



TECNOLOGÍAS DE PREDICCIÓN BASADAS EN INTELIGENCIA COMPUTACIONAL

 *Coordinación de
Ciencias Computacionales*

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

`ccc.inaoep.mx/~pgomez`

6 de Noviembre del 2012
Universidad Autónoma de Tlaxcala Facultad de
Ciencias Básicas, Ingeniería y Tecnología.

Esta presentación está disponible en:

<http://ccc.inaoep.mx/~pgomez/conferences/PggUat12.pdf>

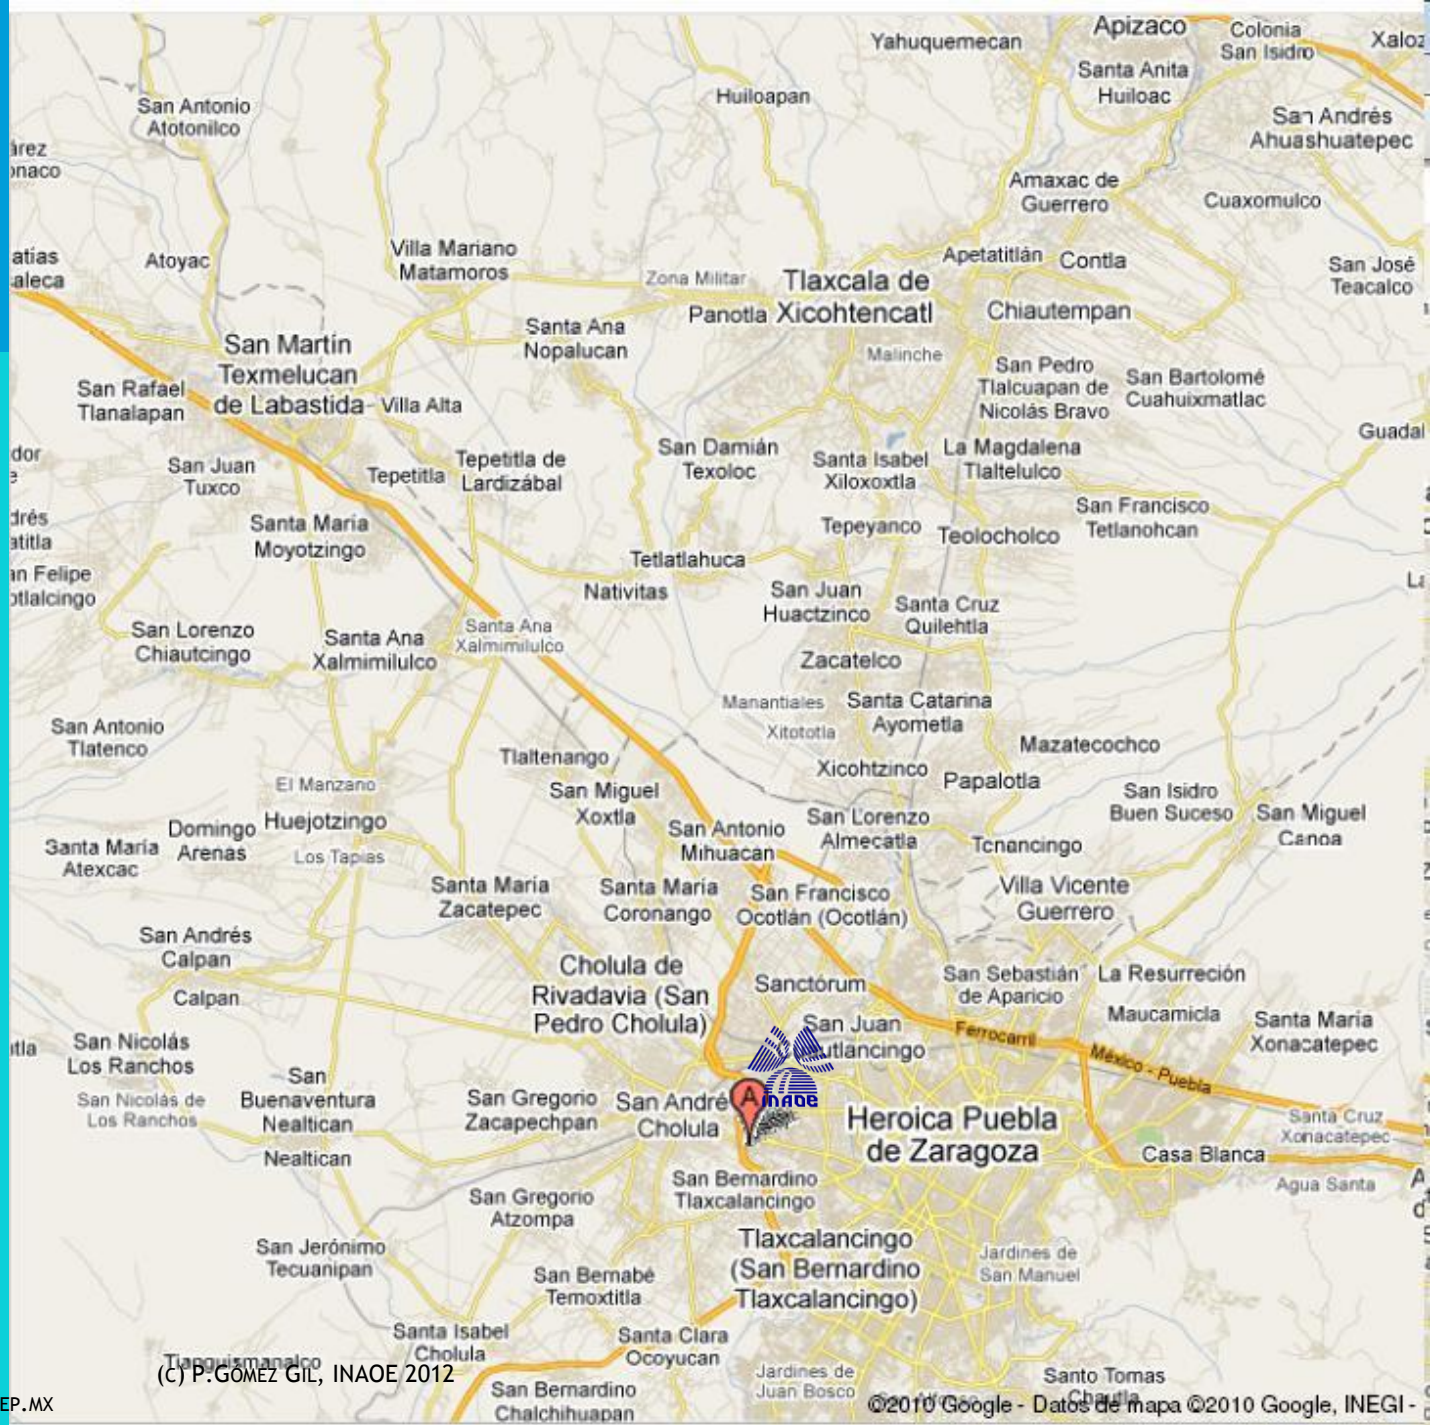
SOBRE EL INAOE



Es un centro público de investigación cuya misión es contribuir a la generación, avance y difusión del conocimiento para el desarrollo del país y de la humanidad, por medio de la identificación y solución de problemas científicos y tecnológicos y de la formación de especialistas en las áreas de Astrofísica, Óptica, Electrónica, Ciencias Computacionales y áreas afines.

<http://www.inaoep.mx/>





(C) P.GÓMEZ GIL, INAOE 2012

ÁREAS DE INVESTIGACIÓN DE LA COORDINACIÓN EN CIENCIAS DE LA COMPUTACIÓN DEL INAOE



1. ***Aprendizaje automático y reconocimiento de patrones***
2. Tratamiento de lenguaje natural
3. Percepción por computadora
4. Ingeniería de Sistemas

APRENDIZAJE AUTOMÁTICO Y RECONOCIMIENTO DE PATRONES



- ① Se enfoca en el desarrollo de investigación básica y aplicada en áreas como aprendizaje reforzado basado en grafos, cómputo suave para clasificación, extracción de características, minería de datos, reconocimiento de patrones lógico-combinatorio y ***redes neuronales artificiales***.


PUERTAS ABIERTAS 2012

[HTTP://CENTEOTL.INAOEP.MX/GH100/PUERTAS_ABIERTAS.HTML](http://centeotl.inaoep.mx/gh100/PUERTAS_ABIERTAS.HTML)



GUILLERMO HARO | CONTACTO

2013, Centenario del Natalicio de Guillermo Haro



PROGRAMA DE ACTIVIDADES
Puertas Abiertas 10 de Noviembre
Horario: 10 a 22h

Horario de Laboratorios 10:00 a 18:00
 Observación Astronómica 18:00 a 22:00

LABORATORIOS:

