

Filtro predictor basado en redes neuronales para pronóstico de series temporales de lluvia acumulada empleando submuestreo

J. A. Pucheta¹, M. R. Herrera², C. M. Rodríguez Rivero¹, J. S. Baumgartner¹, V. H. Sauchelli¹

¹*Departamentos de Electrotecnia y de Electrónica, Laboratorio de Investigación Matemática Aplicada a Control (LIMAC), Facultad de Ciencias Exactas, Físicas y Naturales - Universidad Nacional de Córdoba, Córdoba, Argentina.*

²*Departamento de Ingeniería Electrónica, Facultad de Tecnología y Ciencias Aplicadas, Universidad Nacional de Catamarca, Catamarca, Argentina.*

Resumen

En éste trabajo se presenta un filtro predictor basado en redes neuronales (RNs) directas para pronóstico de series temporales de alta rugosidad empleando submuestreo, contribuyendo a la nueva generación de herramientas que permiten conocer la previsibilidad de agua de lluvia. Se generan series temporales a partir de submuestrear a una serie dato original, partiendo del valor disponible más reciente hacia el más antiguo. Se usaron series provenientes de la Ecuación Mackey-Glass (MG) de 120 datos, donde se usaron para validar al algoritmo los últimos 18 valores. También se usó una serie de lluvia mensual acumulada proveniente del establecimiento Santa Francisca, Alta Gracia, Córdoba, que tiene 125 valores. Para cada una de las series generadas por el submuestreo, se ajustó a un filtro diferente basado en RNs, y cada uno de ellos genera un pronóstico que luego es promediado en su conjunto. La regla de ajuste utilizada en el proceso de aprendizaje se basa en el método Levenberg-Marquard y el desempeño del filtro propuesto se evalúa a través del índice SMAPE. En muchos casos se obtienen mejoras muy notorias respecto del resultado obtenido mediante el filtro basado en RNs sin submuestreo.

Abstract

In this work, a neural networks (NN) -based predictor filter for forecasting cumulative rainfall sub-sampled time series of high roughness is presented. It is intended to contribute to the generation of tools to ascertain the predictability of rainfall. Time series are generated from a series down sample the original data, based on the latest available value to the oldest. Using series from the Mackey-Glass Equation (MG) 120 data, which were used the last 18 values to validate the algorithm. Series of monthly rainfall accumulated from Santa Francisca, Alta Gracia, Cordoba, were used which consist of 125 values. For each series generated by sub-sampling, was adjusted to a different filter based on NN, and each one generates a forecast that is then averaged together. The adjustment rule used in the learning process is based on the Levenberg-Marquard method and the proposed filter performance is evaluated by SMAPE index. In many cases very noticeable improvements are obtained with respect to the result obtained by filter based on NN without down sampling.

Palabras Clave

Pronostico de series temporales, submuestreo, decimación, redes neuronales, Mackey-Glass.

Introducción

La predicción de los fenómenos naturales es un tema desafiante, en particular la predicción de información acerca de la disponibilidad de agua, muy útil entre otras cosas para los problemas de control de las actividades agrícolas. Se propone generar una metodología para diseñar un sistema capaz de dar una secuencia de valores que representen el escenario futuro de disponibilidad de agua de lluvia.

La motivación de hacer éste proyecto surge de la necesidad de herramientas basadas en conocimiento para que en el momento que el agricultor debe decidirse en sembrar uno u otro tipo de cultivo según la rentabilidad deseada, tenga información estimada por un sistema que sea confiable.

Así, el propósito del sistema es estimar la disponibilidad de agua de lluvia durante el proceso de crecimiento antes de que el agricultor dé comienzo al proceso de siembra del cultivo. No obstante, una vez que se dio inicio al proceso de crecimiento del cultivo, mediante un esquema de control adecuado [15] es posible tomar decisiones en manejo del cultivo que permitan asegurar el rédito de la operación.

Existen varias aproximaciones basadas en redes neuronales (RNs) para predicciones [20], específicamente de lluvias [13], demandas de energía [4], y disponibilidad de agua tomando un conjunto de puntos de medición [11]. Aquí se presenta una propuesta basada en un filtro auto regresivo no lineal (ARN) clásico usando retardos en la red de predicción, tomando los datos de solución la ecuación de Mackey-Glass (MG) como punto de partida [8] [6]. El número de entradas del filtro se pone en función de la cantidad de datos disponibles, de tal manera que cuando los datos son sub muestreados la cantidad de entradas es menor.

Descripción general del enfoque mediante RNs

La motivación fundamental del estudio, se basa en un sistema de control de lazo cerrado, como el que se muestra en la Fig. 1, donde el controlador tiene en cuenta condiciones futuras para el diseño de leyes de control. En este esquema, el controlador toma en cuenta el estado actual del acumulado mensual de lluvia para ser tomados por el observador de estado. Sin embargo, en este artículo se presenta solo la parte concerniente al predictor, tomando como punto de referencia las series temporales. El diseño del controlador que genera acciones sobre el manejo del cultivo, está basado en [15] [16].

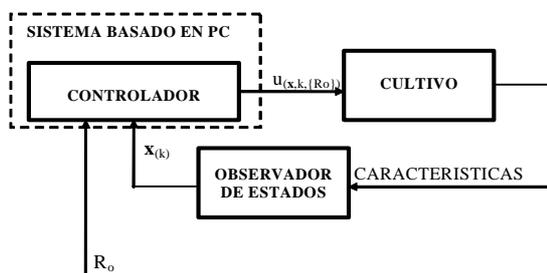


Fig. 1. Esquema del sistema de control que considera secuencias futuras.

