

# Noisy Chaotic Time Series Forecast Approximated By Combining Reny's Entropy With Energy Associated To Series Method: Application To Rainfall Series

C. R. Rivero, J. A. Pucheta, A. D. O. Cañón, L. Franco, Y. J. T. Valdivia, P. S. Otaño, V. H. Sauchelli, *Member, IEEE*

**Abstract**— This article proposes that the combination of smoothing approach considering the entropic information provided by Renyi's method, has an acceptable performance in term of forecasting errors. The methodology of the proposed scheme is examined through benchmark chaotic time series, such as Mackey Glass, Lorenz, Henon maps, the Lynx and rainfall from Santa Francisca - Cordoba, with addition of white noise by using neural networks-based energy associated (EAS) predictor filter modified by Renyi's entropy of the series. When the time series is short or long, the underlying dynamical system is nonlinear and temporal dependencies span long time intervals, in which this are also called long memory process. In such cases, the inherent nonlinearity of neural networks models and a higher robustness to noise seem to partially explain their better prediction performance when entropic information is extracted from the series. Then, to demonstrate that permutation entropy is computationally efficient, robust to outliers, and effective to measure complexity of time series, computational results are evaluated against several non-linear ANN predictors to show the predictability of noisy rainfall and chaotic time series reported in the literature.

**Keywords**— neural networks, noisy chaotic time series, forecasting, energy associated to series (EAS), Renyi's entropic information.

## I. INTRODUCCIÓN

**L**A PREDICCIÓN de observaciones futuras es un problema importante en las series temporales, y más importante en meteorología. Debido al cambio climático regional el rendimiento de la producción agrícola se ve afectada en las regiones semiáridas para los agricultores [1]; gran parte de estos estudios se han limitado solo a regiones relativamente más pequeñas, como las regiones húmedas [2]. Dado que los métodos más avanzados de aprendizaje automático ya están disponibles ampliamente para el modelado metrológico [3] y la informática [4], las aplicaciones de estos métodos son necesarios para tener una mejor comprensión de las distribuciones actuales de las fuentes generadoras, así como las

predicciones futuras [5] [6] para una gestión sostenible de los ecosistemas [7]. Las redes neuronales (RNA) han sido ampliamente utilizadas como pronosticadores de series temporales: la mayoría de las veces se trata de redes neuronales de retroalimentación hacia adelante (FFNN), que emplean una ventana deslizante sobre la secuencia de entrada. Ejemplos típicos de este enfoque son los pronósticos meteorológicos [8] y [9]. Dado que la estructura de la serie de precipitaciones depende del régimen climático y meteorológico, así como la duración de la duración de la lluvia [10] [11] [12], los métodos basados en inteligencia computacional estáticos son generalmente incapaces de capturar el patrón temporal de los datos [13]. Sin embargo, la naturaleza no gaussiana de los datos pluviométricos también plantea problemas a los métodos estadísticos [14] que asumen la distribución normal, porque los datos tienen altos niveles de ruido, incertidumbres y errores. La insuficiencia de series largas para pronosticar probables escenarios de lluvia y la tergiversación de la precipitación puntual real en una ubicación específica también crean desafíos adicionales al problema de predicción de lluvia [15]. A continuación, se proponen nuevos métodos para mejorar aún más las herramientas actuales. Las redes neuronales artificiales (RNAs) han demostrado un rendimiento superior en la predicción en corto período de tiempo sobre otras técnicas [16], lo que sugiere que las RNAs son una herramienta prometedora para ayudar en el pronóstico de lluvia. Este artículo describe un enfoque alternativo para pronosticar series temporales caóticas basadas en la entropía de permutación de Renyi. El estudio de la entropía de permutación se basa en un análisis estadístico de las series temporales financieras publicada en [17] y el análisis de datos inteligentes [18]. Esta entropía condicional de un modelo se utiliza posteriormente en lugar de la entropía de la teoría de la información en el algoritmo de predicción propuesto. Por lo general, el proceso puede implicar encontrar una función de regresión lineal o no lineal que toma como

---

C. R. Rivero is with Universidad Nacional de Córdoba, Department of electrical and electronic engineering, Mathematics Research Laboratory applied to Control, Cordoba, Argentina, [crodiguezrivero@ieee.org](mailto:crodiguezrivero@ieee.org)

J. A. Pucheta is with Universidad Nacional de Córdoba, Department of electrical and electronic engineering, Mathematics Research Laboratory applied to Control, Cordoba, Argentina, Cordoba, Argentina, [julian.pucheta.ar@ieee.org](mailto:julian.pucheta.ar@ieee.org)

A. D. O. Cañón is with Universidad Antonio Nariño, Department of electronic engineering, [dorjuelac@gmail.com](mailto:dorjuelac@gmail.com).

L. Franco is with the Computer Science Department at Malaga University, Malaga, Spain, [lfranco@lcc.uma.es](mailto:lfranco@lcc.uma.es).

Y. J. T. Valdivia is with Computer Science School, Universidad Católica San Pablo, Arequipa, Peru, [yvantv@ieee.org](mailto:yvantv@ieee.org).

