

MATRIZ DE CONOCIMIENTO SOBRE LA COMPLEJIDAD DE PREDICCIÓN EN SERIES DE TIEMPO.

E. Bautista-Thompson & J. Figueroa-Nazuno

Centro de Investigación en Computación.

Instituto Politécnico Nacional.

Unidad Profesional "Adolfo López Mateos" Zacatenco

Col. Linda Vista, C.P. 07738

México D. F.

ebautista@correo.cic.ipn.mx

jfn@cic.ipn.mx

Resumen

Se presentan los resultados de la evaluación de la capacidad de diferentes técnicas para la predicción y modelado de series de tiempo. Utilizando mapas autoorganizados (SOM), se identificaron relaciones entre la capacidad de predicción de las técnicas y la complejidad de las series de tiempo. Se construyeron clases de complejidad de las series y clases de capacidad de predicción de las técnicas.

Palabras clave: Predicción, Series de Tiempo, Complejidad, SOM.

1. Introducción.

En la literatura constantemente se reportan nuevas metodologías para la predicción de series de tiempo [1, 2, 3], sin embargo a pesar del gran interés en el desarrollo de nuevas técnicas de predicción, no hay criterios homogéneos para la evaluación de la capacidad de predicción de las técnicas desarrolladas, también se observa que los conceptos de predicción y modelado de series de tiempo se usan de forma indistinta y ambigua en la literatura [4]; cuando en realidad la predicción y el modelado de una serie de tiempo operativamente son conceptos diferentes. Por ultimo, se han hecho algunos trabajos sobre clasificación de series de tiempo basado en el análisis de parámetros característicos determinados con técnicas de sistemas dinámicos no lineales [5, 6, 7], sin embargo no se encuentra en la literatura información sobre las relaciones que pueden existir entre la complejidad de las series de tiempo (determinada en base a los parámetros que caracterizan a las series), y el tipo de técnicas de predicción o modelado utilizadas. Los argumentos anteriores nos motivan a desarrollar el análisis que se presenta en este trabajo con el objetivo de generar una matriz de conocimiento que nos permita extraer reglas sobre la predicción de series de tiempo.

Para realizar el análisis sobre la capacidad de predicción se utilizaron dos clases de series de tiempo: series experimentales, las cuales presentan comportamiento complejo (económicas, sísmicas, fisiológicas) y series sintéticas en las cuales se tiene control sobre los parámetros de la función generadora (Seno, Lorentz, Henon, Ikeda). Las técnicas de predicción y modelado evaluadas, fueron seleccionadas bajo el criterio de que fuesen representativas de los diferentes modelos y teorías usados para la predicción de series de tiempo como son: Estadística Moderna, Teoría de Sistemas Dinámicos No Lineales e Inteligencia Artificial (e. g. Redes Neuronales). Para la determinación de la complejidad de las series de tiempo se hizo uso de diversas herramientas de análisis: Chaos Data Analyzer, VRA 4.2, NLyzer, y Técnica de Extracción de Gramáticas, con las cuales se calcularon los parámetros característicos de las series de tiempo: Exponente Principal de Lyapunov, Entropías, Mapa de Recurrencia, Dimensiones, Coeficiente de Hurst, Reglas de Producción Gramatical [8, 9, 10, 11].

La información generada fue analizada utilizando mapas autoorganizados (SOM) [12, 13], los cuales permiten clasificar la información y así determinar las relaciones existentes entre complejidad de la serie y capacidad de predicción de las técnicas.

2. Evaluación de las Técnicas y Caracterización de las Series de Tiempo.

Se seleccionaron 16 series de tiempo (ver Tabla 1) representativas de las diferentes clases de series de acuerdo a la clasificación propuesta por Figueroa-Nazuno et. al. [14]. Las técnicas evaluadas (ver Tabla 2) son de dominio publico en su mayoría y están basadas en diferentes teorías y modelos computacionales: Inteligencia Artificial (Redes Neuronales y Lógica Difusa) [15, 16], Estadística Moderna (Modelos Autoregresivos) [15] y Teoría de Sistemas Dinámicos No Lineales [3, 10].