La contribución de este trabajo se basa en el proceso de generación de series de datos a partir del submuestreo de una única serie dato, simbolizada en la Fig. 1 por $\{R_0\}$. La serie es generada a partir de valores instantáneos de R_0 . No obstante, para realizar la predicción se requieren de valores históricos de ésta variable.

Para el ajuste de los parámetros del filtro se emplea el algoritmo de Levenberg-Marquardt [3]. Con el fin de mostrar el comportamiento del modelo propuesto se utilizan series de datos de la solución de la ecuación diferencial de MG y de mediciones de lluvia en campo, del Establecimiento Santa Francisca, San Ignacio, Córdoba. El filtro basado en RN se aplica a la serie dato para predecir 18 valores futuros tomando una base histórica de 102 valores de la serie.

Descripción general de la ecuación de Mackey-Glass (MG)

La ecuación de MG es muy difundida en el modelado de fenómenos naturales y ha sido usada por diferentes autores para realizar comparaciones entre diferentes técnicas de pronósticos y modelos de regresión [6] [19]. Aquí se propone un algoritmo para predecir los valores de series de tiempo tomada como solución de la ecuación de MG [8]. La ecuación de MG está descrita como una ecuación diferencial con retardo en el tiempo de la forma

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

donde α , β , y c son parámetros y τ es el tiempo de retardo.

De acuerdo al valor que tome τ , la solución es una serie que puede transformarse de periódica a caótica no periódica. La ecuación (1) se resuelve a partir de la integración numérica usando el método de Runge-Kutta de cuarto orden. La serie para pronosticar está formada por valores de muestreo con un intervalo de tiempo determinado. Esta serie puede cambiar radicalmente su comportamiento cambiando las condiciones iniciales. Aquí se fijó el parámetro $\beta=0,1$ $\alpha=20$, $c=10$ $\tau=100$.

Descripción general del submuestreo

En este trabajo se implementa un muestreo de la serie de datos, para formar varias series diferentes. En cada una de éstas se pretende utilizar la misma estructura del filtro predictor para determinar los valores futuros a un paso. En la Fig. 2 se muestra un ejemplo de una serie temporal, originadas mediante la función senoidal

$$y_k = \text{sen}(\alpha k), \quad \alpha = \frac{\pi}{50}, \quad k = 0, 1, 2, \dots, 102, \quad (2)$$

donde αk varía de 0 a 2π .

A partir de la serie (2) se genera una segunda serie muestreando a cada k impar, lo que resulta

$$y_k^D = y_k, \quad D = 2, \quad k = 0, 2, 4, 6, \dots, 102, \quad (3)$$

siendo la cantidad de pasos que se submuestra de D , y en éste artículo varía de 2 a 7, no obstante, en la Fig. 2 se muestran las series obtenidas cuando D varía de 1 a 4. Nótese que una serie submuestreada tiene su valor futuro a un paso coincidente con la serie original en cada punto submuestreado, por lo que el Δt pasa de 1 a 2, 3, etc Δt de la serie original.

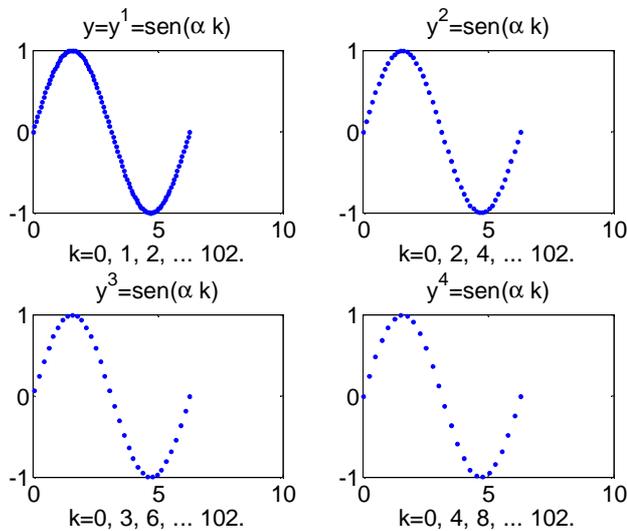


Fig. 2. Serie original y^D , series submuestreadas con decimación de D de 1, 2, 3 y 4.

Descripción general del movimiento Browniano Fraccional

En este trabajo el parámetro de Hurst es usado como indicador de similitud entre series temporales, específicamente la rugosidad [12] de la serie generada por el filtro predictor. La definición de H surge de la generalización de la definición del Movimiento Browniano, pasando de una integral de orden 1 a la de orden H, y presenta una forma especial de los incrementos varianza que sugiere diversas formas de estimar al parámetro H, ya que hay diversos métodos para calcular H asociado a un mB [2] [5] [10].

En este trabajo se usa un método basado en el algoritmo de Wavelet que estima H a partir del mBf [1] [5] [7].

Medición del desempeño del filtro predictor

El desempeño del filtro es evaluado usando el índice SMAPE (Symmetric Mean Absolute Percent Error), error medio absoluto simétrico porcentual. Propuesto en la mayoría de evaluaciones métricas, definido por

$$SMAPE_s = \frac{1}{n} \sum_{t=1}^n \frac{|X_t - F_t|}{(X_t + F_t)/2} \cdot 100 \quad (4)$$

donde, t es el tiempo de observación, n es el tamaño de la muestra, s es cada serie de tiempo, X_t y F_t son los valores el actuales y los pronosticados de la serie de tiempo a un tiempo t respectivamente. El SMAPE para cada serie s calcula el error simétrico absoluto en porcentaje del valor entre el actual X y el correspondiente pronóstico F, a través de todas las observaciones de t del conjunto de pruebas de tamaño n para cada serie de tiempos s.