V. H. Sauchelli is with Universidad Nacional de Córdoba, Department of electrical and electronic engineering, Mathematics Research Laboratory applied to Control, Cordoba, Argentina, Cordoba, Argentina, [victorsauchelli@gmail.com](mailto:victorsauchelli@gmail.com)

P. S. Otaño is with National University of Technology, Cordoba, Argentina, [paula.otano@gmail.com](mailto:paula.otano@gmail.com)

argumentos  $p$  valores pasados de  $x(t)$ . Las observaciones a menudo se consideran como técnicas estadísticas estándar que no capturan suficientemente el proceso generador subyacente de las series temporales y su naturaleza es a menudo no estacionaria. Este artículo proporciona algunas estrategias de pronóstico cuando se aplican a series temporales complicadas. Desde entonces, se han desarrollado cientos, si no miles, de estrategias para una amplia variedad de métodos de predicción, tales como la demanda eléctrica [19] [20] [21], las aplicaciones biomédicas [22], la combinación de predicción utilizando la programación genética [23], la energía eólica [24], la demanda de agua [25], los mercados financieros [26], etc. Una de las razones del fracaso es que los modelos establecidos de predicción de series temporales estadísticas, tanto de regresión lineal como de RNAs no lineales, no tienen en cuenta el aspecto de la causa generativa de las series temporales. Por lo tanto, desde el punto de vista de la física, una proposición mucho más atractiva es tratar de aproximar los procesos subyacentes responsables de generar las series temporales o al menos estimar mediante herramientas [27] [28]. Una práctica conocida como determinista vs modelos estocásticos crean puentes entre los enfoques locales y globales para el análisis de errores basados en el modelo [29]. Por lo tanto, se propone una técnica de suavizado como Energía Asociada a la Serie (EAS) [30] [31], combinado con la entropía de permutación de Renyi y proporcionar una ley heurística para el entrenamiento de la RNA. El objetivo de este trabajo es seleccionar la energía asociada a la serie temporal (EAS) combinada con la información entrópica de las series temporales para realizar pronósticos de datos futuros. El horizonte de pronóstico para los autores es 18 predicciones hacia adelante. Por lo tanto, en este esfuerzo de investigación, se han centrado en el cálculo de la entropía de los datos de series de tiempo para modificar la estructura de los parámetros de la RNAs asumiendo el enfoque EAS. Las aplicaciones iniciales de la entropía ordinal de patrón y permutación demuestran que esto es muy prometedor para cuantificar y analizar el comportamiento dinámico de las series temporales caóticas y otras series temporales. Estudios recientes han abordado esta cuestión, a partir de la serie temporal original a través de un patrón ordinal, en el que la serie temporal se convierte en una secuencia simbólica ordinal en el que la señal pasa a través de sucesivas ventanas [32]. El desempeño del enfoque propuesto es evaluado a través de series temporales obtenidas de sistemas dinámicos tales como ecuaciones del sistema de Mackey-Glass (MG), Logística (LOG) y Lorenz (LOR) como así también de precipitación obtenidas del establecimiento Santa Francisca, Córdoba. El método apoya la aplicabilidad de la entropía de permutación al analizar el comportamiento dinámico de series temporales caóticas, incluso cuando se agrega ruido blanco para predicciones de series de tiempo.

El resto del artículo está organizado de la siguiente manera. En la Sección II se presentan algunas series temporales caóticas y datos pluviométricos provenientes de la estancia Santa Francisca, Córdoba. A continuación, el ruido blanco se añade al conjunto de datos de series temporales que utilizará el método propuesto. La Sección III hace un repaso de la entropía

de permutación usada para medir sobre el conjunto de datos. La Sección IV muestra la configuración experimental y los métodos utilizados para pronosticar las series de referencia o benchmark, con aplicación a la predicción de precipitaciones. En la sección V, se discute el método propuesto por las series temporales empíricas y se compara la complejidad con la exactitud de las predicciones producidas por los métodos de pronóstico propuestos. En la Sección VI se presentan algunas conclusiones y sus implicaciones para futuras investigaciones.

## II. SERIES TEMPORALES BENCHMARK

En pronósticos a largo plazo, la precisión de las predicciones disminuye mientras aumenta la incertidumbre. El camino utilizado por el pronosticador es la reducción de los errores de predicción de las predicciones al promediar más de un modelo, por lo que la razón es que el promedio cancela los errores de los modelos y al hacerlo elimina el patrón de ruido y mejora la precisión. Con la adición de ruido blanco, la metodología trata de demostrar que los investigadores se enfrentan a un problema práctico con información ruidosa en situaciones del mundo real [33] y no deben descuidar las fuentes de información fuera del conjunto de datos actuales [34].

### A. Series caóticas Mackey-Glass

Esta ecuación sirve para modelar fenómenos naturales y se ha utilizado en trabajos anteriores para implementar una comparación de los diferentes métodos empleados para hacer predicciones. La solución de la ecuación MG [35] se explica por la ecuación diferencial de retardo de tiempo definida como:

$$\dot{y}(t) = \frac{\alpha y(t-\tau)}{1 + y^c(t-\tau)} - \beta y(t) \quad (1)$$

donde  $\alpha$ ,  $\beta$  y  $c$  son parámetros y  $\tau$  es el tiempo de retardo. Según  $\tau$  aumenta, la solución cambia de periódica a caótica. La Ec. (1) se resuelve mediante un paso de integración de Runge-Kutta de cuarto orden estándar, y la serie a pronosticar se forma mediante valores de muestreo con un intervalo de tiempo dado.

Las series elegidas son MG17<sub>noisy</sub> con  $\tau = 17$  y MG30<sub>noisy</sub> con  $\tau = 30$  según se muestran en la TABLA . El parámetro H sirve para tener una idea de rugosidad en el sentido estadístico de una señal [36] y las series temporales se consideran como una traza unidimensional del movimiento Browniano fraccionario ( $fBm$ ), las cuales dependen del exponente o parámetro Hurst y varía entre 0 y 1 [37].

