

Methodological Advances in Artificial Neural Networks for Time Series Forecasting

M. R. Cogollo and J. D. Velásquez, *Senior Member, IEEE*

Abstract— Objective: The aim of this paper is to analyze the development of new forecasting models based on neural networks using the guidelines of the synthesis method, systematic literature review. **Method:** We used the systematic literature review method employing a manual search of papers published on new neural networks models in the time period 2000 to 2013. **Results:** Only 19 studies meet all the requirements of the inclusion criteria. Of these, only three proposals considered a neural networks model using a process different to the autoregressive. **Conclusion:** Although studies relating to the application of neural network models were frequently present, we find that the studies proposing new forecasting models based on neural networks with a theoretical support and a systematic procedure for the construction of model, were scarce in the time period 2000-2013.

Keywords— Nonlinear models, Neural networks models, Forecasts, Innovation, Search methods.

I. INTRODUCCIÓN

EL PRONÓSTICO de series de tiempo es un problema general de gran interés práctico en muchas disciplinas debido a que permite descubrir, con algún margen de error, los valores futuros de una serie a partir de sus valores pasados [1, 2]. En la literatura más relevante se han presentado numerosas aplicaciones exitosas en diferentes campos de aplicación, como por ejemplo, la economía [3], las finanzas [4] y la hidrología [5].

A partir del trabajo seminal de Box y Jenkins [41] en la década del 70, se dio paso a un importante esfuerzo en el estudio y aplicación de modelos lineales compuestos por modelos matemáticos que representan procesos autorregresivos (AR) y procesos de promedios móviles (MA). Mientras que en los procesos AR se supone que el valor actual de la serie de tiempo es una combinación lineal de sus valores pasados, en los procesos MA se supone que dicho valor actual es función de las perturbaciones aleatorias pasadas que han afectado dicha serie. Muchas experiencias prácticas han demostrado que esta aproximación permite representar la dinámica de muchas series de tiempo reales, lo que popularizado esta clase de modelos tanto en el campo académico como en el profesional [4].

No obstante, también se ha encontrado que muchas series de tiempo reales parecen seguir comportamientos no lineales y que la aproximación de Box y Jenkins [6] es insuficiente para representar dichas dinámicas [2, 7, 14]. Es así como en la literatura más relevante se ha presentado una amplia gama de

modelos que proponen diferentes representaciones matemáticas de la no-linealidad presente en los datos [1, 2, 14-16], tales como los modelos basados en regímenes [6, 14] y diferentes tipos de redes neuronales artificiales (ANN, por su sigla en inglés) [2, 17-19].

Particularmente, las ANN han recibido bastante atención por la comunidad científica, lo que se ha traducido en un importante esfuerzo investigativo evidenciado por la gran cantidad de publicaciones sobre este tema; es así, como una simple búsqueda en SCOPUS con las cadenas "neural networks" AND "time series" reporta más de 6.000 documentos encontrados, muchos de los cuales podrían resultar irrelevantes ante las necesidades del investigador.

Es indudable que en la literatura se han propuesto un número importante de arquitecturas de ANN. La gran mayoría de modelos propuestos se basan en sumar una función no lineal al modelo AR, tal como es el caso de la red neuronal artificial con arquitectura dinámica (DAN2, por su sigla en inglés) [20, 21] o las redes neuronales autorregresivas [10, 22, 23]; aplicar una función no lineal al modelo AR, como en el caso del perceptron multicapa [11]; o hibridar con otros modelos que capturen la componente lineal [24, 25].

A pesar del éxito alcanzado por las ANN, también es cierto que aparentemente persisten, desde la década de los 90s, varios problemas relacionados con la adecuada especificación del modelo [19]. Esto es evidenciado por el hecho de que la mayor parte de las decisiones en el proceso de especificación son subjetivas y están basadas en la experiencia del modelador [13]. Es así como, aparentemente, no se ha llegado a un procedimiento completamente sistemático para la especificación formal de modelos de ANN [26].

Otro de los problemas persistentes, es que hay una ausencia notoria de desarrollos en la extensión del modelo MA usando ANN [27] en comparación con las extensiones del modelo AR. De esta forma, puede considerarse que la gran parte de ANN propuestas en la literatura están basadas en una estructura autorregresiva no lineal, tal como ya se indicó. Esta restricción no permite que se modele apropiadamente series de tiempo que contienen una componente inherente MA [27].