Formulación del problema

Una predicción clásica puede ser formulada como sigue. Dados los valores pasados de un proceso uniformemente espaciados $x(n-1)$, $x(n-2)$, . . . , $x(n-m)$, con un intervalo de

muestreo T y un orden de predicción m , se desea predecir el valor presente $x(n)$ para tales procesos.

Por lo tanto, se desea la mejor predicción de los valores presentes de una señal respecto de un criterio definido. El sistema predictor es implementado usando un modelo autorregresivo no lineal adaptativo. Las RNs son usadas como construcción de un modelo no lineal que presentan, en sentido estadístico, el menor error de predicción [14] [20]. Estas RNs sirven para modelar procesos reales responsables de generación de datos [4] [11] [18]. En este trabajo se utilizan redes directas con tiempos de retardos [9].

El valor actual de la serie temporal se utiliza como la respuesta deseada del filtro adaptativo y los valores pasados de la señal son las entradas de este filtro. Entonces la salida del filtro será la predicción en un paso de la señal. En la Fig. 3 se muestra el diagrama en bloques de una predicción basada en filtro de RN no-lineal.

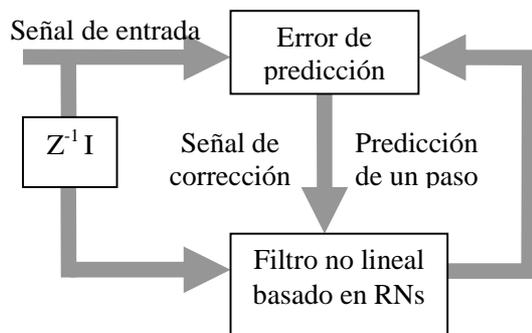


Fig. 3. Diagrama en bloques del sistema predictor.

Aquí, el dispositivo está diseñado de tal manera que la predicción sea a partir de una determinada secuencia $\{x_n\}$ en un tiempo n correspondiente a una serie temporal y se pueda obtener la mejor predicción $\{x_e\}$ para los siguientes 18 valores de secuencia. Por lo tanto, se propone un filtro predictor con un vector de entrada de dimensión l_x , el cual es obtenido por la aplicación de un operador de retardo Z^{-1} para la secuencia $\{x_n\}$. Entonces la salida del filtro podrá generar x_e como el próximo valor, que será igual al valor presente x_n , de manera que el error de predicción en un tiempo k puede ser evaluado como

$$e(k) = x_n(k) - x_e(k) \quad (5)$$

el cual es usado por la regla de aprendizaje para ajustar los parámetros de la RN.

Esquema propuesto

Algunos resultados han sido obtenidos desde una aproximación lineal autorregresiva la cual se detalla en [18]. Estos resultados fueron prometedores y se desea mejorarlos por filtros más sofisticados. Ahora, se propone un modelo de filtro NAR [9] [14] [20] la RN usada es realimentada con retardos en el tiempo.

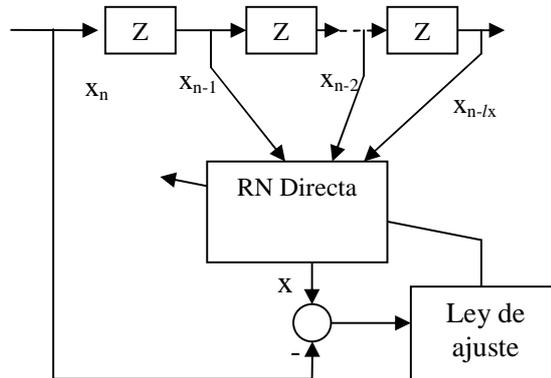


Fig. 4. Filtro predictor no lineal basado en RNs. El operador retardo se simboliza con Z.

La topología de la RN consiste en l_x entradas, una capa oculta de H_o neuronas, y una neurona de salida, como muestra la Fig. 4. El algoritmo de aprendizaje utilizado es el método de Levenberg-Marquardt [3]. Con el fin de predecir la secuencia $\{x_e\}$ un paso adelante, el primer valor sin retardo que se toma desde la línea es x_n , que se toma como entrada. De esta manera, la predicción de salida puede ser expresada como

$$x_e(n+1) = F_p(Z^{-1}I(\{x_n\})) \quad (6)$$

donde, F_p es el operador del filtro predictor no-lineal, y $x_e(n+1)$ la salida del predictor en n . Para lograr la serie pronosticada, el valor generado de $x_e(n+1)$ es utilizado como entrada del filtro F_p con el retardo adecuado,

$$x_e(n+2) = F_p(Z^{-1}I(\{x_n, x_e(n+1)\})) \quad (7)$$

y se logra el valor $x_e(n+2)$, que a su vez es retrasado e ingresado como entrada para obtener mediante (6) el valor $x_e(n+3)$,

$$x_e(n+3) = F_p(Z^{-1}I(\{x_n, x_e(n+1), x_e(n+2)\})) \quad (8)$$

y así sucesivamente hasta un valor $x_e(n+D_e)$,

$$x_e(n+D_e) = F_p(Z^{-1}I(\{x_n, x_e(n+1), \dots, x_e(n+D_e-1)\})) \quad (9)$$

que en el caso de la serie original aquí se pretende llegar hasta 18.

No obstante, el uso de la serie $\{x_n\}$ exige al filtro predictor F_p una gran amplitud de velocidad de respuesta, ya que la secuencia $\{x_n\}$ puede tener cambios muy bruscos de un intervalo de tiempo a otro. Para encarar ésta característica del proceso de predicción, en éste artículo se propone implementar el submuestreo con intención de suavizar la serie $\{x_n\}$.