TABLA I  
PARAMETROS PARA GENERAR SERIES MG

Series No.	N	$\beta$	$\alpha$	c	$\tau$
MG17 <sub>noisy</sub>	102	1.6	30	10	100
MG30 <sub>noisy</sub>	102	0.2	0.1	10	30

### B. Series caóticas de Lorenz

Lorenz encontró tres ecuaciones diferenciales ordinarias que se aproximan estrechamente a un modelo de convección térmica [38]. Estas ecuaciones también se han convertido en un punto de referencia popular para probar métodos de pronóstico no lineales. El modelo de Lorenz está dado por la Ec. (2), los datos se derivan del sistema de Lorenz, el cual es dado por tres

sistemas de ecuaciones diferenciales con retardo de tiempos,

$$\begin{cases} \frac{dx}{dt} = a(y - x), \\ \frac{dy}{dt} = bx - y - xz, \\ \frac{dz}{dt} = xy - cz \end{cases} \quad (2)$$

Una opción típica para los valores de los parámetros es  $a = 10$ ,  $b = 28$  y  $c = 8/3$ . En este caso, el sistema es caótico. El conjunto de datos se construye utilizando el método de Runge-Kutta de cuarto orden con el valor inicial como se muestra en la TABLA para las series seleccionadas LOR01<sub>noisy</sub> y LOR02<sub>noisy</sub>. El tamaño del paso se elige 0,01, respectivamente. Estos conjuntos de parámetros se utilizan comúnmente en la generación del sistema Lorenz porque exhibe un caos determinista.

TABLA II  
PARAMETROS PARA GENERAR SERIES LOR

Series No.	n	X(0)	Y(0)	Z(0)
LOR01 noisy	102	12	9	2
LOR02 noisy	102	0.1	0.1	2

### C. Series Caóticas Henon

La serie de tiempo caótico de Henon se construye a continuación según la Ec. (3) y presenta muchos aspectos del comportamiento dinámico de sistemas caóticos más complicados [39].

$$x(t+1) = b + 1 - ax^2(t) \quad (3)$$

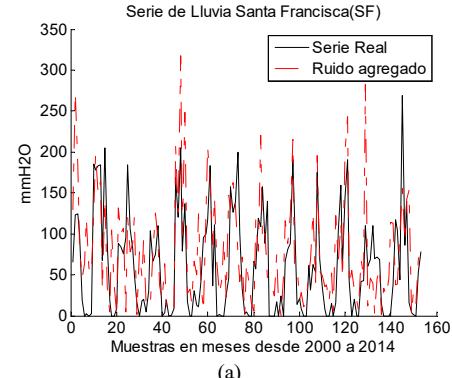
Cuando se generan datos para nuestros experimentos,  $a$  y  $b$  se establecen como se muestra en la TABLA . Estos mismos parámetros se utilizan en ambas series.

TABLA III  
PARAMETROS PARA GENERAR SERIES HEN

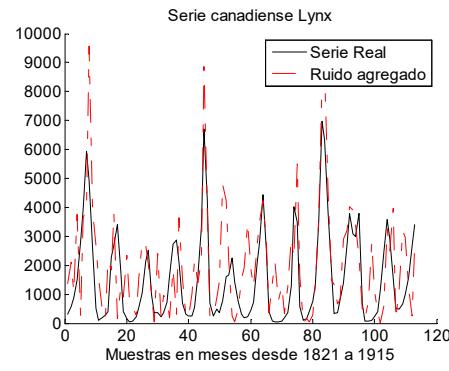
Series No.	N	a	b	X0	Y0
HEN01 noisy	102	1.4	0.3	0	0
HEN02 noisy	102	1.3	0.22	0	0

### D. Series de precipitaciones de lluvia

El conjunto de datos pluviométricos utilizado es de Santa Francisca, Despeñaderos, ubicado en Córdoba, provincia de Argentina (-31.824703; -64.289692) y la fecha de recolección es del año 2000 al 2015 como se muestra en la Figura 1 (a). El conjunto de datos tiene 154 observaciones, correspondientes al periodo de enero de 2000 a octubre de 2014. El conjunto de entrenamiento tiene 136 observaciones, correspondientes al periodo de 2000-2014. El conjunto de pruebas tiene 18 observaciones, correspondientes al periodo de noviembre de 2014 a abril de 2016. El conjunto de validación tiene 18 observaciones, correspondientes al periodo de noviembre de 2014 a abril de 2016.



(a)



(b)

Figura 1. a) Series mensuales de precipitaciones históricas de Santa Francisca; b) Lynx o lince anual atrapado anualmente en el río Mackenzie.

### E. Serie canadiense Lynx

Un conjunto de datos bien conocidos - los datos del lince canadiense se utilizan en este estudio para demostrar la eficacia del enfoque de red neural y la eficacia del método de combinación. La serie de lince que se muestra en la Figura 1 (b) contiene el número de lince atrapado por año en el distrito del río Mackenzie en el norte de Canadá. El conjunto de datos tiene 114 observaciones, correspondientes al periodo de 1821-1934. El conjunto de entrenamiento tiene 96 observaciones, correspondientes al periodo de 1821-1915. El conjunto de pruebas tiene 18 observaciones, correspondientes al periodo de 1916-1934. Esta serie ha sido ampliamente analizada en la literatura con un enfoque en el modelo no lineal [40].

## II. COMBINACIÓN DE LA ENTROPIA DE PERMUTACIÓN CON EL MÉTODO EAS

La entropía de permutación es computacionalmente eficiente, robusta a valores atípicos, y efectiva para medir la complejidad de las series temporales. Bandt y Pompe [41] introdujeron la entropía de permutación como una nueva medida de la complejidad de las series temporales no lineales, es decir, sugirieron una aproximación al análisis de series de tiempo en el que incorporaron una serie de tiempo continuo como una secuencia simbólica en otro espacio, Ellos llamaron "entropía de permutación". Asumimos que hay  $N$  observaciones  $x_1, x_2, \dots, x_N$  disponibles de algún fenómeno. El objetivo del análisis es producir una estimación para el cambio  $x_{t+\Delta T} - x_t$ , donde  $t \in \mathbb{Z}$  denota el paso del tiempo actual y  $\Delta T = t_n, \dots, t_{n+18}$  es el horizonte de pronóstico. El

algoritmo propuesto se puede esbozar en la siguiente secuencia de pasos como en [5].