El racionamiento planteado hasta aquí motivo las preguntas de investigación formuladas a continuación:

- RQ1. ¿Cuáles son los nuevos modelos basados en redes neuronales artificiales que han sido propuestos desde el año 2000 hasta el año 2013?
- RQ2. ¿Cuáles de los modelos propuestos consideran una estructura diferente a la autorregresiva?
- RQ3. ¿Los estudios publicados presentan una aproximación sistemática, paso a paso, para la construcción del modelo?

M. R. Cogollo, Universidad EAFIT, Medellín, Colombia, mcogollo@eafit.edu.co

J. D. Velásquez, Universidad Nacional de Colombia, Sede Medellín, Medellín, Colombia, jdvelasq@unal.edu.co

RQ4. ¿Cuáles son los problemas pendientes por resolver en las nuevas aproximaciones propuestas?

De esta forma, el objetivo de este trabajo es responder las preguntas de investigación anteriores a partir del análisis de las evidencias documentales presentadas en la literatura más relevante usando la metodología de Revisión Sistemática de Literatura (SLR, por su sigla en inglés).

La importancia de este trabajo está fundamentada en dos aspectos: primero, las revisiones de literatura realizadas hasta ahora no han analizado hasta qué punto se avanza en el planteamiento de una estrategia sistemática de especificación; por ejemplo, no se analiza si en los artículos seleccionados se desarrollan aspectos como: selección de la arquitectura, selección de las variables de entrada, estimación de parámetros o evaluación del modelo [3]. Dichas revisiones tampoco analizan si se desarrollan propuestas basadas en componentes diferentes a la autorregresiva. Segundo, en este trabajo se discuten algunos problemas pendientes de solución y que pueden ser el punto inicial de investigaciones futuras.

El resto de este artículo está organizado como sigue. En la Sección II, se presenta la metodología de investigación. En la Sección III se describen los resultados obtenidos; seguidamente, en las Secciones IV y V se presentan la discusión y las conclusiones obtenidas respectivamente.

II. METODOLOGÍA

En este estudio se aplicó la metodología de Revisión Sistemática de Literatura (SLR) desarrollada por Kitchenham [28] en el contexto de la ingeniería de software. Dicha metodología promueve el uso de una estrategia sistemática que permite buscar, identificar y sintetizar la evidencia documental con el fin de responder una determinada pregunta de investigación. La SLR permite superar las falencias propias de la revisión informal o narrativa, entre las que se encuentran: la ausencia o mala formulación de preguntas de investigación o la carencia de una descripción explícita de cómo fue seleccionada la evidencia documental.

El objetivo de esta revisión es identificar las contribuciones teóricas más importantes en el desarrollo de modelos de redes neuronales artificiales para el pronóstico de series de tiempo no lineales, que fueron realizadas en el periodo comprendido entre los años 2000 y 2013. Igualmente, también se busca identificar nuevos problemas de investigación originados a partir de las propuestas publicadas.

A. Proceso de Búsqueda

El proceso de búsqueda consistió en una búsqueda manual de los artículos publicados en revistas seriadadas para el periodo comprendido entre los años 2000 y 2013. La búsqueda fue realizada usando el sistema bibliográfico SCOPUS, el cual incluye una de las más grandes colecciones de resúmenes, referencias e índices bibliográficos en el planeta.

Se usaron dos criterios de búsqueda. Como primer criterio se usó la cadena:

TITLE-ABS-KEY (nonlinear neural model for forecasting) AND DOCTYPE(ar or rev) AND

PUBYEAR AFT 1999

El segundo criterio usa la cadena de búsqueda:

TITLE-ABS-KEY (neural networks AND nonlinear times series modeling) AND DOCTYPE (ar) AND PUBYEAR AFT 1999

B. Criterios de Inclusión y Exclusión

En esta investigación se definió un único criterio de inclusión: que el artículo propusiera un nuevo tipo de red neuronal para la predicción de series de tiempo.

Adicionalmente, los artículos que cumplieron con alguna de las siguientes características fueron excluidos:

1. Se presenta una aplicación de ANN sin ningún desarrollo teórico formal o en el trabajo analizado no se define una pregunta de investigación.
2. Se replica un estudio o metodología sin ningún desarrollo conceptual o práctico novedoso.