Solución propuesta

La metodología consiste en generar series temporales a partir de submuestrear a la serie original $\{x_n\}$, partiendo del último valor disponible hacia el más antiguo. Así, muestreando con un intervalo se obtiene una serie, con dos intervalos otra, y así hasta por ejemplo 7 intervalos, según la serie dato lo permita. Así, submuestreando cada un intervalo a $\{x_n\}$ se obtiene la secuencia $\{x_n\}^2$, que tendrá la mitad de elementos que $\{x_n\}$, con una decimación $D=2$. Consecuentemente, con $D=3$ se obtiene $\{x_n\}^3$ y en general, con D se obtiene la secuencia $\{x_n\}^D$.

Con cada una de las secuencias $\{x_n\}^D$ se implementa un filtro F_p específico, que generará predicciones para cada serie según (6). De esta manera, si existen s series correspondientes a la secuencia $\{x_n\}$, existirán s filtros F_p que implementarán la predicción (6). Los valores que se obtienen de implementar (6) se promedian para generar la salida del filtro propuesto. Por lo tanto, se tiene que

$$x_e^s(n+1) = \frac{1}{s} \sum_s F_p^s(Z^{-1}I(\{x_n\}^s)), \quad (10)$$

donde x_e^s es la variable a predecir cuyo argumento $n+1$ se ubica en la serie con una decimación D según indique el índice s , la secuencia $\{x_n\}^s$ se corresponde con $\{x_n\}^D$ con el cambio adecuado de índices, y F_p^s se refiere al filtro predictor para cada secuencia $\{x_n\}^s$.

Cabe aclarar que cada vez que se implementa la expresión (6) según el procedimiento (7)-(8)-(9) en las series submuestreadas, el valor de $D_e(n+1)$ va a cambiar, ya que va a disminuir según lo implique D . Así, para $s=1$ $D_e=18$, pero para $s=2$ $D_e=9$, para $s=3$ $D_e=6$, y así sucesivamente.

Principales resultados

El algoritmo propuesto se ensayó con series provenientes de la Ecuación MG (1), cuyos parámetros α , β , c , y τ fueron fijados en 0,2, 0,1, 10 y 30 respectivamente. La longitud de la serie es de 120 datos, donde se usaron para validar al algoritmo los últimos 18 valores. También se usó una serie de lluvia mensual acumulada proveniente del establecimiento Santa Francisca, Alta Gracia, Córdoba, que tiene 125 valores.

Se definieron dos clases de datos en cada conjunto de valores, uno de estos usado por el algoritmo para realizar el ajuste del filtro, clase que tiene 102 valores, los otros valores de la serie son usados para validar la predicción del sistema y definen la clase validación, para determinar si la predicción es aceptable o no, en los 18 últimos valores. De esta manera los 102 valores del conjunto de datos usados para el pronóstico sumados a los 18 valores de validación darán un conjunto de datos reales de 120 valores. Con las series de Santa Francisca se hizo algo similar, ya que se pretendió predecir los últimos 18 valores de la serie.

Configuración del modelo y proceso del ajuste

Las condiciones iniciales del filtro y el algoritmo de aprendizaje son mostradas en la Tabla 1. Nótese que el número de neuronas en la capa oculta y de iteraciones son ajustadas en función del número de entradas. Las condiciones iniciales del algoritmo de aprendizaje son usadas para el pronóstico de series temporales, cuya longitud de la serie de datos es de 102 o 107 valores cada una.

Tabla 1. Parámetros del algoritmo de ajuste

Variable	Símbolo	Valor
Número de entradas	l_x	$D \cdot D_e$
Número de patrones	N_p	l_x
Número de neuronas en la capa oculta	H_o	l_x+3
Número de iteraciones	i_t	$4 \cdot l_x+10$

Resultados obtenidos en la prueba con MG

Los resultados obtenidos son mostrados en las figuras Fig. 5 a Fig. 10. En la Fig. 5 se muestra el pronóstico obtenido para el caso de la serie $\{x_n\}_1^T$, y en la Fig. 6 se muestra el detalle de la validación del algoritmo, donde están superpuestas las series reales y pronosticadas a un paso. Luego se comienza a implementar el filtro aquí propuesto mediante (10), donde las Fig. 7 y Fig. 8 muestran lo obtenido para el caso de $D=\{1,2\}$, y finalmente en las Fig. 9 y Fig. 10 para $D=\{1,2,3,4\}$.

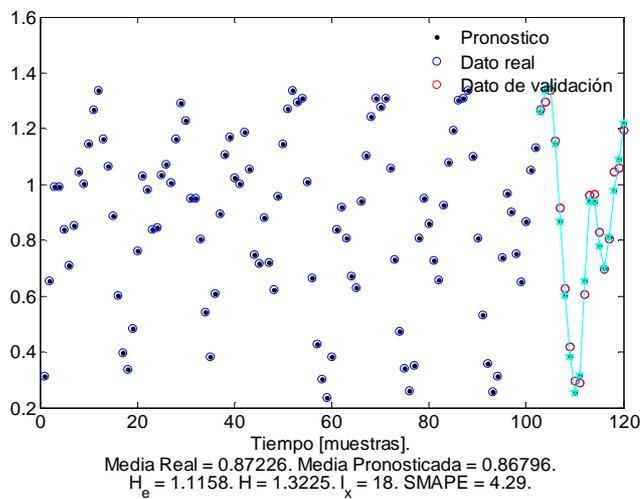


Fig. 5. Pronóstico realizado sin decimación con la serie original.