Para conocer más sobre la Coordinación de Computación visita: ccc.inaoep.mx

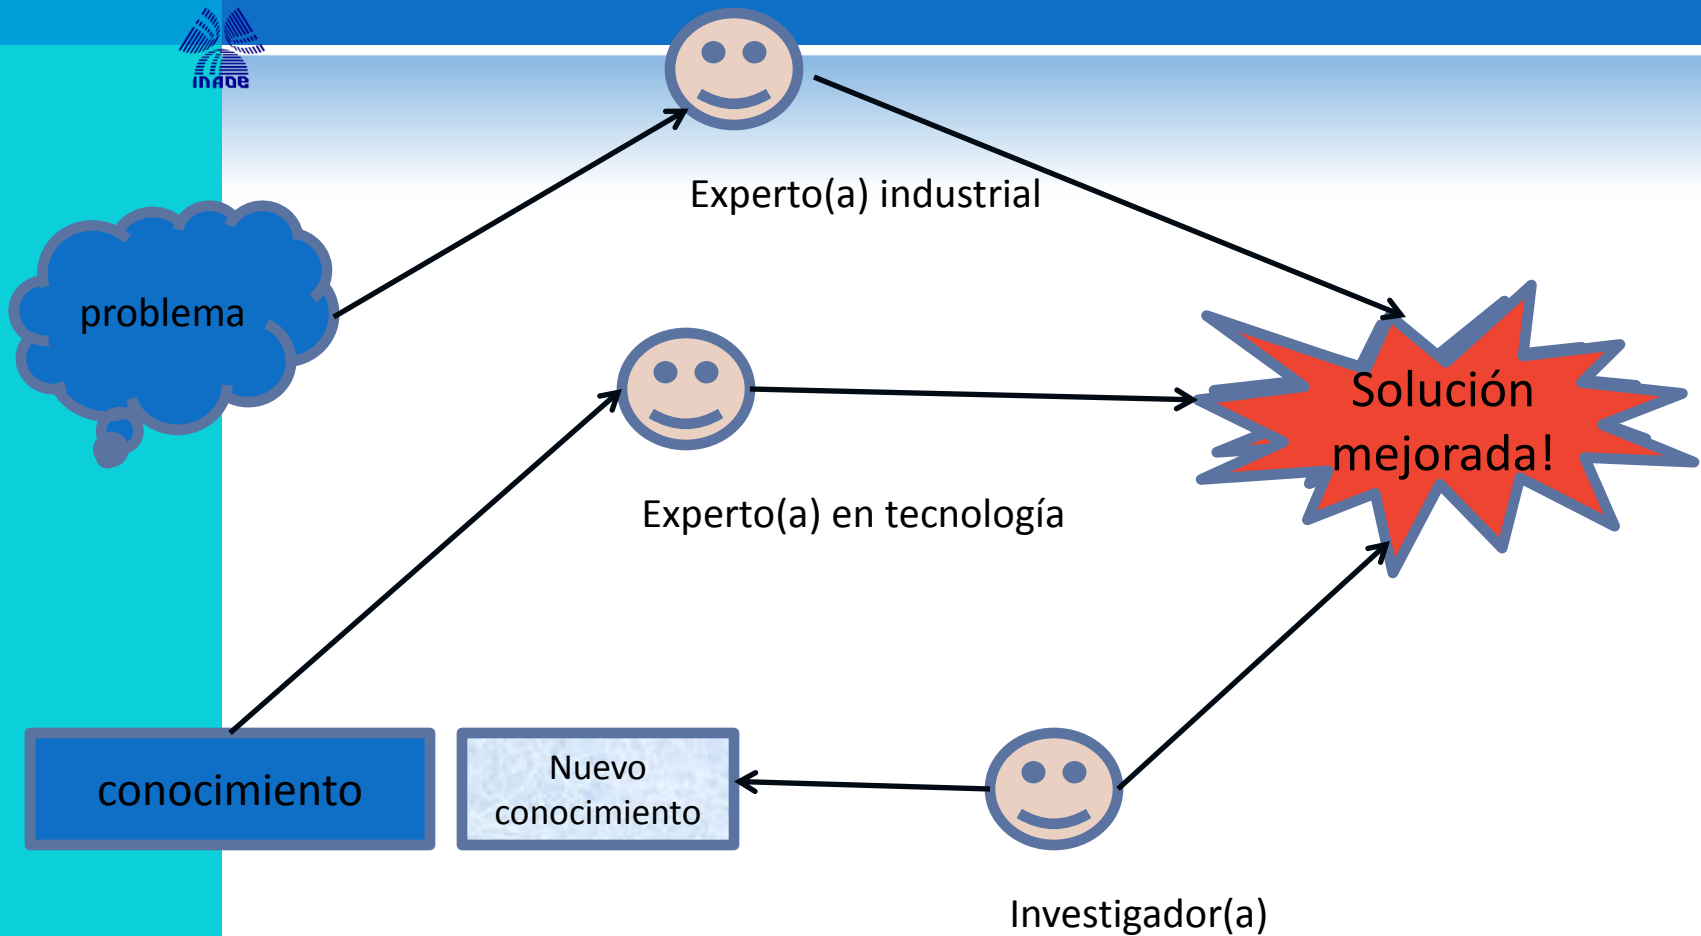


OBJETIVO DE LA PRESENTACIÓN




Motivar a la audiencia a conocer más sobre las herramientas existentes para resolver problemas de predicción, utilizando Inteligencia Computacional, en especial *Redes Neuronales Artificiales*.

TRANSFIRIENDO CONOCIMIENTO



CONTENIDO RESTANTE:

- ⊙ ¿Que es inteligencia computacional?
- ⊙ ¿Qué son las redes neuronales artificiales?
- ⊙ La necesidad de predecir
- ⊙ Las series de tiempo caóticas
- ⊙ Redes neuronales, caos y predicción a largo plazo
- ⊙ Conclusiones y perspectivas



¿QUÉ ES LA INTELIGENCIA
COMPUTACIONAL?



IEEE Computational Intelligence Society

MIMICKING NATURE FOR PROBLEM SOLVING

IEEE Computational Intelligence Soc

Menu

About CIS

- Welcome from the Past President
- Scope
- Constitution
- Bylaws
- ADCOM Meeting Minutes
- Officers (EXCOM)
- ADCOM Members
- Standing Committee Chairs
- Constitution and Bylaws Committee

Membership Benefits

IEEE CIS > About CIS

Scope

The Field of Interest of the Society shall be the theory, design, application, and development of biologically and linguistically motivated computational paradigms emphasizing neural networks, connectionist systems, genetic algorithms, evolutionary programming, fuzzy systems, and hybrid intelligent systems in which these paradigms are contained.

LA COMPUTACIÓN “CONVENCIONAL”



Pasos para la solución de problemas:

1. Desarrollo de una formulación matemática.
2. Desarrollo de un algoritmo para implementar la solución matemática.
3. Codificación del algoritmo en un lenguaje específico.
4. Ejecución del código.

[Gómez-Gil, 2011]