C. Evaluación de la Calidad

Para evaluar la calidad de los artículos finalmente seleccionados se utilizaron las siguientes preguntas:

- QA1. ¿Es explícita la formulación matemática del modelo?
- QA2. ¿Es definido el proceso de estimación de parámetros para el nuevo modelo?
- QA3. ¿El estudio especifica criterios para seleccionar las variables relevantes?
- QA4. ¿El estudio presenta un método para determinar la complejidad apropiada (número de capas o neuronas) del modelo?
- QA5. ¿Hay una evaluación o diagnóstico para el modelo?
- QA6. ¿Se examina la factibilidad de la metodología propuesta por medio de una aplicación a un caso real?
- QA7. ¿Se especifica un procedimiento para el entrenamiento del modelo (transformación de datos, valores iniciales de los parámetros, criterio de parada, etc.)?

Se dieron puntajes a las preguntas de la siguiente forma:

- QA1: S (si), la formulación matemática del nuevo modelo es presentada de forma explícita en el artículo; P (parcialmente), la formulación matemática es implícita; N (no) no se define explícitamente la formulación matemática ni puede ser fácilmente inferida de la lectura del artículo.
- QA2: S (si), se describe detalladamente un procedimiento para estimar los parámetros del modelo; P (parcialmente), se señala un procedimiento o sugiere la lectura de otros estudios; N (no) no aborda la temática de estimación de parámetros.
- QA3: S (si), el artículo plantea explícitamente criterios para la selección de variables relevantes; P (parcialmente), se señalan procedimientos o se sugiere la lectura de otros estudios; N (no), no se aborda el problema de selección de variables relevantes.
- QA4: S (si), hay un método o criterio explícito para la

determinación de la complejidad del modelo (capas o nodos); P (parcialmente), no se especifica explícitamente como definir la complejidad apropiada del modelo o se hace referencia a otros artículos; N (no), no se aborda el problema de determinación de la complejidad del modelo.

- QA5: S (si), se muestra de forma explícita un procedimiento para diagnosticar el modelo; P (parcialmente), el diagnóstico del modelo es realizado implícitamente o se refiere a un método propuesto en otro artículo; N (no), no se define ni se recomienda un método de diagnóstico para el modelo propuesto.
- QA6: S (si), los autores aplican el modelo para pronosticar una serie de tiempo real; P (parcialmente), el modelo desarrollado es usado para pronosticar una serie de tiempo simulada; N (no), no se realiza una aplicación del modelo propuesto.
- QA7: S (si), la formulación del algoritmo de entrenamiento es explícita en el artículo; P (parcialmente), el algoritmo de entrenamiento es implícito o se hace referencia a otro estudio; N (no), no se define ni se recomienda un algoritmo de entrenamiento.

Para las preguntas QA1 a QA7 se asignaron los siguientes puntajes: S = 1, P = 0,5 y N = 0. Como complemento al análisis de los modelos seleccionados, se consideraron adicionalmente los siguientes criterios:

- QA8: Relación entre el número de citas que recibió el artículo y el tiempo publicado (es decir, la diferencia entre 2010 y el año de publicación del estudio).
- QA9: Valor del indicador Scimago Journal Rank, el cual refleja el prestigio de la fuente, esto es, el valor de las citas ponderadas por documento de acuerdo con el año de publicación del artículo.
- QA10: Impacto normalizado por fuente del artículo (SNIP), que define la razón del conteo de citas de la revista por artículo y el potencial de citas en el campo de interés.

Adicionalmente, también fue identificado si los modelos propuestos consideran una estructura diferente a la autorregresiva.

D. Recolección de Datos

Los datos extraídos de cada estudio fueron: nombre de la revista donde se publicó el artículo y las referencias completas, el tema de investigación y resumen del estudio, el objetivo o pregunta de investigación, la calidad de la investigación, los resultados obtenidos sobre el tópico en consideración, las investigaciones futuras propuestas por el estudio, el número de citas recibidas, los indicadores "Source-Normalized Impact per Paper" (SNIP) y "SCImago Journal Rank" (SJR) en el año de publicación del artículo.

El indicador SJR corresponde a la cantidad de citas recibidas por el artículo durante un periodo de tres años, las cuales son ponderadas de acuerdo con el prestigio y el área temática de la revista en que se publicó el artículo analizado.