<i>Serie de Tiempo</i>	<i>Tipo de Serie de Tiempo.</i>
Sinc	Periódica
Operiodic2	Cuasiperiódica
Mackey-Glass	Caótica
Logistic	Caótica
Lorentz	Caótica
Rosler	Caótica
Ikeda	Caótica
Henon	Caótica
DI	Compleja
Laser	Compleja
Down Jones	Compleja
Kobe	Compleja
ECG	Compleja
EEG	Compleja
Brownian Motion	Estocástica
White Noise	Estocástica

Tabla 1. Series de Tiempo.

<i>Técnica de Predicción</i>	<i>Tipo de Técnica de Predicción.</i>
FIRNet	Heurística (AI): Red Neuronal de Respuesta de Impulso Finito (Generalización de la red estándar de tipo Feedforward)
Npredict-PNNGauss	Heurística (AI): Red Neuronal Probabilística (Gauss)
Npredict-MLFFN	Heurística (AI): Red Neuronal de Multicapa con alimentación hacia delante
Pittnet-FFNBP	Heurística (AI): Red Neuronal de tipo FeedForward con aprendizaje de Backpropagation
Pittnet-RBFNBP	Heurística (AI): Red Neuronal de tipo Radial Basis Function con aprendizaje de Backpropagation
Matlab-Anfis	Heurística (AI): Modelo Neuro-Difuso
Tiscan-Predict	Teoría de Sistemas Dinámicos No Lineales: Modelo de ajuste local de funciones lineales
Tiscan-Polynom	Teoría de Sistemas Dinámicos No Lineales: Modelo de ajuste global de funciones no lineales
Tiscan-Polynomp	Teoría de Sistemas Dinámicos No Lineales: Construcción de Ansatz de polinomio.
Tiscan-rbf	Teoría de Sistemas Dinámicos No Lineales: Modelo de ajuste global de funciones no lineales
Tiscan-nstep	Teoría de Sistemas Dinámicos No Lineales: Construcción de Ansatz para ajuste local lineal
Sugimay	Teoría de Sistemas Dinámicos No Lineales: Método simplex mas el uso de la dimensión embebida y vecinos cercanos.
Npredict-ARMA	Estadística: Modelo de promedios de autoregresión

Tabla 2. Técnicas de Predicción.

La metodología para la realización de los experimentos consistió en la evaluación de las 16 series para cada técnica, el número de experimentos por cada serie de tiempo podía variar desde 1 hasta un máximo de 10, dependiendo de las características de cada técnica, por ejemplo en el caso de la predicción o modelado con redes neuronales se exploraba el posible espacio de soluciones en forma limitada dado que explorar en forma exhaustiva requeriría de una cantidad de experimentos extensa (el número de posibilidades es combinatoria en base a la cantidad de parámetros que pueden ser modificados). La comparación entre los datos originales y los predichos se hizo mediante la graficación de ambas series (original y predicha), el número de datos predichos por serie fue de 50, además se evaluó el error resultante de la predicción exitosa (error medio raíz cuadrada RMSE y el error bias BE) [4], ver Tabla 3.

Error	Formula	Definición.
RMSE (Error Medio Raíz Cuadrada)	$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (x_i^p - x_i^o)^2 \right]^{\frac{1}{2}}$	Representa la medida típica de error de predicción. Valores cerca de cero indican una buena predicción. El término de la diferencia al cuadrado da mayor peso a las discrepancias grandes entre la el valor original y el predicho.
BE (Error Bias)	$BE = \frac{1}{N} \sum_{i=1}^N (x_i^p - x_i^o)$	Es una medida de la tendencia a sub o sobre predecir un valor. Un error bias positivo indica una tendencia a sobrepredecir una dato y un valor negativo a subpredecirlo.

Tabla 3. Fórmulas de errores de predicción.

La selección de los parámetros que caracterizan a las series de tiempo se realizó considerando fuesen representativos del comportamiento dinámico del sistema, los parámetros cuantifican características de tipo estadístico, topológico, computacional, espacial y temporal. A continuación se describen los parámetros que fueron calculados con las diferentes herramientas utilizadas:

Exponente de Lyapunov (EL). El exponente principal de Lyapunov, mide la evolución de trayectorias vecinas en el espacio fase. Mide la inestabilidad de la dinámica del sistema debido a cambios en sus condiciones iniciales [9, 17, 18, 19].

