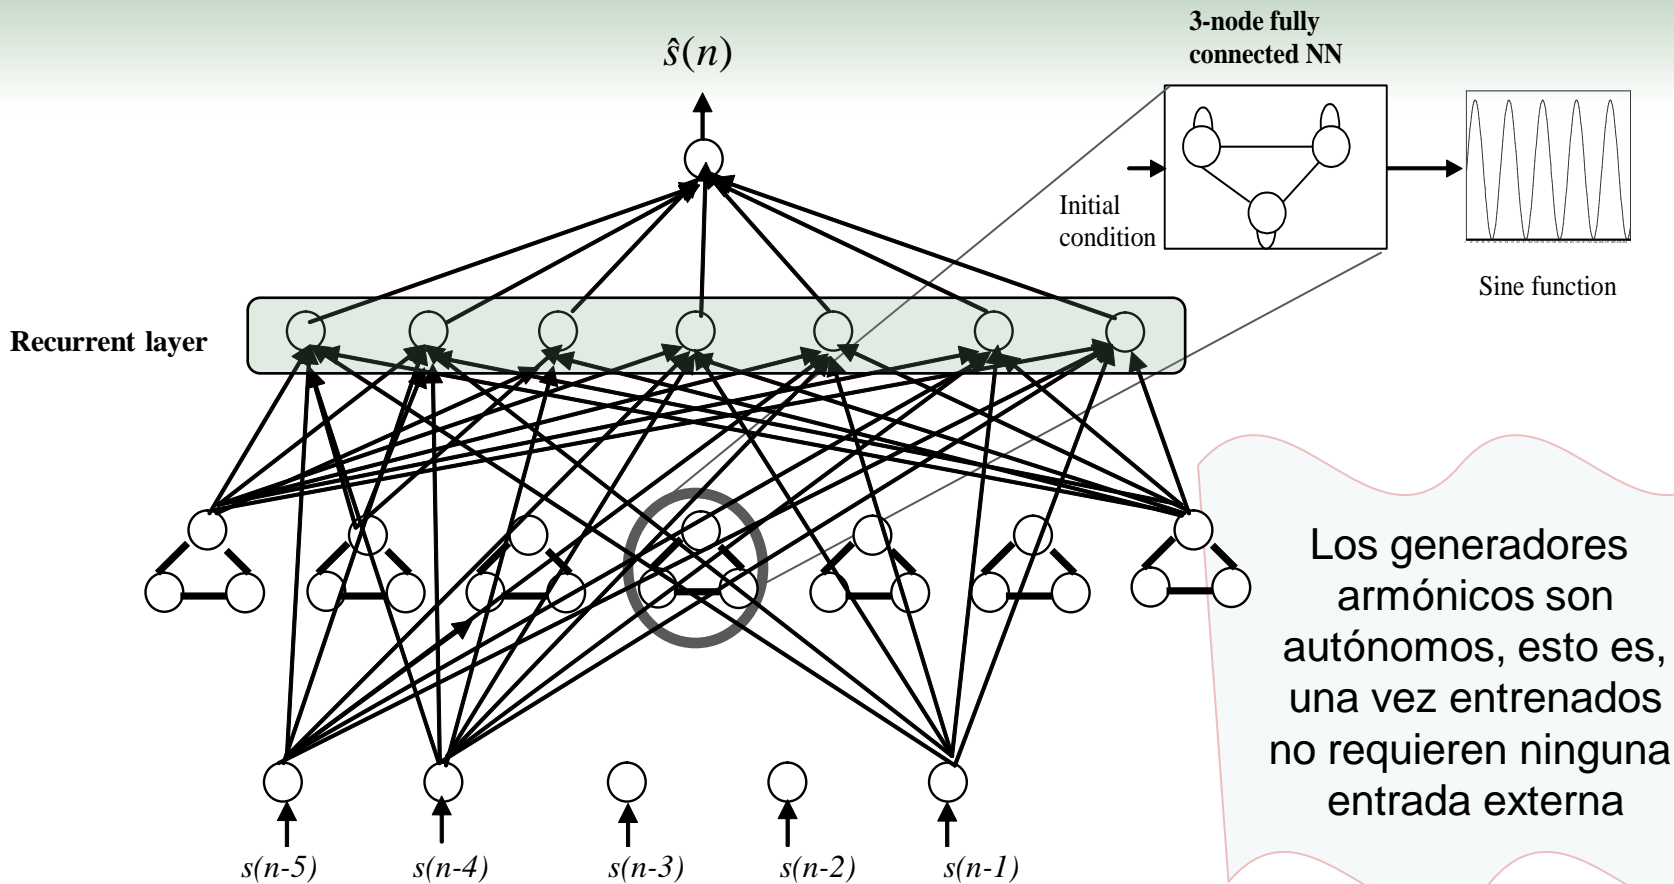
$$x_i = \sum_j w_{ji} y_j$$

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

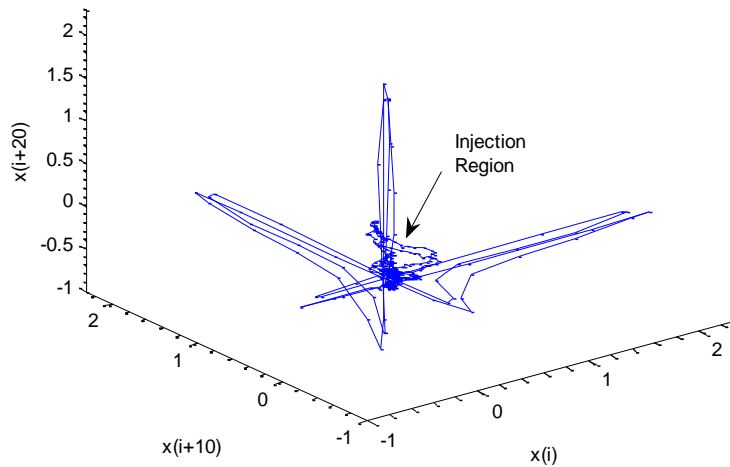


CLOSE-UP DE LA SEÑAL PREDICHA




COMPARACIÓN DE MAPAS DE RETORNO

Embedding of the ECG Amplitude with lag = 10



Señal Original



Señal predicha

FORTALEZAS Y DEBILIDADES DE LA HCNN

- ⊙ 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.

(Gómez & Ramírez 2006)


LA RED HWRN

- ⊙ Propuesta originalmente en (García-Pedrero 2009)
- ⊙ Es una red de conexiones híbridas basada en señales reconstruidas 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 reconstruidas
 2. Entrenamiento de subredes totalmente recurrentes
 3. Entrenamiento del modelo completo

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

ARQUITECTURA DE LA HWRN (GARCÍA-PEDRERO 2009)




(Gómez et al. 2010)

EJEMPLO DE UNA SERIE FINANCIERA: NN5-001




(Crone , 2008)