ÉXITOS Y FRACASOS DE LA COMPUTACIÓN “CONVENCIONAL”

EXITOS	FRACASOS
Muy eficiente en la solución a problemas matemáticos y de simulación.	Muy ineficiente resolviendo problemas de reconocimiento.
Muy eficiente realizando tareas repetitivas y bien definidas.	Muy ineficiente con adaptación y aprendizaje.
	Muy ineficiente con problemas de percepción.

OBSERVEN QUE...



... Los sistemas biológicos
utilizan estrategias de
procesamiento muy diferentes
a los sistemas de cómputo
convencionales

CARACTERÍSTICAS DE LA COMPUTACIÓN BIOLÓGICA



- ⊙ Contiene mecanismos de percepción
- ⊙ Es masivamente paralela y altamente interconectada
- ⊙ Es tolerante al ruido en el medio ambiente y en sus componentes
- ⊙ Tiene gran variabilidad y especialización en sus componentes.
- ⊙ Es altamente adaptable al medio
- ⊙ Es lenta y baja en precisión
- ⊙ Presenta un desarrollo evolutivo continuo hacia sistemas más complejos



ÁREAS PRINCIPALES DE LA INTELIGENCIA COMPUTACIONAL

- ⊙ Algoritmos evolutivos
- ⊙ Redes Neuronales Artificiales
- ⊙ Lógica Difusa




LAS REDES NEURONALES ARTIFICIALES

REDES NEURONALES ARTIFICIALES



- Están inspiradas en la construcción del cerebro y 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**)



© 2000 John Wiley & Sons, Inc.



EL CEREBRO Y LAS RNA




Una red neuronal artificial se parece al cerebro en dos aspectos:


1. Adquiere el conocimiento del medio ambiente, a través de un proceso de aprendizaje,
2. La fuerza de conexión entre los neurones, conocida como los pesos sinápticos, se utiliza para almacenar el conocimiento adquirido.

[Haykin 2009]


EL CONTEXTO DE REDES NEURONALES



EL COMPONENTE FUNDAMENTAL: NEURONA






© 2000 John Wiley & Sons, Inc.