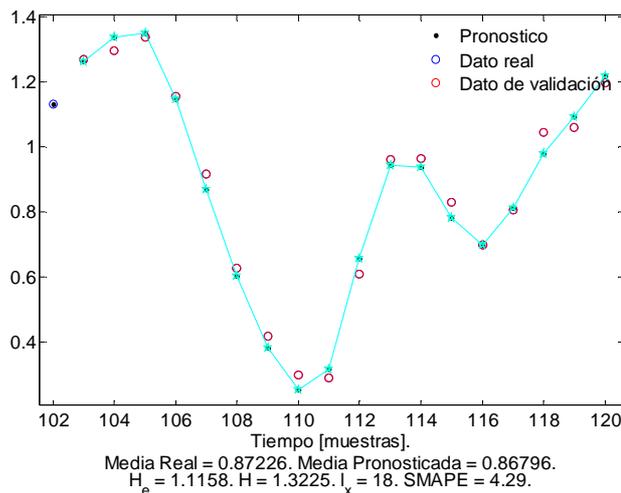


Fig. 6. Validación del pronóstico realizado sin decimación sobre la serie original.

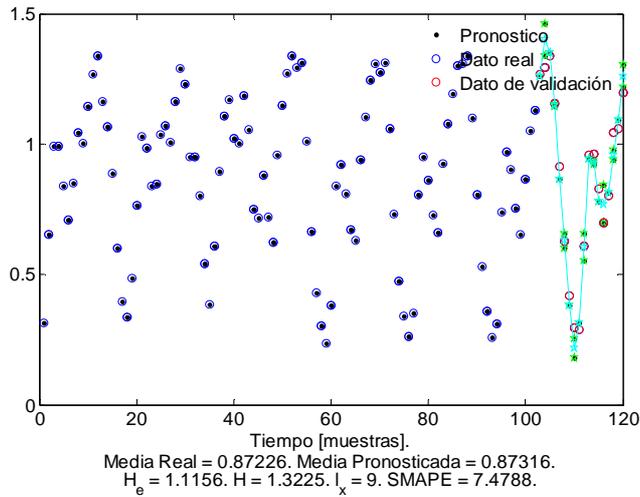


Fig. 7. Pronostico realizado mediante (10) usando $D=\{1,2\}$ sobre la serie original.

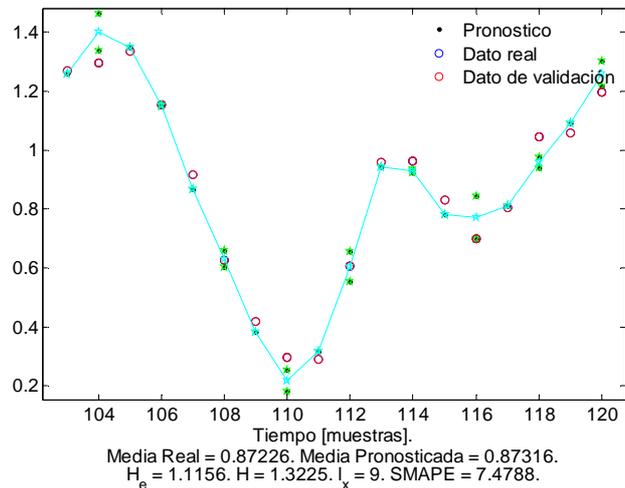


Fig. 8. Validación del pronostico realizado con $D=\{1,2\}$ mediante (10) sobre la serie original.

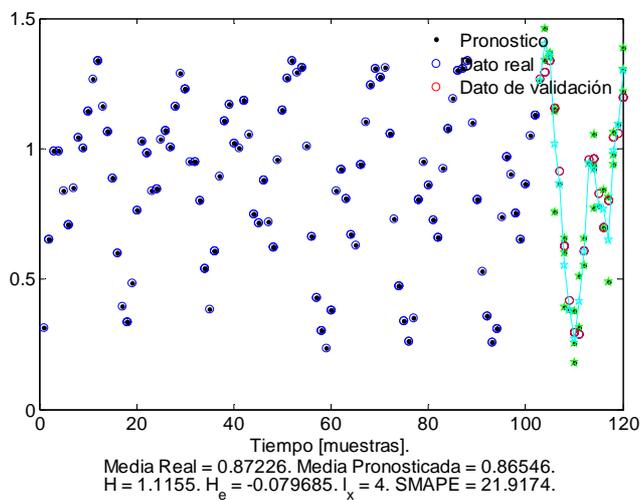


Fig. 9. Pronostico realizado mediante (10) usando $D=\{1,2,3,4\}$ sobre la serie original.

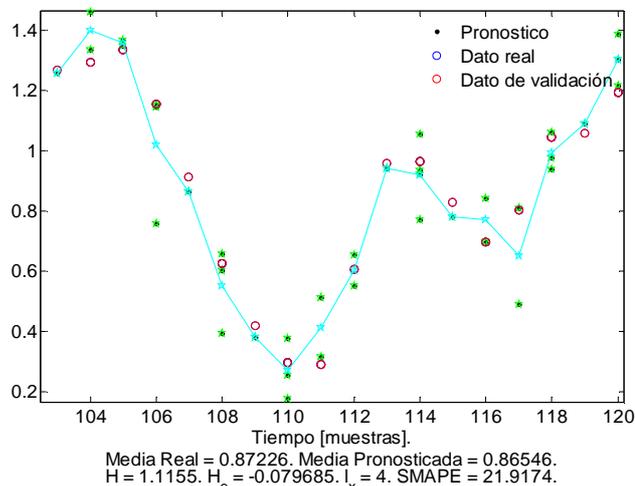


Fig. 10. Validación del pronostico realizado con $D=\{1,2,3,4\}$ mediante (10) sobre la serie original.

Resultados obtenidos en la prueba con Santa Francisca

Los resultados obtenidos en el ensayo del filtro predictor (10) aplicado a la serie de Santa Francisca, son mostrados en las figuras Fig. 11 a Fig. 16. Al igual que en el caso MG, en la Fig. 11 se muestra el pronóstico obtenido para el caso de la serie $\{x_n\}^1$, y en la Fig. 12 se muestra el detalle de la validación del algoritmo, donde están superpuestas las series reales y pronosticadas a un paso. Luego se comienza a implementar el filtro aquí propuesto mediante (10), donde las Fig. 13 y Fig. 14 se muestra lo resultante para el caso de $D=\{1,2\}$, en las Fig. 15 y Fig. 16 para $D=\{1,2,3\}$.