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




Señal de Aproximación mas general



Señal de detalle mas general

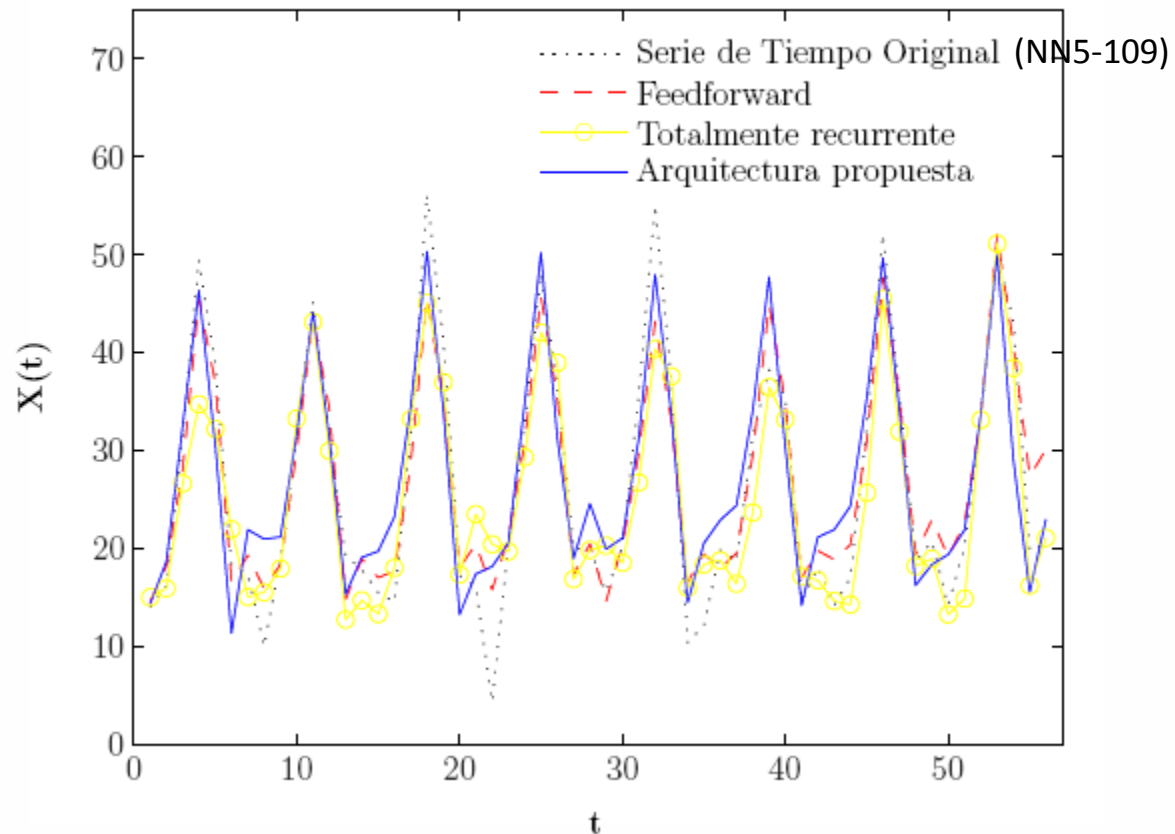


Señal de detalle a nivel 2



Señal de detalle a nivel 3

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



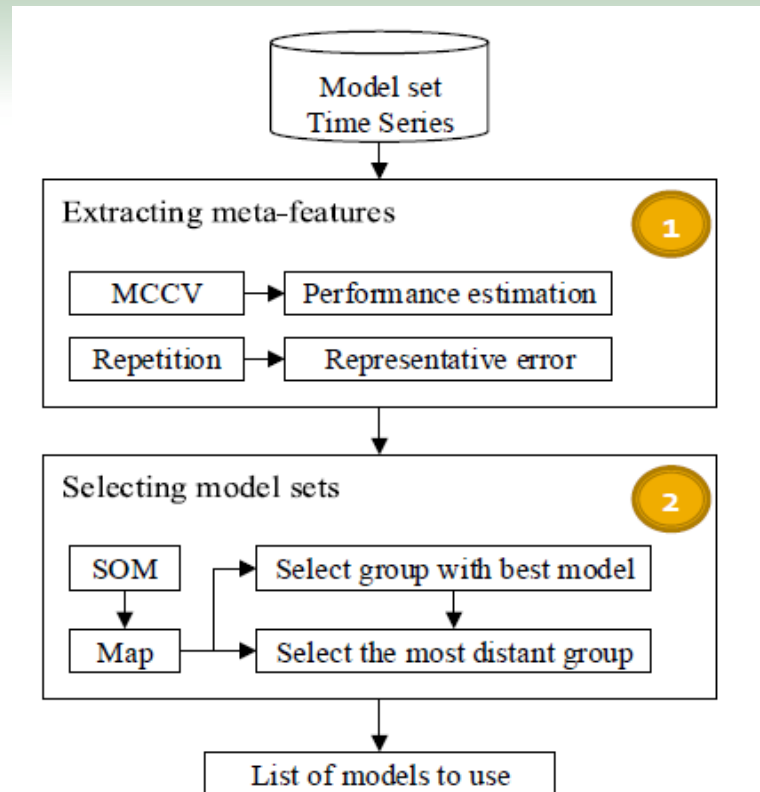
(Gómez et al. 2010)

MODELO DE PREDICCIÓN BASADO EN META-CARACTERÍSTICAS Y ENSAMBLES

- ⊙ Sistema basado en el uso de meta-aprendizaje y ensambles
- ⊙ La selección de los ensambles adecuados, se basa en un sistema de agrupamiento construido con una red SOM
- ⊙ Se definen varias heurísticas para la selección de modelos. Se entrenan varios modelos de predicción con la serie de entrenamiento.
- ⊙ Se utilizan como meta-características el desempeño de modelos y se genera un vector de errores, llamado “error representativo”

MODELO DE PREDICCIÓN BASADO EN META-CARACTERÍSTICAS Y ENSAMBLES

MCCV = Monte Carlo Cross Validation
SOM = Self Organizing Map



(Fonseca-Delgado & Gomez-Gil, 2014)