Exponente de Hurst (EH). El exponente de Hurst permite determinar si el fenómeno representado por la serie de tiempo presenta correlaciones de largo alcance (memoria y persistencia de largo alcance). Si la serie de tiempo posee un comportamiento con persistencia de tendencia positiva entonces $EH > 0.5$, no hay comportamiento predecible si $EH = 0$, o hay un comportamiento con persistencia de tendencia negativa si $EH < 0.5$ [20].

Dimensión de Capacidad (DCA). La dimensión de capacidad es similar a la dimensión de Hausdorff y mide el grado de auto-similitud del sistema (comportamiento invariante ante cambios de escala espacial), permite cuantificar el grado de heterogeneidad de la señal a diferentes escalas [9].

Dimensión de Correlación (DCO). La dimensión de correlación mide la cantidad de veces que la trayectoria del atractor del sistema pasa por una vecindad dada en el espacio fase, cuantifica la correlación espacial local entre puntos de la trayectoria en el espacio fase, sin tomar en cuanto el grado de correlación temporal [9, 10].

Frecuencia Dominante (FD). Permite determinar si existe alguna frecuencia característica de la señal, las series de carácter aleatorio poseen espectros amplios sin ninguna frecuencia

dominante, lo mismo se aplica en cierto grado para las series caóticas, las series periódicas y cuasiperiódicas poseen picos bien definidos [20].

Entropía Espacio-Temporal (EET). La entropía espacio-temporal, cuantifica de forma global el grado de no correlación de los datos mediante el análisis de recurrencia (Mapas de Recurrencia). A mayor porcentaje de EET menor cantidad de estructura en el mapa de recurrencia y por consiguiente menor correlación entre los datos [6, 7].

Entropía de Shannon (ES). La entropía de Shannon, es una medida de la cantidad de información que se obtiene al tomar una medida para especificar el estado del sistema [10].

Porcentaje de Determinismo (DET). Permite medir el grado de determinismo en el sistema, por medio del análisis de mapas de recurrencia [6, 7].

Porcentaje de Recurrencia (REC). Permite medir el grado de recurrencia (periodicidad y estructura) entre los datos de la serie de tiempo, que es indicativo de patrones repetitivos en la serie de tiempo, por medio del análisis de mapas de recurrencia [6, 7].

Reglas de Producción (RP). La generación de gramáticas a partir de una serie de tiempo permite dar una medida de complejidad (computacional) en la cual a mayor número de reglas de producción necesarias para generar una gramática, mayor es la dificultad para la predicción o modelado de la serie de tiempo [11].

3. Resultados.

La Figura 1, muestra un ejemplo de predicción con la técnica nstep (TISEAN) basada en la Teoría de Sistemas Dinámicos No Lineales.




Figura 1. Experimento 1. Serie Láser. Técnica nstep (TISEAN).

Las Figuras 2 y 3 muestran el comportamiento de los diferentes errores de predicción calculados durante la evaluación de las técnicas. El error RMSE (ver Figura 2), presenta un comportamiento creciente de la serie periódica hacia las series complejas, también se observa un máximo de error en la predicción de las series de tipo caótico tanto para las técnicas heurísticas como para las técnicas basadas en dinámica no lineal. Por su parte el error BE (ver Figura 3), indica poco efecto bias (de sub predicción o sobre predicción) por parte de las técnicas de predicción o modelado para la mayoría de las series evaluadas.




Figura 2. Error RMSE




Figura 3. Error BE.

La Tabla 4 muestra los parámetros calculados para las series de tiempo y la Tabla 5 muestra la escala de dichos parámetros, esta tabla se construyó en base a la integración de diversos criterios definidos en la literatura sobre los parámetros calculados [6, 7, 8, 20], la escala de parámetros se definió considerando el mayor valor y el menor valor obtenido para cada parámetro y su subdivisión en intervalos iguales, se incluye además el impacto en la dificultad de predicción de la serie de tiempo debido a cada propiedad, el criterio de

asignación de los valores es de carácter empírico (para cada parámetro el valor numérico asignado de degradación en la capacidad de predicción es mayor para el valor del parámetro que denota la mayor complejidad de la serie de tiempo). El objetivo de esta asignación numérica es permitir cuantificar el grado de complejidad de la serie de tiempo en base al conjunto de los parámetros calculados para la misma y poder relacionarlo con la capacidad de las diferentes técnicas para predecir y modelar las series.