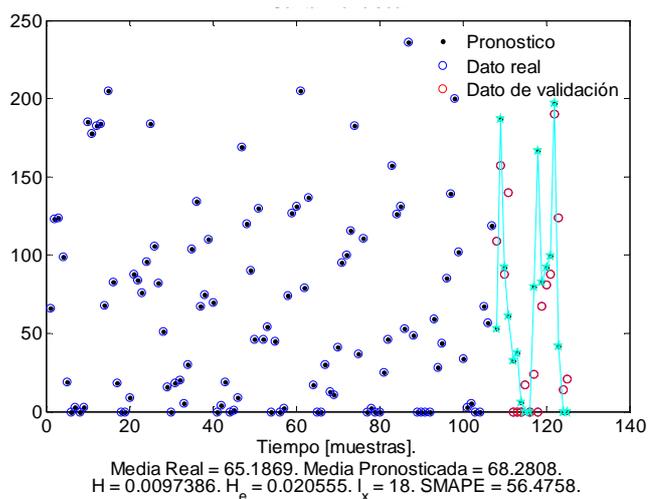


Fig. 11. Pronostico realizado sin decimación con la serie original.

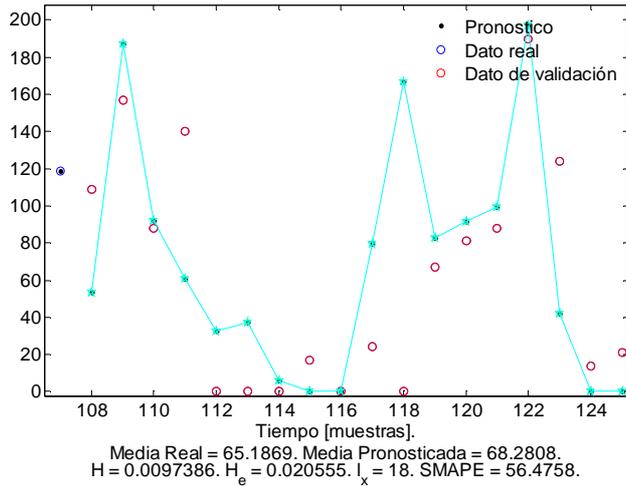


Fig. 12. Validación del pronóstico realizado sin decimación sobre la serie original.

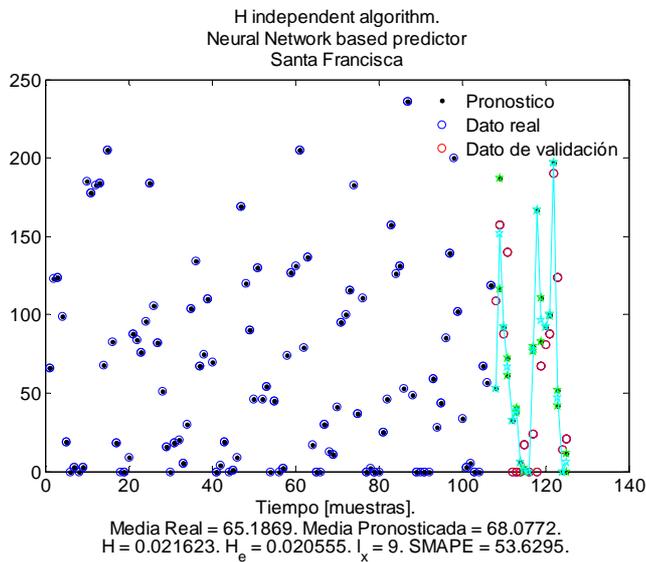


Fig. 13. Pronostico realizado mediante (10) usando $D=\{1,2\}$ sobre la serie original.

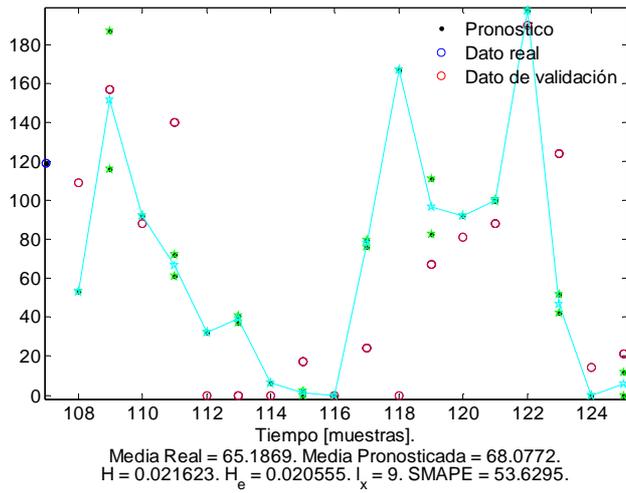


Fig. 14. Validación del pronóstico realizado con $D=\{1,2\}$ mediante (10) sobre la serie original.