EJEMPLO DEL AGRUPAMIENTO DE MODELOS

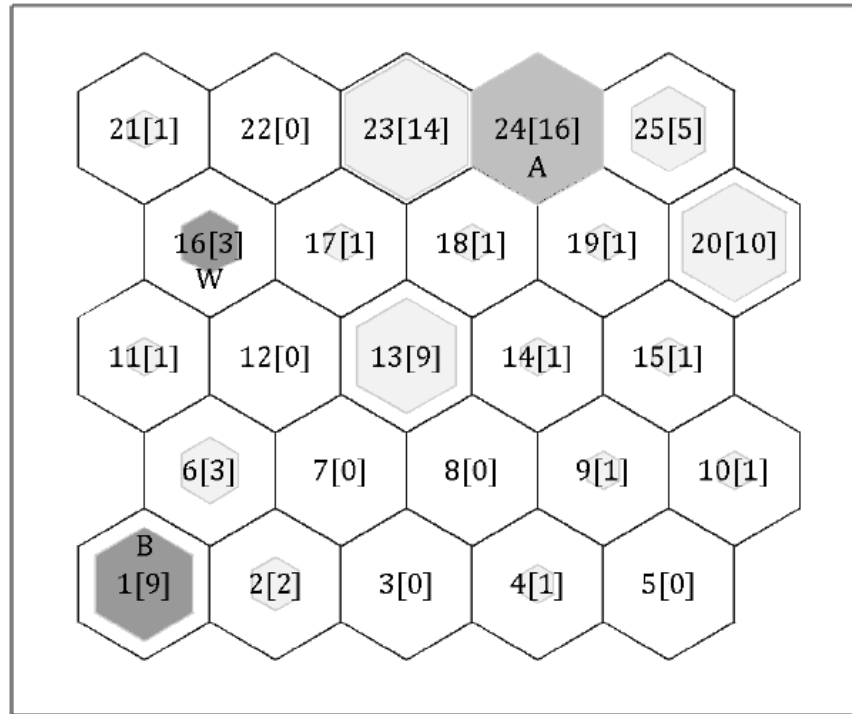


Fig. 5. SOM map with the time series 1 of the NN5 reduced set.

(Fonseca-Delgado & Gomez-Gil, 2014)

DESEMPEÑO DE DIFERENTES HEURÍSTICAS DE SELECCIÓN




Fig. 9. Performance of the proposed method for each rule, using median as combination strategy. Results of each rule are marked as: “Always” for #1, “First” for #2, “Max. 2” for #3 and “Max. 3” for #4.

(Fonseca-Delgado & Gomez-Gil, 2014)

PERSPECTIVAS



- ◎ 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



Gracias por su atención!

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

Esta presentación está disponible en:

<http://ccc.inaoep.mx/~pgomez/conferences/PggCIM15.pdf>

Página personal ->Publicaciones -> Conferencias

REFERENCIAS

- ① Universitat Bonn, Klinik für Epileptologie. EEG time series download page. URL: http://epileptologie-bonn.de/cms/front_content.php?idcat=193, Last accessed at Dec. 12, 2013.
- ① Crone S.F.: NN5 forecasting competition for artificial neural networks & computational Intelligence.” Available at <http://www.neural-forecasting-competition.com/NN5/datasets.htm> Last consulted at May 27, 2015 (2008)
- ① Fonseca-Delgado, R, Gomez-Gil, P. “Selecting and Combining Models with Self-Organizing Maps for Long-Term Forecasting of Chaotic Time Series.” Proceedings of the 2014 International Joint Conference on Neural Network (IJCNN), part of the 2014 IEEE World Congress on Computational Intelligence, July 6-11, Beijing China
- ① 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)

REFERENCIAS

- © Glass, Leon. “Complex Cardiac Rhythms,” Nature, Vol. 330, No. 24/31, pp. 695-696, December 1987.
- © 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, García-Pedrero A and Ramírez-Cortés JM. “Composite Recurrent Neural Networks for Long-Term Prediction of Highly-Dynamic Time Series Supported by Wavelet Decomposition”, Soft Computing for Intelligent Control and Mobile Robotics, Vol. 318/2011, pp.253-268, Castillo O, Janusz K and Pedrycz W. Editors, Springer-Verlag. DOI:10.1007/978-3-642-15534-5_16. , 2010 (Preliminary PDF)

REFERENCIAS

- © 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](#))
- © 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
- © Takens, F. Detecting Strange Attractors in Turbulence (1981), 366—381. Springer Berlin Heidelberg.