#### A. Proceso de aprendizaje propuesto

Los pesos de RNAs se sintonizan mediante el enfoque EAS, que supone que las primitivas de las series temporales se calculan como una nueva entrada a la RNA [42], en la que la predicción intenta igualar el área pronosticada al área real calculada como primitiva. La puesta en marcha del algoritmo [43] logra la dependencia estocástica a largo plazo del parámetro de Hurst con el fin de hacer más precisa la predicción. El área de la serie temporal prevista se establece como una nueva entrada a la RNA y sirve para ser comparada con el área real de la serie temporal. Proponemos la información entrópica proporcionada por Renyi entropía con el parámetro  $\alpha$  de la secuencia para ajustar la ley de aprendizaje. El enfoque de aprendizaje propuesto consiste en cambiar el número de patrones, la longitud del filtro y el número de iteraciones en función de la entropía de Renyi para cada serie cronológica correspondiente. El proceso de aprendizaje se lleva a cabo utilizando un modelo por lotes o Batch. En este caso la actualización del peso se realiza después de la presentación de todos los ejemplos de entrenamiento, que forma una época. Además, el criterio propuesto para modificar el par  $(i_t, N_p)$  viene dado por el número de iteraciones realizadas por cada época que es dada por

$$l_x \leq i_t \leq R_L^{(\alpha)} \cdot l_x. \quad (4)$$

donde  $l_x$  es la dimensión del vector de entrada. A continuación, se propone un ajuste heurístico para el par  $(i_t, N_p)$  en función de  $R_L^{(\alpha)}$  de acuerdo al conjunto de funciones mostradas en la Figura 2.

Con respecto a la estimación de la entropía  $H_L$  de una serie temporal dada, un buen punto de partida podría ser la entropía de Shannon n-gramo (bloque). Para las series temporales de entropía más complejas también se podría considerar el uso de un comité de redes neuronales de alimentación múltiple no lineal [5] and [44].

Las trayectorias simuladas se añaden al final de la secuencia original  $\{x_i\}$ . Suponiendo que la última entropía observada disponible es  $H_L$ , para cada trayecto  $\gamma_k$  se puede observar la secuencia de entropía correspondiente  $H_L \rightarrow H_{L+1}^k \rightarrow H_{L+2}^k \rightarrow \dots \rightarrow H_{L+N}^k$ .

La probabilidad de la trayectoria  $\gamma_k$  puede estar ligada a la probabilidad de encontrar tal secuencia de entropía:

$$P(\gamma_k) = \prod_{i=1}^N P(H_{L+i}^k / H_{L+i-1}^k, H_{L+i-2}^k, \dots, H_{L+1}^k), \quad (5)$$

Para errores de predicción, estas están limitados por  $|\hat{H}_{L+i}^k - H_{L+i}^k| \leq 1$ .

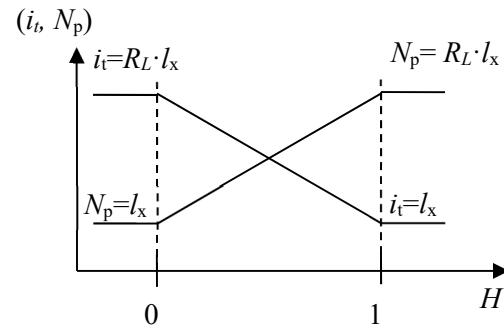


Figura 2. Ajuste heurístico de  $(i_t, N_p)$  en términos de  $R_L^{(\alpha)}$  después de cada época.

### III. RESULTADOS COMPUTACIONALES

En esta sección, comparamos nuestros resultados con otros métodos propuestos en la literatura, como BEMA [5], BEA [6], BA [45], EAS [30] y NN-Mod. [46] para la predicción de series temporales caótica para demostrar que el método de entropía de permutación tiene un rendimiento aceptable y comparable.

#### A. Configuración del algoritmo EAS-Mod

Las condiciones iniciales del filtro predictor EAS-Mod. y el algoritmo de aprendizaje se muestran en la TABLA . En el que se puede observar que el número de neuronas en la capa oculta y las iteraciones se ajustan en función del número de entradas. Estas condiciones iniciales del algoritmo de aprendizaje se utilizaron para pronosticar el área de las series temporales, cuya longitud depende del tamaño del conjunto de datos de entrada.

TABLA IV  
CONFIGURACION PROPUESTA PARA EL EAS-MOD

Variable	Condición Inicial
$H_o$	19
$l_x$	17
$it$	200
$NP$	$l_x$

El rendimiento de la comparación se mide por el índice Error Medio Absoluto Simétrico Porcentual (SMAPE) propuesto en la mayor parte de la evaluación métrica [47], definida por,

$$SMAPE_s = \frac{1}{n} \sum_{t=1}^n \frac{|X_t - F_t|}{(|X_t| + |F_t|)/2} \times 100 \quad (6)$$

donde  $t$  es el tiempo de observación,  $n$  es el tamaño del conjunto de pruebas,  $s$  es cada serie de tiempo,  $X_t$  y  $F_t$  son los valores reales y los valores de series temporales pronosticados en el tiempo  $t$ , respectivamente. El SMAPE de cada serie  $s$  calcula el error absoluto simétrico en porcentaje entre el  $X_t$  real y su correspondiente valor de pronosticado  $F_t$ , a través de todas las observaciones  $t$  del conjunto de prueba de tamaño  $n$  para cada serie temporal  $s$ . Para realizar la comparación hay tres clases de conjuntos de datos: una es la serie de tiempo original usada para que el algoritmo proporcione el pronóstico, que varía según el tamaño y para las series benchmark MG, LOR y HEN son de 102 valores con adición de ruido, 156 para la serie de lluvia

SF ruidosas y 114 para la de Lynx ruidosa, las cuales se utilizan para entrenar los pesos de las RNAs. El otro es el pronóstico y los datos de validación obtenidos por los últimos 18 valores de un conjunto de datos.