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

LA CONEXIÓN ENTRE NEURONAS FORMA LAS REDES NEURONALES




TIPOS DE RNA



- ① Las RNA pueden clasificarse en general como **alimentadas hacia adelante o recurrentes**. El tipo de entrenamiento que utilizan puede ser **supervisado o no supervisado**.
- ① Hay cientos de modelos de redes neuronales y algoritmos para entrenarlas!!!
- ① El modelo escogido depende de la aplicación que se desea hacer y de la disponibilidad y características de los datos.

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 (Gómez-Gil 2006)




LA NECESIDAD DE PRONOSTICAR

? PARA QUÉ PRONOSTICAR?


- ⊙ La mayoría de los negocios y proyectos requieren hacer planes que implican un futuro **incierto**.
- ⊙ Para que esta planeación tenga menos riesgos, se requiere **estimar** el comportamiento **futuro** de indicadores económicos, políticos, sociales etc.
- ⊙ Esta estimación de valores futuros normalmente está basada en comportamientos **pasados** de los indicadores, representados en muchos casos a través de lo que se conoce como SERIES DE TIEMPO (una señal medida en **periodos regulares** de tiempo)

EJEMPLO DE UNA SERIE DE TIEMPO MEDIDA CADA HORA



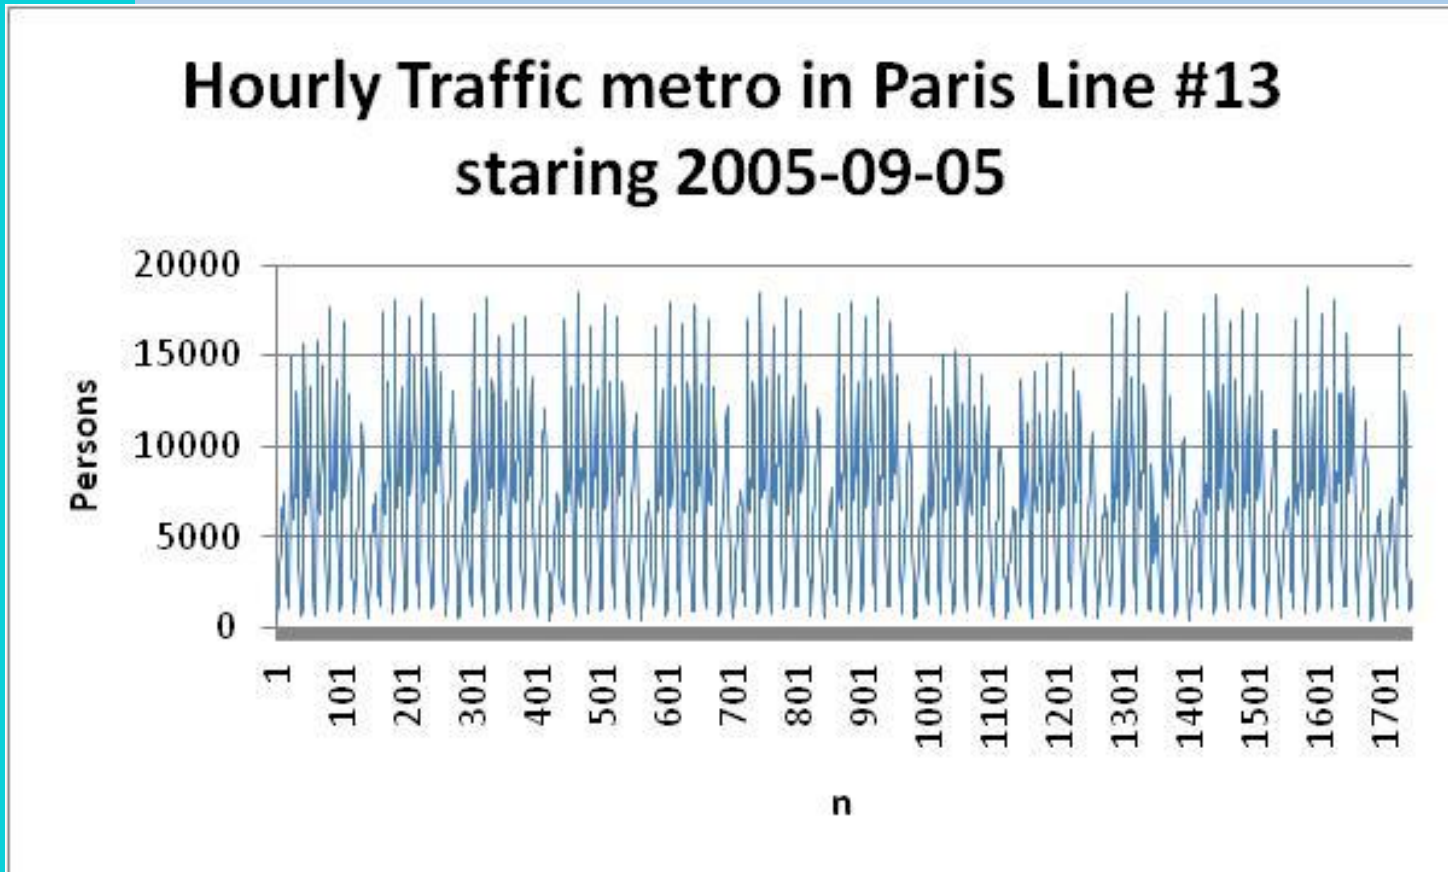
Datos tomados de [Crone 2010]

VARIOS DÍAS DE LA MISMA SERIE...



Datos tomados de [Crone 2010]

VARIOS MESES DE LA MISMA SERIE...