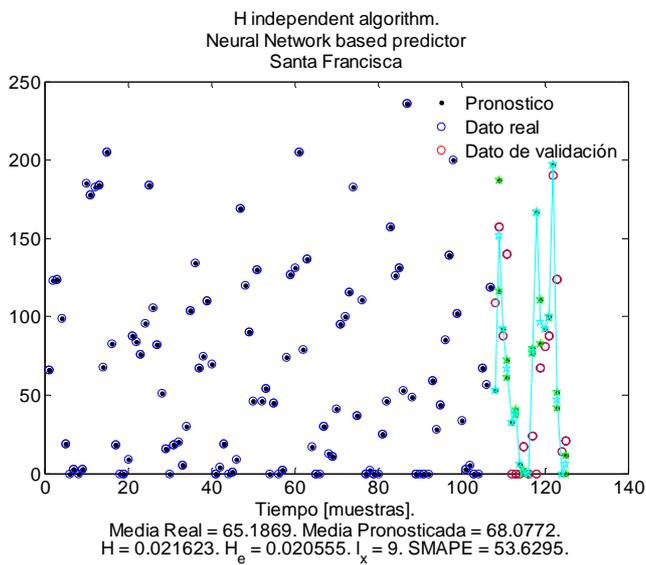


Fig. 15. Pronóstico realizado mediante (10) usando $D=\{1,2,4\}$ sobre la serie original

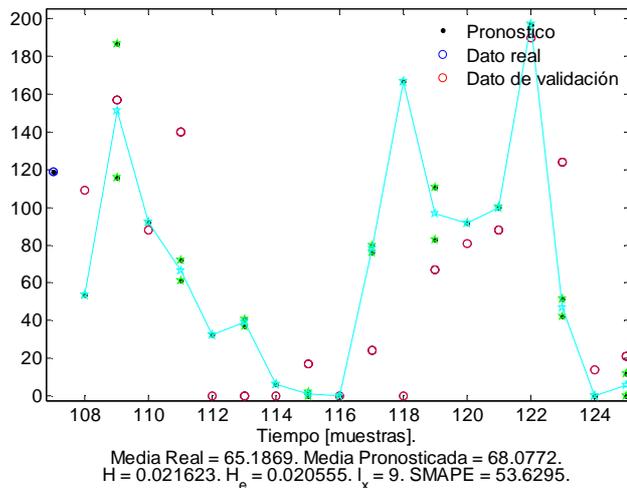


Fig. 16. Validación del pronóstico realizado con $D=\{1,2,4\}$ mediante (10) sobre la serie original.

Resultados obtenidos

En la Tabla 2 se muestran los resultados obtenidos para las dos series de prueba. Nótese que el objetivo es que la Media real sea aproximada por la Media pronosticada por el filtro, y que ésta serie pronosticada junto con la serie dato presente una rugosidad similar. Si se utilizara el filtro lineal promedio, es decir media histórica desde Diciembre de 2008 hasta Mayo de 2010, la Media Pronosticada sería 74,57 mientras que la real es de 65,18.

Tabla 2. Valores obtenidos. La Media real en MG(30) es 0,87226 y en Santa Francisca es 65,18. La rugosidad H en Santa Francisca es 0,0205, y en MG es 1.

Variable	MG			Santa Francisca		
	{D} y (10)	{1,2}	{1,2,3,4}	1	{1,2}	{1,2,4}
Media Pronosticada	0,86	0,87	0,865	68,28	68,07	68,07
H, rugosidad	1	1	1	0,0097	0,0216	0,0216
SMAPE	4,29	7,4788	21,9	56,47	53,64	53,62

Nótese que en algunas series MG se obtienen mejoras en cuanto al índice SMAP, pero en el caso de la serie de Santa Francisca, es más pronunciada la mejora respecto del SMAP, el error en cuanto a la Media pronosticada tiende a disminuir, y el parámetro de rugosidad H tiende a aproximarse al de la serie dato.

Discusión

Los resultados muestran que es posible mejorar la predicción de series temporales mediante un filtro que utilice el submuestreo. Fue elegida la serie MG(30) porque presenta una media y una rugosidad desafiante para cualquier algoritmo predictor, y facilita el ajuste para el caso de la serie de Santa Francisca. No obstante, el desempeño del filtro fue mejor en la serie de Santa Francisca. Se han ensayado otras series MG en las cuales se obtuvieron buenos resultados, pero no fueron agregadas a éste artículo para mantener poco contenido y representativo. En la serie de Santa Francisca se hicieron diversos ensayos, y se muestran los que mejor representan el desempeño del filtro aquí propuesto. Resta probar

combinaciones de $\{D\}$, por ejemplo $\{1,3\}$ o $\{1,3,4\}$ tratando de mejorar el desempeño. El concepto que explota el filtro propuesto que es cuando se pronostica series suaves, el desempeño es mejor que cuando las series son rugosas. Por lo tanto, el efecto buscado mediante el submuestreo es el de suavizar la serie. Por otro lado, El algoritmo propuesto aquí separa en varios filtros predictores a partir del submuestreo de la serie original, y a las salidas generadas por estos filtros son promediadas, sin ponderar algún filtro sobre el otro. El efecto de ponderar el promedio, es un desafío que puede generar un beneficio en el desempeño.

Cabe aclarar, que los resultados aquí expuestos pretenden mostrar que la metodología es capaz de predecir con 18 pasos hacia adelante, lo que en éste proceso real significan 18 meses a futuro, sólo basado en la hipótesis de que la rugosidad de la serie o proceso es invariante, lo cual es una afirmación fuerte.

Conclusiones

En este trabajo se presentó un modelo de un filtro predictor para pronóstico de series temporales de alta rugosidad empleando submuestreo. La contribución reside en generar series suaves a partir de una serie dato, que permiten ajustar los parámetros de un filtro para cada sub serie y luego se promedian las salidas. La ley de ajuste de los parámetros de la RN se basa en el método de Levenberg-Marquardt.

Se submuestreó a la serie dato uniformemente, de a valores enteros, procedimiento que mostró ser directo y simple, aunque perfectible. La rugosidad de la serie pronosticada resultante fue evaluada por el parámetro de Hurst H .