El indicador SNIP es calculado teniendo en cuenta la cantidad de citas recibidas por el artículo, el número de

artículos publicados y potencial de citación del área.

III. RESULTADOS OBTENIDOS

A continuación se describen los resultados obtenidos en esta investigación.

A. Resultados de la Búsqueda

Al usar las cadenas de búsqueda en el sistema SCOPUS se recuperó automáticamente un total de 3988 publicaciones. Seguidamente, se aplicaron de forma manual los criterios de inclusión y exclusión, lo que llevo a seleccionar, finalmente, un total de 24 artículos, cuyas referencias aparecen en la Tabla I. De este proceso, vale la pena señalar que aunque hay un número muy alto de publicaciones sobre ANN, existen realmente muy pocos estudios en que se propongan nuevos modelos con un soporte teórico apropiado. Igualmente, se encontró que no hay un número estable de publicaciones por año en las cuales se presenten nuevos avances teóricos; el número máximo de publicaciones ocurrió en el año 2005.

B. Evaluación de la Calidad

Para los 24 estudios finalmente seleccionados se aplicaron los criterios de calidad definidos en la Sección II. Los resultados obtenidos son presentados en la Tabla II, en la que cada fila representa uno de los estudios seleccionados. En la Tabla II, las columnas 3 a 9 muestran el grado de cumplimiento de los criterios de calidad definidos por las preguntas QA1 a QA7; la columna 10 recopila el puntaje total obtenido en relación a las preguntas QA1 a QA7; las columnas 11 a 13 muestran los resultados obtenidos al aplicar los criterios complementarios QA8 a QA10. Finalmente, la columna 15 da información sobre la metodología propuesta en cada estudio (híbrido, combinación u otra diferente de las anteriores); un asterisco (*) en esta columna indica que se propone un esquema diferente al autorregresivo.

Los resultados del análisis de calidad muestran que el puntaje promedio es $4,5 \pm 1,302$, lo que significa que la calidad promedio de los estudios seleccionados varía entre 3,2 y 5,8. Nótese que este rango de valores difiere significativamente del puntaje ideal de 7, el cual representa un artículo que cumple con todos los requerimientos necesarios para tener una estrategia apropiada para la selección del modelo final. Esto indica que, en general, los modelos desarrollados entre el 2000 y el 2013 no satisfacen completamente todos los requisitos para desarrollar un nuevo modelo basado en redes neuronales.

Finalmente, debe señalarse que únicamente los estudios S10 y S16 cumplen completamente con los siete criterios para la especificación del modelo.

C. Factores de Calidad

Cuando se analizaron los 18 artículos seleccionados, se encontró que únicamente tres propuestas consideran un proceso diferente al autorregresivo: Khashei and Bijari [24],

Tseng, Yu and Tzeng [29], Zhang [30], y Wang et al. [48].

Por otra parte, se analizó la correlación entre el puntaje obtenido y la fecha de publicación del artículo. La Fig. 1 muestra que los estudios publicados en 2005, 2006, 2007 y 2009 están caracterizados por valores similares y altos puntajes, a diferencia de las publicaciones realizadas en los años 2004, 2008 y 2013 que tienen valores heterogéneos. Nótese que los estudios publicados en los periodos inicial y final están caracterizados por bajos puntajes, esto es, no

cumplen con una gran parte de los criterios necesarios para una adecuada formulación de un modelo de pronóstico basado en redes neuronales artificiales.

Adicionalmente, se encontró que el coeficiente de correlación entre el puntaje obtenido y la razón citaciones por año de los estudios es $-0,1505$ (valor- $p = 0,5120$), lo que indica que la calidad de la especificación del modelo no tiene influencia sobre el número de citaciones recibidas por año.

TABLA I. DESCRIPCIÓN DE LOS ESTUDIOS SELECCIONADOS.