<i>Serie de Tiempo.</i>	<i>Exponente de Hurst</i>	<i>Dimensión de Capacidad</i>	<i>Dimensión de Correlación</i>	<i>Exponente de Lyapunov</i>	<i>Frecuencia Dominante</i>	<i>Número de Reglas de Producción</i>	<i>Entropía (Shannon)</i>	<i>Entropía Espacio Temporal (%)</i>	<i>Recurrencia (%)</i>	<i>Determinismo (%)</i>
Sine	0,94768	0,246	0,228	0,517	-0,0005	27	3,711	0	19,556	62,19
Qperiodic2	0,00155	0,679	0,923	0,925	0,13	66	2,445	0	8,148	97,760
Mackey-Glass	0,0781	0,983	1,025	1,481	0,0685	75	0,15914	50	0,51034	37,5178
Logistic	-0,0593	0,941	0,930	0,760	0,3795	61	0,03522	78	8,61304	0,85112
Lorentz	0,75551	0,965	1,025	0,601	0,0005	63	4,78931	57	32,8839	92,0699
Rosler	0,56174	0,994	1,026	1,049	0,017	72	2,45897	0	6,38852	88,0434
Ikeda	-0,0195	0,983	1,019	1,452	0,3235	71	0	53	0,54849	0
Henon	-0,03338	0,997	0,991	2,301	0,4605	69	0,0204	51	9,43468	0,63758
DI	0,31231	0,986	2,053	1,288	0	92	0,8521	39	3,30067	60,2251
Laser	0,08799	0,961	2,096	0,949	0,1305	66	2,93549	47	10,716	71,4658
Down Jones	0,56318	0,887	1,035	0,144	0	65	6,43519	2	98,8534	98,8812
Kobe	0,01593	0,904	1,053	1,102	0,2205	79	3,74401	78	57,046	44,3674
ECG	0,74842	0,934	1,051	0,242	0	53	3,51860	0	13,7886	89,8581
EEG	0,20447	0,890	1,876	1,199	0,041	82	0	73	2,7157	0
Brownian Motion	0,5374	0,971	1,103	2,043	0	85	2,74038	0	11,7750	66,2786
White Noise	0,00179	0,983	2,086	1,606	0	73	0	79	0	-1

Tabla 4. *Parámetros de caracterización de las series de tiempo.*

<i>Escala de los parámetros (Valor de degradación en la capacidad de predicción)</i>	<i>Interpretación</i>
Exponente de Hurst (Parámetro Estadístico)	
EH > 0.5 (0)	La tendencia local sobre el intervalo continuará (persistencia). La mejor predicción se basa en la extrapolación de la <i>tendencia positiva</i> en la serie de tiempo.
EH = 0.5 (1)	Valores sucesivos son independientes y la mejor predicción es el último valor medido.
EH < 0.5 (0)	La tendencia local puede revertirse (anti persistencia). La mejor predicción tiende al valor medio sobre el intervalo. <i>Tendencia negativa</i> en la serie de tiempo.
Dimensión de Capacidad (Parámetro Topológico)	
DC > 0.750 (3)	Autosimilaridad alta
0.500 < DC < 0.750 (2)	Autosimilaridad media
DC < 0.500 (1)	Autosimilaridad baja
Dimensión de Correlación (Parámetro Topológico)	
DCO > 1.474 (3)	Cantidad de información alta
0.851 < DCO < 1.474 (2)	Cantidad de información media
DCO < 0.851 (1)	Cantidad de información baja
Exponente Principal de Lyapunov (Parámetro Topológico)	
EL < 0.863 (1)	Predictibilidad alta
0.863 < EL < 1.582 (2)	Mediana Predictibilidad
EL > 1.582 (3)	Predictibilidad baja
Frecuencia Dominante (Parámetro Temporal)	
Existe (0)	Puede haber componente aleatoria
No existe (1)	Fuerte componente aleatoria
Número de Reglas de producción (Parámetro Computacional)	
RP > 71 (3)	Alta complejidad computacional y dificultad de predicción
49 < RP < 71 (2)	Mediana Complejidad Computacional y dificultad de predicción
RP < 49 (1)	Baja complejidad computacional y dificultad de predicción.
Entropía (Shannon) (Parámetro Computacional)	
ES > 4 (1)	Alto contenido de información en una medición en la serie de tiempo
2 < ES < 4 (2)	Mediano contenido de información en una medición en la serie de tiempo
ES < 2 (3)	Bajo contenido de información en una medición en la serie de tiempo
Entropía Espacio Temporal (%) (Parámetro Espacio-Temporal)	
EET > 52 % (3)	Poco estructurado el Mapa de Recurrencia
26% < EET < 52% (2)	Medianamente estructurado el Mapa de Recurrencia
EET < 26% (1)	Altamente estructurado el Mapa de Recurrencia
Recurrencia (%) (Parámetro Espacial)	
REC > 66% (1)	Alto grado de correlación en los datos
33% < REC < 66% (2)	Mediano grado de correlación en los datos
REC < 33% (3)	Bajo grado de correlación en los datos
Determinismo (%) (Parámetro Espacial)	
DET > 66% (1)	Alto grado de determinismo
33% < DET < 66% (2)	Mediano grado de determinismo
DET < 33% (3)	Bajo grado de determinismo