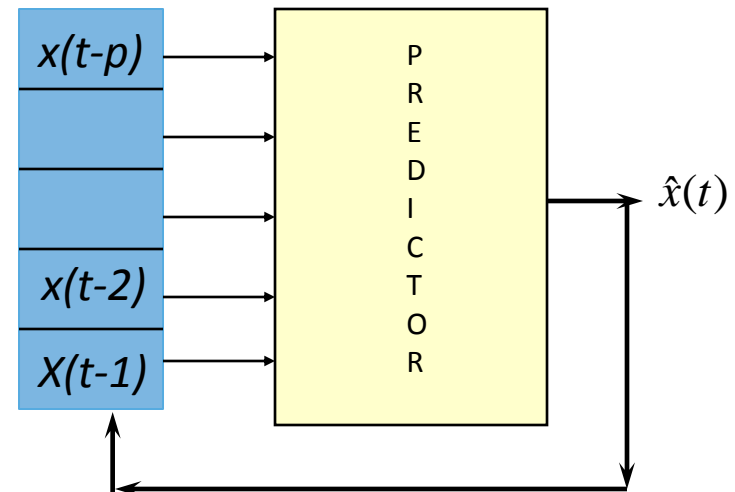

Datos tomados de [Crone 2010]

¿QUÉ ES PRONOSTICAR?

- ⊙ Dada una serie de tiempo, **pronosticar significa** calcular uno o varios valores futuros y desconocidos, utilizando información contenida en dicha señal y/o contenida en otras variables externas.
- ⊙ En muchos casos no se cuenta con variables externas confiables que ayuden a la predicción, por lo que solo se utiliza información del pasado de la señal a estimar, bajo el supuesto de que ésta contiene toda la información necesaria para realizar la estimación.

TIPOS DE PRONÓSTICO Ó PREDICCIÓN

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



$$\hat{x}_t = \Phi(x_{t-1}, x_{t-2} \dots x_{t-p})$$

EL PROBLEMA CON PREDICCIÓN RECURSIVA


- ① La predicción de un punto utiliza valores del pasado reales.
- ① La predicción a largo plazo eventualmente requiere utilizar valores calculados por el mismo sistema para realizar la estimación. Esto puede provocar que los errores se propaguen muy rápidamente.
- ① Si el sistema es altamente **no lineal**, esto es un grave problema.



EJEMPLO DE PREDICCIÓN RECURSIVA

Suponiendo que se conocen 100 datos...

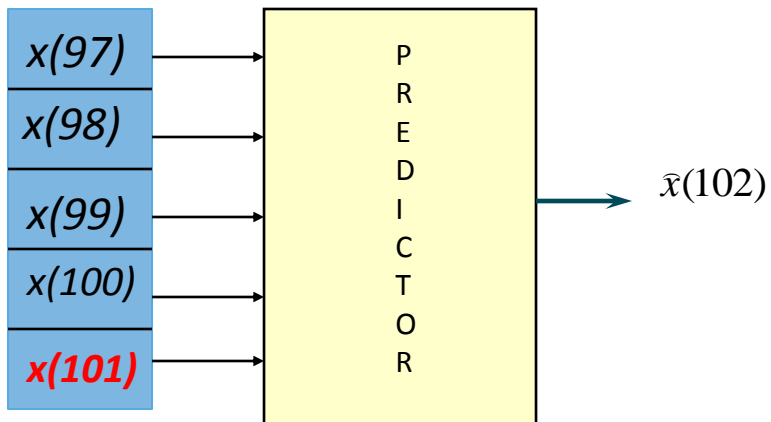
Primera predicción:



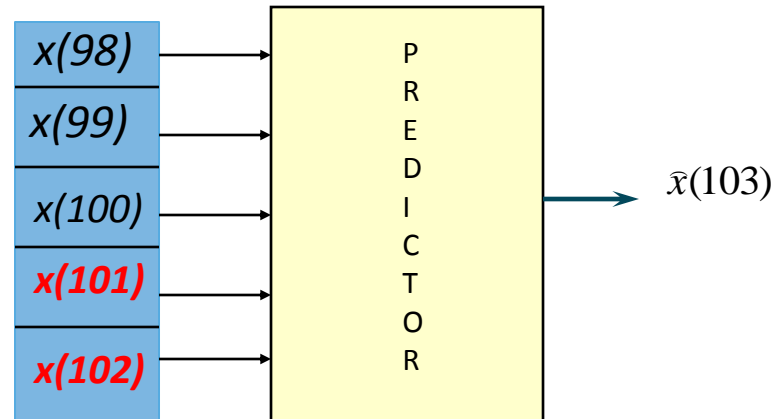
EJEMPLO DE PREDICCIÓN RECURSIVA (CONT.)

Suponiendo que se conocen 100 datos

Segunda predicción:



Tercera predicción:

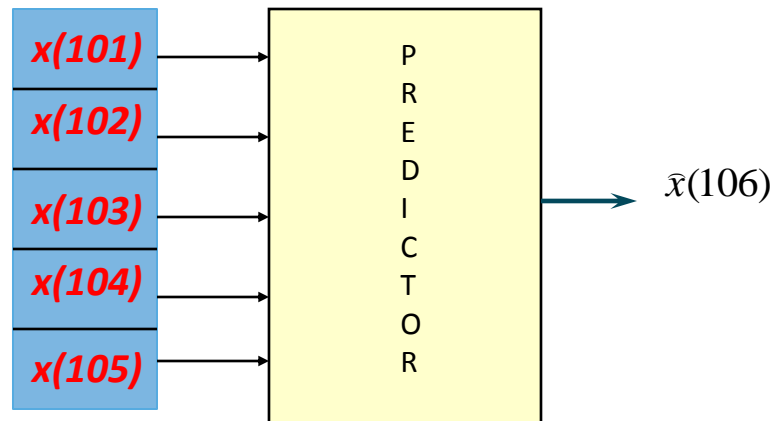


(en rojo se muestran los datos estimados)

EJEMPLO DE PREDICCIÓN RECURSIVA (CONT.)

Suponiendo que se conocen 100 datos

Sexta predicción:



TÉCNICAS DE PREDICCIÓN

- ⊙ Lineales
 - ⊙ ARMA
 - ⊙ ARIMA
 - ⊙ Filtros de Kalman
 - ⊙ ...
- ⊙ No lineales
 - ⊙ Redes Neuronales Artificiales
 - ⊙ ...