Los últimos 18 valores se pueden utilizar para validar el rendimiento del sistema de predicción y comparar si el pronóstico es aceptable o no. El método Monte Carlo se utilizó para pronosticar los próximos 18 valores de precipitaciones SF, Lynx, MG, LOR y HEN ruidosas.

Los resultados en la TABLA muestran que EAS-Mod no es superior frente a los competidores para producir predicciones de series temporales, con un promedio de SMAPE de 5,34 sobre la serie de todos los tiempos.

#### IV. DISCUSIÓN

En este trabajo se comparó la predicción ruidosa y caótica de series temporales mediante la combinación del método EAS-Mod basado en RNA usando la entropía de permutación y otros métodos de predicción, y se aplicó a series temporales caóticas reales y artificiales, principalmente series de precipitaciones de lluvia de agua acumulada. La Figura 3 muestra la evolución del promedio SMAPE para los predictores EAS-Mod., BEMA, BEA, BA, EAS y NN-Mod.

El estudio analizó y comparó las ventajas y limitaciones relativas de cada una de las series temporales de la técnica de filtro predictor en términos de métrica SMAPE. Aparece la discusión de cómo las RNAs de retroalimentación hacia adelante pueden逼近arse con éxito a los cambios cuantitativos en la dinámica de los datos de series temporales debido a cambios en los valores de los parámetros de las variables exógenas. Esto permanece abierto para el estudio, que resulta del uso de una característica estocástica para generar un resultado determinista. Aunque la comparación fue realizada por los filtros basados en RNAs, los resultados experimentales

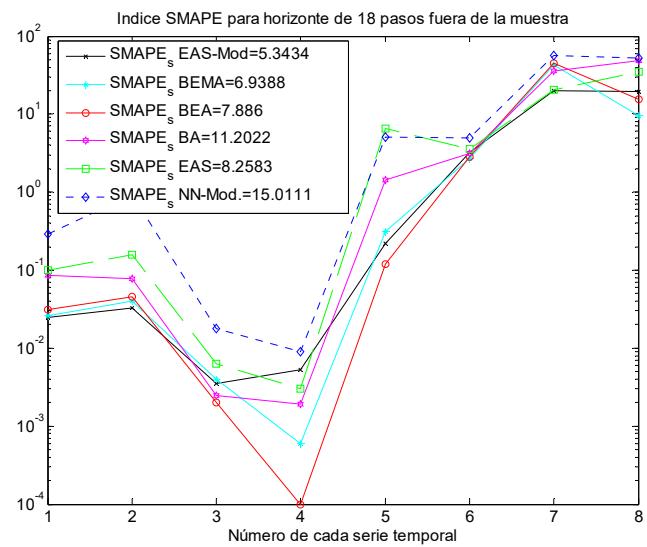


Figura 3. El promedio de los distintos SMAPE aplicado a las 8 series temporales.

#### RESULTADOS DE LA COMPARACION USANDO EL INDICE SMAPE

Series No.	Método	SMAPE
MG30 noisy	EAS-Mod	0.025
	BEMA	0.026
	BEA	0.031
	BA	0.085
	EAS	0.101
	NN-Mod.	0.292
MG17 noisy	EAS-Mod	0.033
	BEMA	0.040
	BEA	0.045
	BA	0.078
	EAS	0.156
	NN-Mod.	0.920
HEN01 noisy	EAS-Mod.	0.0035
	BEMA	0.004
	BEA	0.002
	BA	0.0025
	EAS	0.0063
	NN-Mod.	0.018
HEN02 noisy	EAS-Mod.	0.0053
	BEMA	0.0006
	BEA	0.0001
	BA	0.0019
	EAS	0.003
	NN-Mod.	0.009
LOR01 noisy	EAS-Mod.	0.22
	BEMA	0.31
	BEA	0.12
	BA	1.42
	EAS	6.54
	NN-Mod.	5.06
LOR02 noisy	EAS-Mod.	3.2
	BEMA	2.69
	BEA	2.84
	BA	3.15
	EAS	3.6
	NN-Mod.	4.95
Lynx noisy	EAS-Mod.	19.98
	BEMA	42.89
	BEA	44.63
	BA	36.25
	EAS	20.30
	NN-Mod.	56.72
Lluvia SF noisy	EAS-Mod.	19.28
	BEMA	9.55
	BEA	15.42
	BA	48.63
	EAS	35.36
	NN-Mod.	52.12

TABLA V

confirman que este método de pronóstico puede predecir las series temporales caóticas en términos del índice SMAPE. Sin embargo, el deseo de preservar las dependencias estocásticas consideradas limita todos los horizontes a predecir con la misma estructura de modelo.

## V. CONCLUSIONES

El estudio muestra las ventajas y desventajas relativas del filtro predictor EAS-Mod basado en modelo NAR utilizadas para pronosticar series de lluvia como así también series caóticas artificiales. Este artículo presenta una metodología para la combinación del filtro predictor EAS teniendo en cuenta la información entrópica proporcionada por el método Renyi, que tiene un desempeño aceptable en términos de errores de predicción. Los resultados experimentales confirman que el método propuesto puede predecir las series temporales caóticas más ruidosas en términos de índices SMAPE en comparación con otros métodos de pronóstico existentes en la literatura.

## AGRADECIMIENTOS

Este trabajo contó con el apoyo de la Universidad Nacional de Córdoba (UNC), FONCYT-PDFT PRH Nº 3 (Programa UNC RRHH03), SECYT UNC, Ingeniería Electrónica e Ingeniería Biomédica de la Universidad Antonio Nariño, Colombia, Agencia Nacional de Promoción Científica y Tecnológica (ANPCyT) y el Departamento de Ingeniería Eléctrica y Electrónica - Universidad Nacional de Córdoba. Leonardo Franco reconoce el apoyo del Ministerio de Economía y Competitividad (España) a través del subsidio TIN2014-58516-C2-1-R que incluye fondos FEDER.