Tabla 5. Escala de parámetros calculados.

La Figura 4 muestra la gráfica de la predicción o el modelado de las series de tiempo por parte de las diferentes técnicas evaluadas.



Técnica de predicción
Figura 4. Matriz de Predicción y Modelado.

Se observa que las técnicas de predicción o modelado más eficientes (por el número de series que logran predecir o modelar) son las basadas en la teoría de sistemas dinámicos no lineales (nstep, sugmay) y de origen heurístico (PNNGauss, Anfis).

Con el objetivo de cuantificar la capacidad de predicción de las técnicas evaluadas se construyó un Coeficiente de Capacidad de Predicción (CCP). El coeficiente esta definido como:

$$CCP = <Complejidad de la Serie Predicha> + Eficiencia de Predicción - <RMSE> - <BE>$$

donde se define:

<Complejidad de la Serie Predicha>, como el promedio de la complejidad de las series predichas o modeladas por la técnica evaluada.

Eficiencia de Predicción, es la razón del número de series predichas por la técnica entre el número total de series evaluadas.

<RMSE>, es el promedio del Error Medio Raíz Cuadrada de todas las series predichas por la técnica evaluada.

<BE>, es el promedio del Error Bias de todas las series predichas por la técnica evaluada.

El mayor peso en el coeficiente esta dado por el promedio de la complejidad de las series predichas, seguido por la eficiencia de predicción.

La Figura 5 muestra el Coeficiente de Capacidad de Predicción (CCP) vs. Técnica de Predicción o Modelado, con excepción de la técnica Anfis que no permite la generación de archivos con los datos predichos (por lo que no se tiene información sobre el error *RMSE* y *BE* para esta técnica) al resto de las técnicas evaluadas se les pudo determinar su CCP. Se observa que de las técnicas que modelan, las que poseen mayor capacidad de predicción

son de carácter heurístico, sin embargo la técnica Sugimay que se basa en análisis no lineal también tiene una buena capacidad de predicción junto con la técnica ARMA de origen estadístico. En el caso de las técnicas de predicción se observa que la capacidad de predicción es similar tanto para las técnicas heurísticas como para las basadas en sistemas dinámicos no lineales.




Figura 5. Coeficiente de Capacidad de Predicción.