REDES NEURONALES ARTIFICIALES, CAOS Y EL PREDICCIÓN A LARGO PLAZO

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.

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

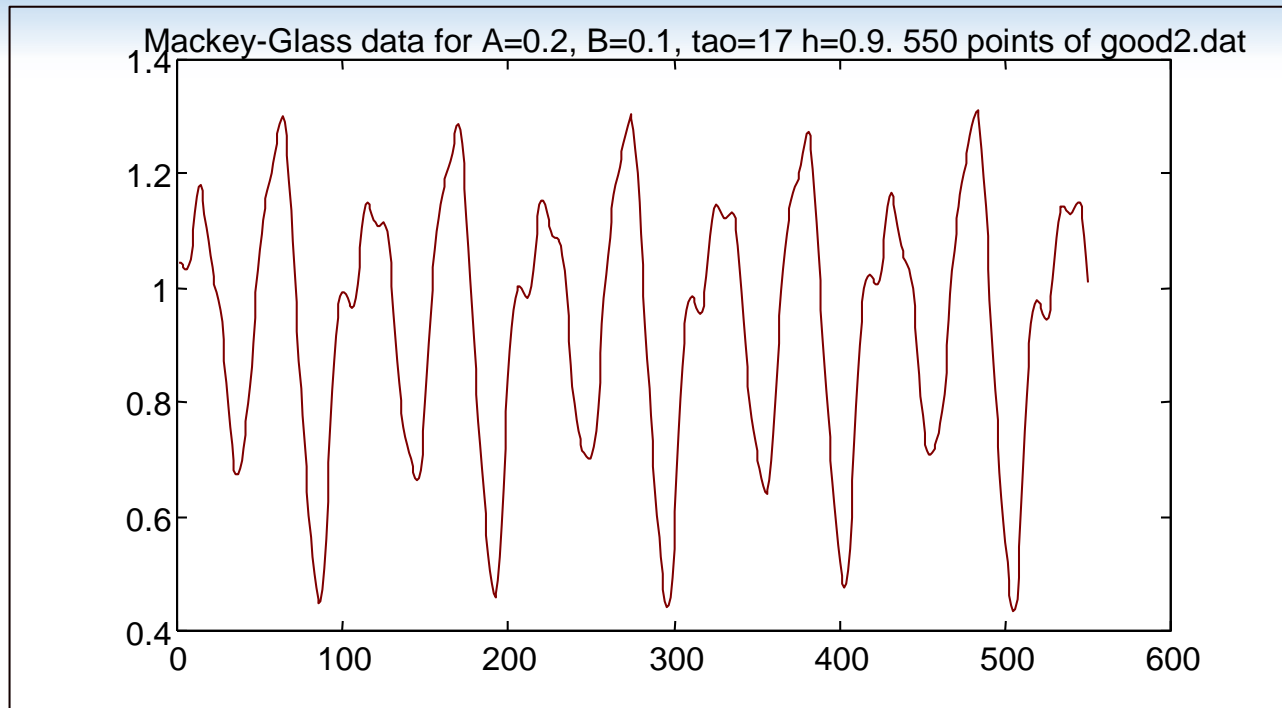
- Ⓢ Las trayectorias caóticas son aperiódicas y determinísticas,
- Ⓢ Los sistemas caóticos son extremadamente dependientes de las condiciones iniciales. Por lo tanto, pequeñas variaciones en las condiciones iniciales del sistema, harán que cambie de forma exponencial después de un determinado avance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



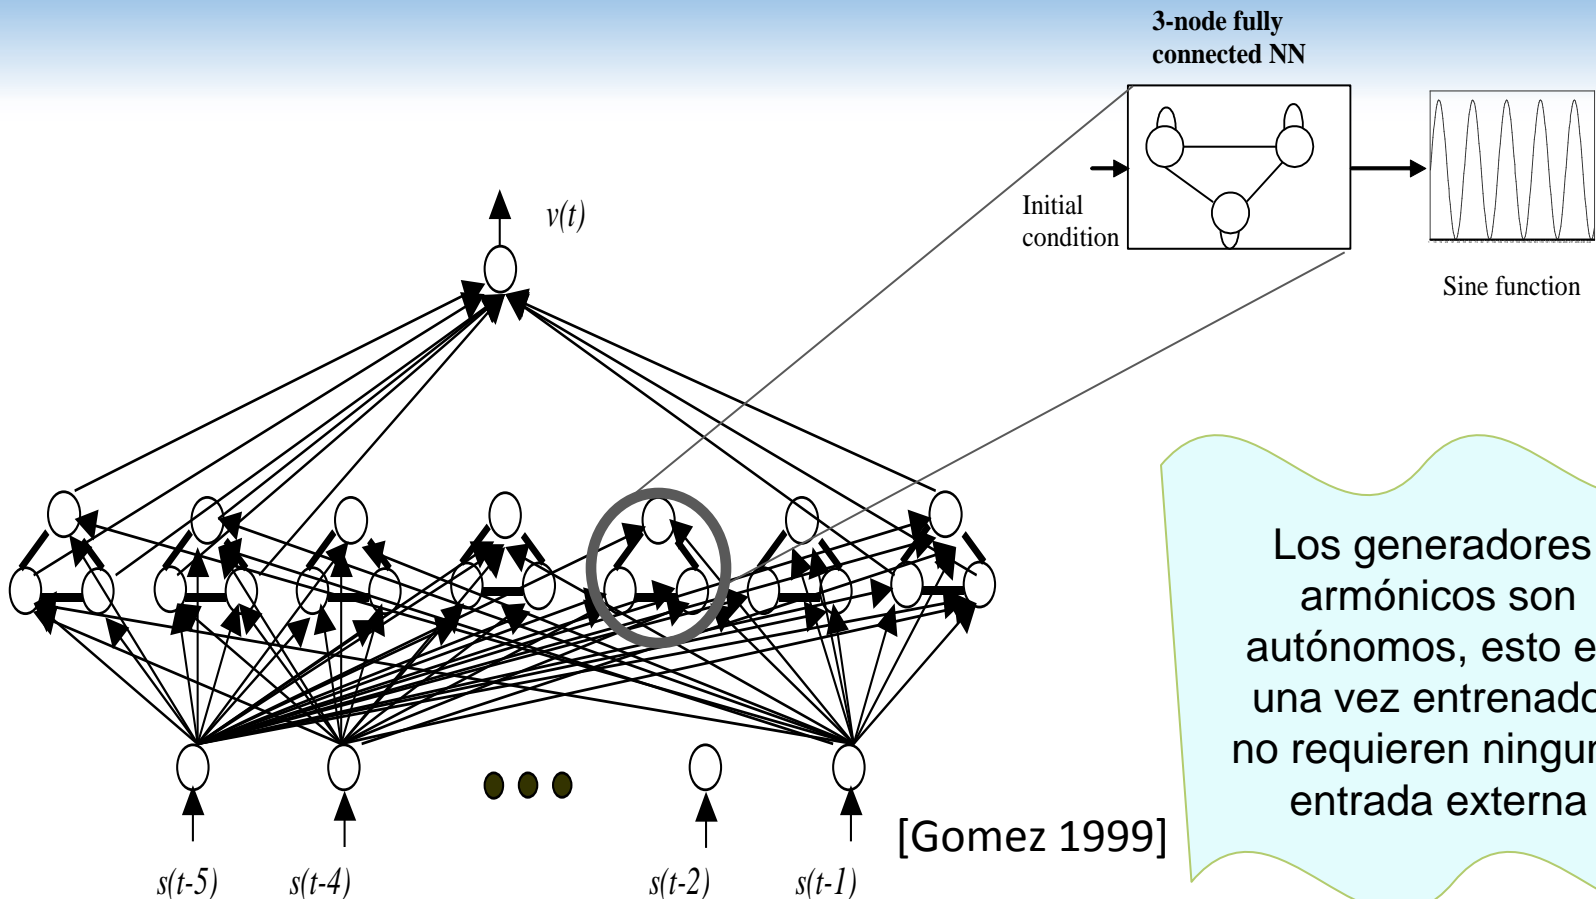
MAPA DE RETORNO DE LA SERIE MACKEY-GLASS