## RREFERENCIAS

- [1] V. Rossi, F. Salinari, S. Poni, T. Caffi, and T. Bettati. Addressing the implementation problem in agricultural decision support systems: The example of vite.net©. Computers and Electronics in Agriculture, 100:88–99, 2014.
- [2] Dickie M.J y Coronel A. Cambio climático, breve historia y tendencias en la Región Húmeda. Published in: Revista "Para Mejorar la Producción" Nº 54. Cultivos Estivales, Marzo de 2016.
- [3] Silvina M. Cabrini, Carlos P. Calcaterra (2016). Modeling economic-environmental decision making for agricultural land use in Argentinean Pampas. Agricultural Systems, vol. 143, March 2016, Pp. 183–194. doi:10.1016/j.agsy.2015.12.016.
- [4] Papajorgji, Petraq J., Pardalos, Panos M. “Advances in Modeling Agriculture Systems” Optimizations and its applications. Volume 25. ISBN: 978-0-387-75181-8, Springer (2009).
- [5] Cristian Rodriguez Rivero; Julian Antonio Pucheta; Victor Hugo Sauchelli; Hector Daniel Patiño. Short time series prediction: Bayesian Enhanced modified Approach with application to cumulative rainfall series. Int. J. of Innovative Computing and Applications, 2016 Vol.7, No.3, pp.153 - 162. DOI: 10.1504/IJICA.2016.078730.
- [6] Cristian Rodriguez Rivero, Daniel Patiño, Julian Pucheta and Victor Sauchelli, “A New Approach for Time Series Forecasting: Bayesian Enhanced by Fractional Brownian Motion with Application to Rainfall Series” International Journal of Advanced Computer Science and Applications (IJACSA), 7(3), 2016. <http://dx.doi.org/10.14569/IJACSA.2016>.
- [7] David J. Mulla (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. Biosystems Engineering: Special Issue: Sensing Technologies for Sustainable Agriculture. Volume 114, Issue 4, April 2013, Pages 358–371. doi:10.1016/j.biosystemseng.2012.08.009.
- [8] Pucheta, J., Patino, D. and Kuchen, B. “A Statistically Dependent Approach For The Monthly Rainfall Forecast from One Point Observations”. In IFIP International Federation for Information Processing Volume 294, Computer and Computing Technologies in Agriculture II, Volume 2, eds. D. Li, Z. Chunjiang, (Boston: Springer), pp. 787–798. (2009).
- [9] J. Kajornrit, K. W. Wong, C. C. Fung and Y. S. Ong, "An integrated intelligent technique for monthly rainfall time series prediction," 2014 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Beijing, 2014, pp. 1632-1639. doi: 10.1109/FUZZ-IEEE.2014.6891619.
- [10] Diana Analía Dominguez, Marcela Hebe Gonzalez. Variabilidad de la Precipitacion en el Centro Oeste de Argentina y un Modelo de Prediccion Estadistica. Meterologica, Vol. 38, No.2 (2013), pp 105-120.
- [11] Penalba, O. C., and W. M. Vargas, 2004: Interdecadal and Interannual variations of annual and extreme precipitation over central-northeastern Argentina. Int. J. Climatology, 24, 12, 1565-1580.
- [12] Ravelo, A. C. 2000. Caracterización agroclimática de las sequías extremas en la región pampeana argentina. Rev. Arg. de Agrometeorología, 20(2): 187-192.
- [13] Beecham, S. and R. K. Chowdhury (2010). Temporal characteristics and variability of point rainfall: a statistical and wavelet analysis. Int. J. Climatology, 30, 458-473.
- [14] J. Alcroft, and C. A. Glasbey, “A latent Guassian Markov random-field model for spatiotemporal rainfall disaggregation”, Applied Statistics, vol. 52(4), 487-498, 2003.
- [15] C. R. Rivero, H. D. Patiño and J. A. Pucheta, "Short-term rainfall time series prediction with incomplete data," 2015 International Joint Conference on Neural Networks (IJCNN), Killarney, 2015, pp. 1-6. doi: 10.1109/IJCNN.2015.7280315.
- [16] C. R. Rivero, J. Pucheta, H. Patiño, J. Baumgartner, S. Laboret and V. Sauchelli, "Analysis of a Gaussian process and feed-forward neural networks based filter for forecasting short rainfall time series," Neural Networks (IJCNN), The 2013 International Joint Conference on, Dallas, TX, 2013, pp. 1-6. doi:10.1109/IJCNN.2013.6706741.
- [17] Joshua Garland, Ryan James and Elizabeth Bradley (2014). Model-free quantification of time-series predictability. Physical Review E 90 (5), 052910. DOI: 10.1103/PhysRevE.90.052910.
- [18] J. Garland and E. Bradley, in Advances in Intelligent Data Analysis XII, Lecture Notes in Computer Science, Vol. 8207, edited by A. Tucker, F. H. oppner, A. Siebes, and S. Swift (Springer Berlin/Heidelberg, 2013) pp. 210-222.
- [19] C. R. Rivero, V. Sauchelli, H. Daniel Patiño, J. A. Pucheta and S. Laboret, "Long-term power consumption demand prediction: A comparison of energy associated and Bayesian modeling approach," 2015 Latin America Congress on Computational Intelligence (LA-CCI), Curitiba, 2015, pp. 1-6. doi: 10.1109/LA-CCI.2015.7435938.
- [20] Alvaro David Orjuela Canon, "A method for the monthly electricity demand forecasting in Colombia based on wavelet analysis and a nonlinear autoregressive model". En: Colombia Ingeniería ISSN: 0121-750X ed: Grupo Editorial Gaia v.16 fasc.2 p.94 - 106 ,2011.
- [21] M. Q. Raza and A. Khosravi, “A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings,” Renewable and Sustainable Energy Reviews, vol. 50, pp. 1352–1372, 2015.
- [22] Alvaro David Orjuela Canon, "Onset and Peak Pattern Recognition on Photoplethysmographic Signals Using Neural Networks". En: Cuba Lecture Notes In Computer Science ISSN: 0302-9743 ed: Springer v.8258 fasc.N/A p.543 - 550 ,2013
- [23] Adriano S. Koshiyama, Tatiana Escovedo, Douglas M. Dias, Marley M. B. R. Vellasco, Marco A. C. Pacheco (2014). Combining Forecasts: A Genetic Programming Approach. International Journal of Natural Computing Research (IJNCR), Vol: 3/3, DOI: 10.4018/jncr.2012070103
- [24] Xiaochen Wang, Peng Guo and Xiaobin Huang (2011). A Review of Wind Power Forecasting Models. Energy Procedia, Vol. 12,pp.770–778. doi:10.1016/j.egypro.2011.10.103.
- [25] M. Bakker, H. van Duist, K. van Schagen and J. Vreeburg, L. Rietvel (2014). Improving the Performance of Water Demand Forecasting Models by Using Weather Input. Procedia Engineering, Vol 70, pp. 93–102. doi:10.1016/j.proeng.2014.02.012.
- [26] Rodolfo C. Cavalcante, Rodrigo C. Brasileiro, Victor L.F. Souza, Jarley P. Nobrega and Adriano L.I. Oliveira (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. Expert Systems with Applications, Vol. 55, pp. 194–211. doi:10.1016/j.eswa.2016.02.006.
- [27] G. A. Darbellay and D. Wuertz. The entropy as a tool for analysing statistical dependences in financial time series. Physica A, 287:429–439, June 2000.