Mediante los mapas autoorganizados (SOM) se extrajo el conocimiento sobre las relaciones existentes entre el coeficiente de capacidad de predicción de las técnicas y la complejidad de las series de tiempo con el objetivo de generar categorías sobre la capacidad de predicción de las técnicas y sobre la complejidad de las series de tiempo. Los mapas se interpretan de la siguiente forma, en la escala de grises, a menor grado de gris mayor el valor numérico de la propiedad y viceversa, las etiquetas en los mapas corresponden a las unidades que son más representativas de la clase agrupada en dicha zona del mapa, cada propiedad tiene dos mapas uno con etiquetas correspondientes a las series de tiempo predichas y el otro con etiquetas correspondientes a las técnicas de predicción, la correspondencia entre etiquetas en ambos mapas es de uno a uno. Los mapas autoorganizados permiten clasificar la información aun siendo esta incompleta como en el caso de la técnica Anfis en la cual no se tiene información sobre su coeficiente de capacidad de predicción. La Figura 6 muestra un ejemplo de los mapas utilizados en el análisis de extracción de conocimiento, y en la Tabla 6 se presenta la matriz del conocimiento extraído de los mapas autoorganizados.




Figura 6. Mapa correspondiente al Coeficiente de Capacidad de Predicción.

Técnica de Predicción	Serie de Tiempo	Sine	Qperiodic2	Mackey-Glass	Logistic	Lorentz	Rosser	Ikeda	Hcnon	D1	Laser	Down Jones	Kobe	ECG	EEG	Brownian Motion	White Noise
Fimct (P)	CP 2	COM 1		COM 4							COM 3						
PNNGauss (P)	CP 2	COM 1	COM 2				COM 3		COM 4		COM 3	COM 1		COM 2			
MLFFN (P)	CP 1	COM 1	COM 2			COM 2	COM 3							COM 2			
FFNBP (M)	CP 4	COM 1	COM 2	COM 4	COM 4	COM 2	COM 3		COM 4	COM 5		COM 1		COM 2	COM 5	COM 4	
RBFNBP (M)	CP 3	COM 1	COM 2	COM 4	COM 4	COM 2	COM 3		COM 4	COM 5				COM 2		COM 4	
Anfis (M)	CP 3	COM 1	COM 2	COM 4	COM 4	COM 2	COM 3	COM 5		COM 5	COM 3	COM 1	COM 4	COM 2		COM 4	
Predict (P)	CP 2	COM 1				COM 2	COM 3				COM 3	COM 1		COM 2		COM 4	
Polynom (M)	CP 2	COM 1			COM 4						COM 3						
Polynomp (P)	CP 2	COM 1		COM 4	COM 4	COM 2			COM 4		COM 3		COM 4				
rbf (M)	CP 2	COM 1	COM 2	COM 4							COM 3						
nstep (P)	CP 2	COM 1		COM 4	COM 4	COM 2	COM 3		COM 4		COM 3	COM 1		COM 2			
Sugimay (M)	CP 3	COM 1	COM 2	COM 4	COM 4	COM 2	COM 3		COM 4	COM 5	COM 3	COM 1	COM 4	COM 2	COM 5	COM 4	
ARMA (M)	CP 3	COM 1	COM 2	COM 4		COM 2	COM 3				COM 3	COM 1	COM 4	COM 2	COM 5	COM 4	COM 6

Tabla 6. Matriz de Conocimiento de Categorías de Capacidad de Predicción de Técnicas (CP) y Complejidad de Serie de Tiempo (COM).

Del análisis de los mapas se identificaron 6 categorías de Complejidad y 4 de Capacidad de Predicción, donde la categoría de menor valor corresponde a menor complejidad (COM 1) o capacidad de predicción (CP 1) respectivamente y el orden es creciente en complejidad o capacidad de predicción. Las técnicas con mayor capacidad de predicción (categoría CP 3 y CP 4) modelan las series de tiempo, y en el caso de las técnicas que predicen su capacidad de predicción corresponde a la categoría CP 1 y CP 2. Se observa a partir de la categorización que no hay una relación lineal entre la complejidad de la serie y la dificultad para ser predicha por las técnicas.

4. Conclusiones.

La relación entre la complejidad de la serie de tiempo y la dificultad de predicción de la misma no es lineal, la clasificación inicial de las series en base a su comportamiento dominante (periódico, cuasiperiódico, caótico, complejo o estocástico) no es representativo de la dificultad para predecir o modelar la serie de tiempo, el utilizar al conjunto de parámetros que caracterizan a la serie de tiempo nos da mayor información para cuantificar su grado de complejidad y también es posible que permita identificar relaciones entre conjuntos de parámetros y la dificultad o facilidad para predecir dichas series con diferentes técnicas, se está trabajando en lo anterior por parte de los autores.