Los resultados principales muestran un buen desempeño del sistema predictor, aplicado a series obtenidas de las soluciones de la ecuación MG(30), considerando la rugosidad y la media con intención de representar series de lluvia como por ejemplo las aquí presentadas de Santa Francisca. Estos resultados nos incentiva a seguir trabajando en nuevos algoritmos de aprendizaje automático y submuestreo, aplicando otros métodos.

Agradecimientos

Los autores agradecen el apoyo de la Universidad Nacional de Córdoba (Secyt UNC), de la Universidad Nacional de Catamarca (UNCa), y de la Agencia Nacional de Promoción Científica y Tecnológica (ANPCyT), PICT-2007-00526.

Referencias

- [1] Abry, P.; P. Flandrin, M.S. Taquq, D. Veitch., “*Self-similarity and long-range dependence through the wavelet lens*”. Theory and applications of long-range dependence, Birkhäuser, pp. 527-556. 2003.
- [2] Bardet, J.-M.; G. Lang, G. Oppenheim, A. Philippe, S. Stoev, M.S. Taquq. “*Semi-parametric estimation of the long-range dependence parameter: a survey*”. Theory and applications of long-range dependence, Birkhäuser, pp. 557-577. 2003.
- [3] Bishop, C. *Pattern Recognition and Machine Learning*. Boston: Springer, 2006.
- [4] Chow, T.W.S.; Leung, C.T. “*Neural network based short-term load forecasting using weather compensation*”. Power Systems, IEEE Transactions on, Vol.11, Iss.4, Nov 1996, Pp. 1736-1742.
- [5] Dieker, T. *Simulation of fractional Brownian motion*. MSc theses, University of Twente, Amsterdam, The Netherlands. 2004.
- [6] Espinoza Contreras, Adriana Eliza. *El Caos y la caracterización de series de tiempo a través de técnicas de la dinámica no lineal*. Universidad Autónoma de Mexico. Campus Aragón. 2004.
- [7] Flandrin, P. “*Wavelet analysis and synthesis of fractional Brownian motion*” IEEE Trans. on Information Theory, 38, pp. 910-917. 1992.

- [8] Glass, L. and M. C. Mackey. *From Clocks to Chaos, The Rhythms of Life*. Princeton University Press, Princeton, NJ, 1988.
- [9] Haykin, S. *Neural Networks: A comprehensive Foundation*. 2nd Edition, Prentice Hall. 1999.
- [10] Istas, J.; G. Lang. “Quadratic variations and estimation of the local Hölder index of a Gaussian process”. *Ann. Inst. Poincaré*, 33, pp. 407-436. 1994.
- [11] Liu, J.N.K.; Lee, R.S.T. “Rainfall forecasting from multiple point sources using neural networks”. In *proc. of the International Conference on Systems, Man, and Cybernetics*, Pages:429-434 Vol.3.1999.
- [12] Mandelbrot, B. B. *The Fractal Geometry of Nature*, Freeman, San Francisco, CA. 1983.
- [13] Masulli, F., Baratta, D., Cicione, G., Studer, L. “Daily Rainfall Forecasting using an Ensemble Technique based on Singular Spectrum Analysis”. In *Proceedings of the International Joint Conference on Neural Networks IJCNN 01*, pp. 263-268, vol. 1, IEEE, Piscataway, NJ, USA, 2001.
- [14] Mozer, M. C. “Neural Net Architectures for Temporal Sequence Processing”. A. S. Weigend and N. A. Gershenfeld, eds. *Time Series Predictions: Forecasting the Future and Understanding the Past*. pp. 243-264. Reading, M.A.: Addison-Wesley. 1994.
- [15] Pucheta, J., Patiño, H., Schugurensky, C., Fullana, R., Kuchen, B. “Optimal Control Based-Neurocontroller to Guide the Crop Growth under Perturbations”. *Dynamics Of Continuous, Discrete And Impulsive Systems Special Volume Advances in Neural Networks-Theory and Applications. DCDIS A Supplement, Advances in Neural Networks, Watam Press, Vol. 14(S1)*, pp. 618—623. 2007.
- [16] H. Daniel Patiño, Julián Pucheta, and Santiago Tosetti. “Approximate Optimal Control for Crop Production in Intelligent Greenhouses”. 37° JAIHO - Jornadas de Inf. Ind. - Agroinformática (JII 2008 Agroinfo), pp. 66-84, 2008.
- [17] Pucheta, J., Patiño, H.D. and B. Kuchen, “Neural Networks-Based Time Series Prediction Using Long and Short Term Dependence in the Learning Process”. In *proc. of the 2007 International Symposium on Forecasting*, 24th to 27th of June 2007 Marriott Marquis Times Square, New York. 2007.
- [18] Pucheta, J., Patiño, H. D., Kuchen, B. “A Statistically Dependent Approach for the Monthly Rainfall Forecast from One Point Observations”. In *Proc. of the Second IFIP Conference on Computer and Computing Technologies in Agriculture (CCTA2008)* October 18-20. Beijing, China. 2008.
- [19] Velásquez Henao, Juan David, Dyna, Red. “Pronóstico de la serie de Mackey glass usando modelos de regresión no-lineal”. Universidad Autónoma de Mexico. Campus Aragón. 2004.
- [20] Zhang, G.; B.E. Patuwo, and M. Y. Hu. “Forecasting with artificial neural networks: The state of art”. *J. Int. Forecasting*, vol. 14, pp. 35-62. 1998.

Datos de Contacto

Julián Antonio Pucheta. Laboratorio de Investigación Matemática Aplicada a Control, Facultad de Ciencias Exactas, Físicas y Naturales, Universidad Nacional de Córdoba. Vélez Sarsfield 1611, Córdoba, Argentina. CP X5016GCA. julian.pucheta@gmail.com.