LA RED NEURONAL HIBRIDA COMPLEJA [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

TOPOLOGÍA DE UNA HCNN

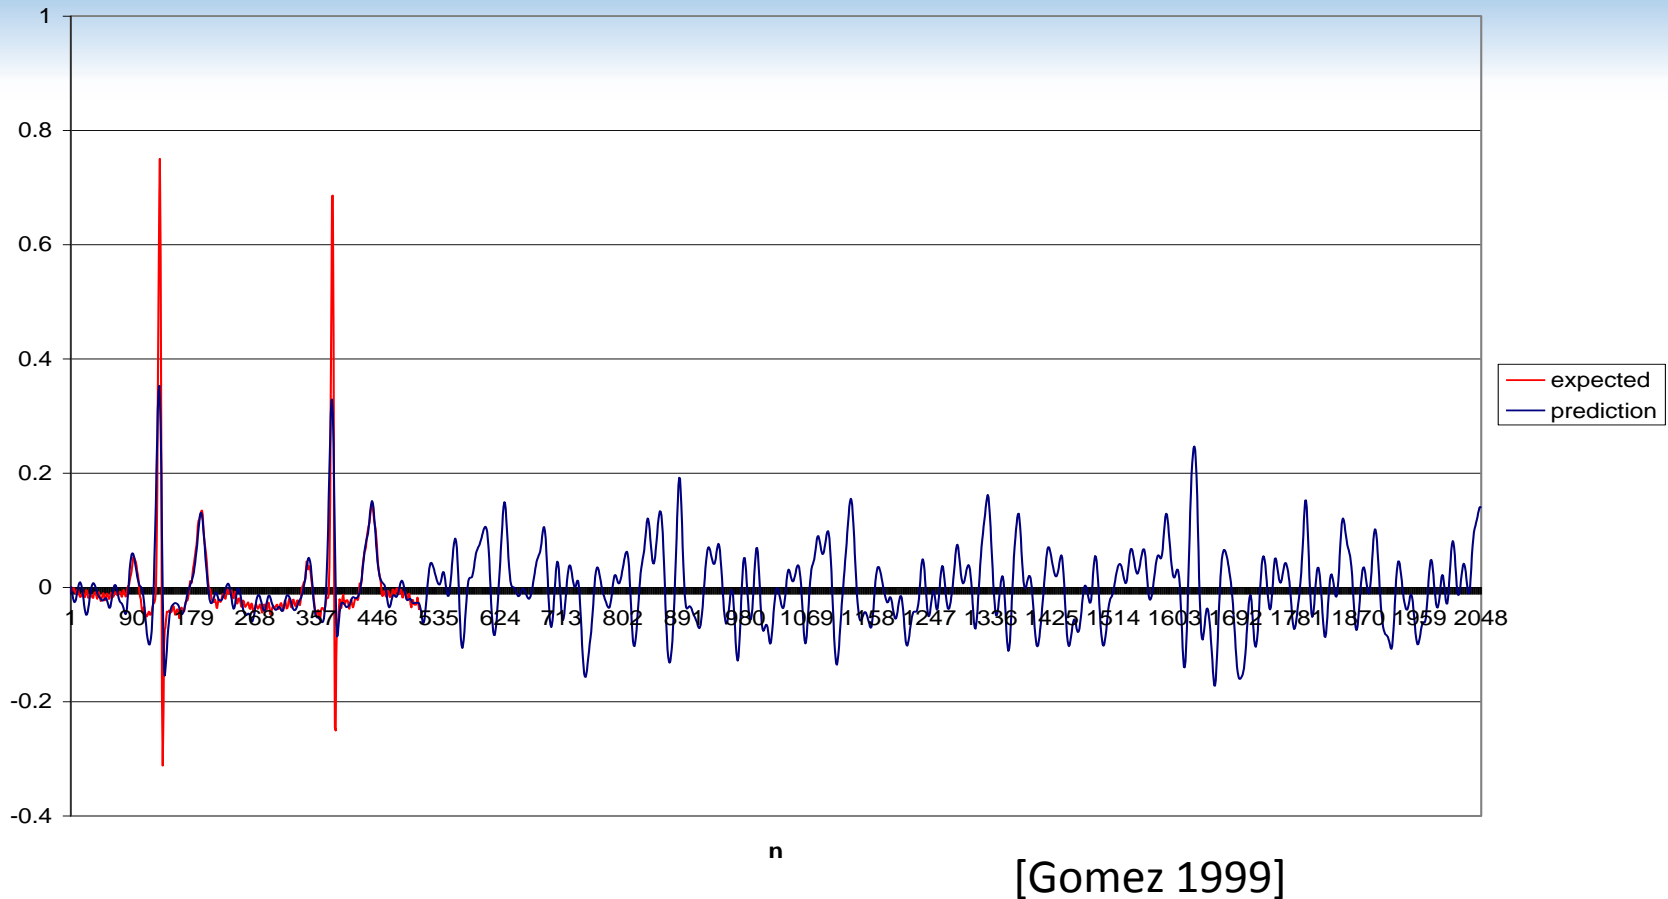


[Gomez 1999]

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

SEÑAL ORIGINAL Y PREDICHA

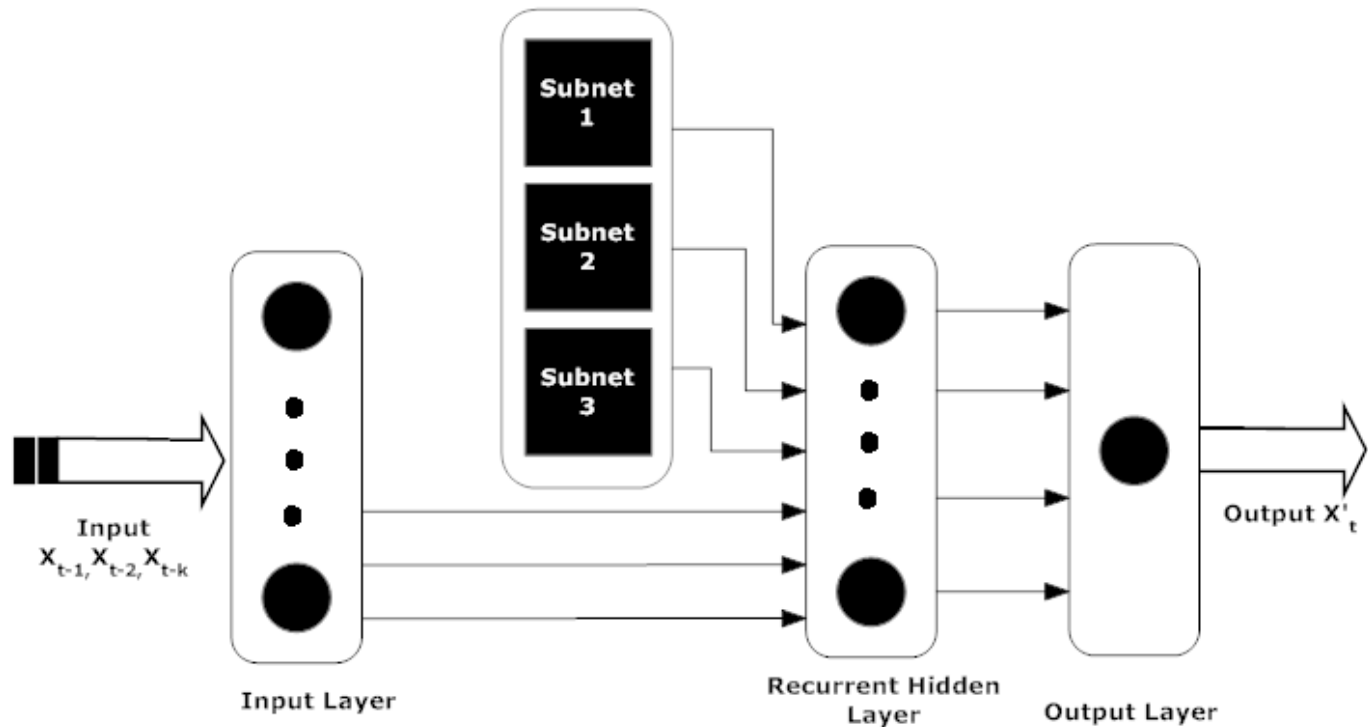
Case K.2



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)




[García-Pedrero 2009]

EJEMPLO DE UNA SERIE FINANCIERA: NN5-001 [CRONE 2008]



MEJOR CASO DE PREDICCIÓN DE LA HWRN SOBRE SERIES NN5 [GARCÍA-PEDRERO Y GÓMEZ-GIL 2010]



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

PERSPECTIVAS: 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



Tonantzintla church
(c) P. GómezGil



*Coordinación de
Ciencias Computacionales*
www.inaoep.mx

Gracias por su atención!

pgomez@inaoep.mx

ccc.inaoep.mx/~pgomez

Esta presentación está disponible en:

<http://ccc.inaoep.mx/~pgomez/conferences/PggUat12.pdf>

REFERENCIAS (1 / 3)

- ⊙ 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

REFERENCIAS (2/3)

- © 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, 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).
- © Gómez-Gil, P. Notas del curso Redes Neuronales Artificiales, INAOE, 2011. Disponible en: [http://ccc.inaoep.mx/~pgomez/cursos/redes neuronales artificiales/ -> presentaciones](http://ccc.inaoep.mx/~pgomez/cursos/redes_neuronales_artificiales/->presentaciones)
- © Glass, Leon. “Complex Cardiac Rhythms,” Nature, Vol. 330, No. 24/31, pp. 695-696, December 1987.

REFERENCIAS (3/3)

- © 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.