No se encontró una técnica de predicción o modelado que fuese superior en su capacidad de predicción en comparación con las otras técnicas, tanto las técnicas heurísticas como las basadas en dinámica no lineal presentan una capacidad de predicción similar, en cuanto a las técnicas de modelado las técnicas de origen heurístico presentan una capacidad mayor que las técnicas basadas en dinámica no lineal. La generación de las categorías de complejidad y capacidad de predicción permiten tener una métrica estándar para la comparación de nuevas técnicas de predicción y series de tiempo, además dicha información puede ser utilizada en el desarrollo de sistemas expertos que identifiquen la mejor o mejores técnicas para la predicción y modelado de las series de tiempo en base a su caracterización y su posterior categorización.

Referencias

- [1] Suhigara, G. & May, R. M. (1990). Nonlinear forecasting as a way of distinguishing chaos from measurement error in time series, *Nature*, 344, 734-740.
- [2] Wan, E. (1994). Time Series Prediction Using a Neural Network with Embedded Tapped Delay-Lines, *Time Series Prediction: Forecasting the Future and Understanding the Past*, Addison-Wesley.
- [3] Kantz, H. & Schreiber T. (2000). *Nonlinear Time Series Analysis*, Cambridge: Cambridge University Press.
- [4] Diebold, F. X. (2001). *Elements of Forecasting*, South-Western Thomson Learning.
- [5] Espinosa-Contreras, A., Suárez-Núñez, R. & Figueroa-Nazuno, J. (1999). Análisis del Comportamiento de Diferentes Sismos en la Ciudad de México con Técnicas de la Dinámica No-Lineal, XLII Congreso Nacional de Física, Villahermosa, Tabasco.
- [6] Espinosa-Contreras, A. & Figueroa-Nazuno, J. (2000). Análisis del Comportamiento de la Pérdida de Paquetes en la Red Internet con Técnicas de la Dinámica No-Lineal, Congreso Internacional de Computación CIC 2000. México D. F..

- [7] Acevedo-Mosqueda, M. E., León-Vega, C. G. & Figueroa-Nazuno, J. (2001). Medición de Complejidad de Series de Tiempo. XLIV Congreso Nacional de Física, Morelia, Michoacán.
- [8] Baker, G. L. & Gollub, J. P. (1993). *Chaotic Dynamics an introduction*, Cambridge: Cambridge University Press.
- [9] Williams, G. P. (1997). *Chaos Theory Tamed*, Washington: Joseph Henry Press.
- [10] Urbach, R. M. A. (2000). *Footprints of Chaos in The Markets*, Financial Times-Prentice Hall.
- [11] Menchaca-Méndez, R., Sánchez-Rodríguez, C., Espinosa-Contreras A. & Figueroa-Nazuno, J. (2000). Modelado y Caracterización de Series de Tiempo por medio de Análisis Gramatical. XLIII Congreso Nacional de Física, Puebla, Puebla.
- [12] Deboeck, G. & Kohonen, T. (Eds) (1998). *Visual Explorations in Finance with Self-Organizing Maps*, New York: Springer-Verlag.
- [13] Kohonen, T., Hynninen, J., Kangas, J. & Laaksonen, J. (1995). SOM_PACK: Manual de Usuario.
- [14] Figueroa-Nazuno, J. (1999). Modelos matemáticos de procesos de contaminación atmosférica. Clean Air 99, Mexico City.
- [15] Masters, T. (1995). *Neural, Novel & Hybrid Algorithms for Time Series Prediction*, John Wiley & Sons.
- [16] Martín del Brio, B. & Sanz Molina, A. (2002). *Redes Neuronales y Sistemas Difusos*, Alfaomega-RA-MA.
- [17] Ruelle, D. (1996). *Chaotic evolution and strange attractors*, Cambridge: Cambridge University Press.
- [18] Hilborn, R. C. (2000). *Chaos and Nonlinear Dynamics*, Oxford: Oxford University Press.
- [19] Ott, E. (2000). *Chaos in Dynamical Systems*, Cambridge: Cambridge University Press.
- [20] Goltz, C. (1997). *Fractal and Chaotic Properties of Earthquakes*, New York: Springer-Verlag.