- [28] Cina Aghamohammadia, Mehran Ebrahimianb, Hamed Tahmooresic (2014). Permutation approach, high frequency trading and variety of micro patterns in financial time series. *Physica A: Statistical Mechanics and its Applications*, vol. 413, pp. 25–30.
- [29] Weigend, A.S., Gershenfeld, N.A.: Time Series Prediction: forecasting the future and understanding the past. Addison Wesley, Harlow (1994)
- [30] C. Rodriguez Rivero, J. Pucheta, S. Laboret, H. Patiño, V. Sauchelli, Energy associated tuning method for short-term series forecasting by complete and incomplete datasets. *Journal of Artificial Intelligence and Soft Computing Research*, 2016. Accepted.
- [31] Cristian Rodríguez Rivero, Julián Pucheta, Sergio Laboret, Daniel Patiño, Víctor Sauchelli. Forecasting short time series with missing data by means of energy associated of series. *Applied Mathematics*, 2015, 6, 161-1619. <http://dx.doi.org/10.4236/am.2015.69143>.
- [32] K. Kalpakis, S. Yang, P. F. Hu, C. F. Mackenzie, L. G. Stansbury, D. M. Stein, T. M. Scalea (2015). Permutation entropy analysis of vital signs data for outcome prediction of patients with severe traumatic brain injury. *Computers in Biology and Medicine*, 56:167-74. DOI: <http://dx.doi.org/10.1016/j.combiomed.2014.11.007>
- [33] Nonlinear Dynamical Systems Analysis for the Behavioral Science Using Real Data, Guastello, S. J. and Gregson, R. A. M (Ed.), pp.341-366. CRC Press, Taylor & Francis, 2011.
- [34] Buchanan, M. (2013). Forecast: What Physics, Meteorology, and Natural Sciences Can Teach us about Economics, New York: Bloomsbury.
- [35] Glass L. and M. C. Mackey. From Clocks to Chaos, The Rhythms of Life. Princeton University Press, Princeton, NJ, 1988.
- [36] Abry, P.; P. Flandrin, M.S. Taqqu, D. Veitch., Self-similarity and long-range dependence through the wavelet lens. Theory and applications of long-range dependence, Birkhäuser, pp. 527-556. 2003.
- [37] Dieker, T. Simulation of fractional Brownian motion. MSc theses, University of Twente, Amsterdam, The Netherlands. 2004.
- [38] Lorenz, E. N. (1963). Deterministic nonperiodic flow. *J. Atmos. Sci.* 20 p. 130-141.
- [39] Hénon, M. (1976) A two-dimensional mapping with a strange attractor. *Communications in Mathematical Physics*. Vol. 50, pp. 69–77.
- [40] M.J. Campbell, A.M. Walker, A survey of statistical work on the MacKenzie River series of annual Canadian lynx trappings for the years 1821-1934 and a new analysis, *J. R. Statist. Soc. Ser. A*, vol. 140 pp. 411–431, 1977.
- [41] C. Bandt, B. Pompe. Permutation entropy - a natural complexity measure for time series. *Phys. Rev. Lett.*, 88:(17). 2002.
- [42] C. Rodríguez Rivero, M. Herrera, J. Pucheta, J. Baumgartner, D. Patiño and V. Sauchelli. High roughness time series forecasting based on energy associated of series, *Journal of Communication and Computer*, Vol. 9 No. 5, 2012, pp 576-586, ISSN 1548-7709, USA, David Publishing Company.
- [43] C. Rodríguez Rivero, J. Pucheta, J. Baumgartner, M. Herrera, D. Patiño y B. Kuchen. A NN-based model for time series forecasting in function of energy associated of series, Proc. of the International Conference on Applied, Numerical and Computational Mathematics (ICANCM11), Barcelona, Spain, September 15-17, 2011, ISBN 978-1-61804-030-5, Pp. 80-86. (2011).
- [44] L.P. Wang and X.J. Fu, Data Mining with Computational Intelligence, Springer, Berlin, 2005.
- [45] C. Rodriguez Rivero, J. Pucheta, M. Herrera, V. Sauchelli and S. Laboret, "Time Series Forecasting Using Bayesian Method: Application to Cumulative Rainfall," in IEEE Latin America Transactions, vol. 11, no. 1, pp. 359-364, Feb. 2013. doi:10.1109/TLA.2013.6502830.
- [46] Julián A. Pucheta , Cristian M. Rodríguez Rivero, Martín R. Herrera, Carlos A. Salas, H. Daniel Patiño y Benjamin R. Kuchen, A NN approach for cumulative monthly rainfall time series forecasting tuned by roughness. *International Journal of Physical Sciences* Vol. 7(24), pp. 3018 –3031, 22 June, 2012. <http://www.academicjournals.org/IJPSDOI: 10.5897/IJPS11.857>. ISSN 1992 – 1950.
- [47] Armstrong J.S. (Ed.) Principles of forecasting: Handbook for researchers and practitioners. Kluwer, 2001.
- [48] M. R. Cogollo and J. D. Velásquez. Methodological Advances in Artificial Neural Networks for Time Series Forecasting, in IEEE Latin America Transactions, vol. 12, nro. 4, June 2014. DOI: 10.1109/TLA.2014.6868881.
- [49] M. R. Cogollo and J. D. Velásquez, "Are Neural Networks Able To Forecast Nonlinear Time Series With Moving Average Components?," in IEEE Latin America Transactions, vol. 13, no. 7, pp. 2292 – 2300, July 2015. DOI: 10.1109/TLA.2015.7273790.
- [50] Leung, H., Lo, T., & Wang, S. (2001). Prediction of noisy chaotic time series using an optimal radial basis function neural network. *IEEE Transactions on Neural Networks*, 12, 1163–1172.



**C. Rodriguez Rivero** received Electrical Engineering, and his Ph.D. degree in electrical engineering from Faculty of Exact Sciences, Physics and Nature at Universidad Nacional de Córdoba (UNC), in the topic of computational intelligence applied for intelligence agriculture. His research interest includes topics of automatic control, stochastic and optimal control for intelligence agriculture, time series forecasting, machine learning: Bayesian Learning, neural networks, support vector regression and genetic algorithms. Board of Directors of the LA-CIS and Steering Committee of the LA-CCI (IEEE Latin America Conference on Computational Intelligence – lacci.org). IEEE CIS Argentina Chapter chair since 2013, member of INNS (International Neural Network Society), SIAM (Society for Industrial and Applied Mathematics) Control and Optimization, and AADECA (Argentine Association of Automation and Control).



**J. A. Pucheta** received the Electrical Engineering degree from National University of Technology - Córdoba Regional School, Argentina, the M.S. and Ph.D. degrees from Universidad Nacional de San Juan, Argentina, in 1999, 2002 and 2006, respectively. He is currently Professor at Mathematics Research Laboratory applied to Control (LIMAC), Universidad Nacional de Córdoba, Argentina. His research interests include stochastic and optimal control, time series forecast and machine learning. IEEE member.



**Alvaro D. Orjuela-Cañón** received the B.Sc degree in electronic engineering in Bogotá, Colombia in 2006 from Universidad Distrital Francisco José de Caldas. M.Sc degree in electrical engineering from Universidade Federal de Rio de Janeiro (COPPE/UFRJ) in Brazil in 2009. At the same period, was with Electrical Energy Research Centre (CEPEL) in Brazil. In 2015 earned his Ph. D degree in COPPE/UFRJ. He is an associate professor from Universidad Antonio Nariño in Bogotá, Colombia and recognized associate researcher by Colciencias (Colombian department of science, technology and innovation). He is with GIBIO research group of the electronic and biomedical engineering faculty. In his topics of interest are signal processing, neural networks, machine learning, diagnosis methods and computational intelligence in energy systems. Currently, he is Senior Member of IEEE and Chair of the Colombian chapter of the Computational Intelligence Society.



**Dr. L. Franco (M'06 SM'13)** received M.Sc. and Ph.D. degrees in 1995 and 2000, respectively, both from the National University of Córdoba, Argentina. He was then a postdoctoral researcher at SISSA, Italy and Oxford University, UK. Since 2005, he has been with the Computer Science Department at Malaga University Spain where he is currently an Associate Professor. His research interests include neural networks, computational intelligence, biomedical applications and computational neuroscience. He has authored more than 70 publications in journals and international conferences proceedings.



**Y. J. Túpac Valdivia** is Bachelor in Electronic Engineering by Universidad Nacional de San Agustín (Peru, 1995), Master and Doctor in Electrical Engineering by Pontificia Universidade Católica do Rio de Janeiro (Brazil, 2000, 2005), he is Professor in Computer Science School at Universidad Católica San Pablo (Arequipa, Peru). His research is focused on Computational Intelligence applied to Control, Petroleum Engineering, Projects Economic Evaluation.



**P. Otaño.** was born in Cordoba, Argentina. She is a student of Systems Engineering at National University of Technology, Cordoba. Her current research covers Testing-Automation, Computational Intelligence, Operations Research, Neural Networks and Bayesian learning for Time Series Forecasting. She is as a Member of IEEE CIS and she has collaborated and served as co-

organizer at the 1° Latin America Congress on Computational Intelligence (LA-CCI 2014).



**V. H. Sauchelli** received the Electrical Engineering degree and Ph.D. degrees from Universidad Nacional de Córdoba (UNC) a, Major in University Education from National Technological University, Córdoba Regional School (UTN, FRC.) Argentina, in 1973 and 1997, respectively. He is currently principal at Telecommunication Postgraduate Program, Blas Pascal University, and Professor of Control Systems and Signal Processing in electrical and electronic engineering. He is also Head of Mathematics Research Laboratory applied to Control (LIMAC) and Research Projects at Secretary of Sciences and Technology (SECyT), Universidad Nacional de Córdoba. His interests include automatic control, neural networks, fractional-order controllers and signal processing.