ID	AUTORES [REFERENCIA]	AÑO	MODELO PROPUESTO	CONCLUSIONES
S1	Medeiros and Veiga [25]	2000	NCSTAR	Para modelar series de tiempo no lineales se propone usar las salidas de una red neuronal, con una sola capa oculta, como la estimación de los coeficientes de un modelo lineal.
S2	Leung Lai and Po-Shing Wong [31]	2001	SNN	Se considera una variante del modelo de red neuronal convencional. Se muestra cómo el algoritmo de Esperanza y Maximización (EM, por su sigla en inglés) puede emplearse para desarrollar un esquema de estimación eficiente y de bajo costo computacional.
S3	Tseng, Yu and Tzeng [29]	2002	SARIMABP	Se propone un modelo híbrido, llamado SARIMABP, basado en el modelo de series de tiempo SARIMA y el modelo de red neuronal BP, para pronosticar datos de series de tiempo estacionales. Los resultados muestran que el modelo SARIMABP es superior a los otros dos modelos en cuanto a la calidad del pronóstico.
S4	Zhang [30]	2003	-	Se presenta una metodología híbrida con base en los modelos ARIMA y ANN. Se muestra que el modelo híbrido puede ser más efectivo, debido a que provee pronósticos más precisos, que si se usaran los modelos separadamente.
S5	Suarez-Farias, Pedreira and Medeiros [32]	2004	LGNN	Los autores proponen una combinación de modelos lineales estacionarios y no estacionarios. Muestran que el modelo propuesto es una herramienta útil para el análisis de series temporales.
S6	Lee et al. [33]	2004	GRNNFA	Se propone un modelo de red neuronal híbrido que es capaz de capturar el comportamiento de un sistema no lineal, entrenando la red con datos históricos relevantes.
S7	Medeiros and Veiga [34]	2005	NCSTAR	Se considera una generalización del modelo logístico STAR para tratar con múltiples regímenes y obtener una especificación flexible de las variables de transición. El modelo formulado puede interpretarse como un modelo lineal de tiempo variable, donde los coeficientes son las salidas de una red neuronal con una sola capa oculta.
S8	Ghiassi and Saidane [20]	2005	DAN2	Se propone un modelo de red neuronal artificial dinámico para pronosticar series de tiempo, que usa una arquitectura diferente a los modelos tradicionales. Se muestra que el modelo propuesto es mejor que los modelos ANN tradicional y ARIMA.
S9	Yu, Wang and Lai [35]	2005	-	Los autores proponen un modelo no lineal de ensamble de pronósticos, integrando un modelo lineal autorregresivo generalizado (GLAR) con una red neuronal artificial (ANN) para obtener predicciones más precisas.
S10	Chen et al. [36]	2005	FNT	Se considera un modelo de pronóstico de series temporales basado en árboles neuronales flexibles. Se muestra que el modelo FNT propuesto con variables de entradas seleccionadas automáticamente tiene una mayor precisión (error bajo) y buena capacidad de generalización.
S11	Medeiros, Teräsvirta and Rech [37]	2006	AR-NN	Se propone un modelo híbrido entre un modelo Autorregresivo y un modelo ANN con una sola capa oculta. El método de modelado propuesto permite especificar modelos de manera parsimoniosa a un bajo costo computacional.
S12	Pang et al [38]	2007	NLPM-ANN	Se presenta y prueba un modelo no lineal de perturbación basado en redes neuronales. Éste es aplicado exitosamente para la simulación de lluvias de una cuenca.
S13	Hassan, Nath and Kirley [39]	2007	-	Se propone un modelo híbrido basado en el modelo oculto de Markov (HMM, por su sigla en inglés), ANN y Algoritmos Genéticos (GA, por su sigla en inglés), para pronosticar el comportamiento del mercado financiero.
S14	Li et al. [40]	2008	AR*-GRNN	Se considera un modelo combinado, compuesto por un modelo AR* y un modelo de regresión generalizada de redes neuronales (GRNN, por su sigla en inglés). Los resultados indican que el método es efectivo para combinar los modelos de series de tiempo con modelos de redes neuronales, tomando las ventajas de cada modelo.
S15	Khashei, Reza Hejazi and Bijari [41]	2008	-	Se propone un nuevo método híbrido basado en los conceptos básicos de ANN y los modelos de regresión fuzzy, que produce resultados más precisos en conjuntos de datos incompletos.
S16	Chen and Chang [5]	2009	-	Se considera un modelo EANN para construir automáticamente la arquitectura y las conexiones de los pesos de la red neuronal.
S17	Khashei and Bijari [24]	2010	-	Se presenta un nuevo modelo híbrido ANN, usando un modelo ARIMA para obtener pronósticos más precisos que el modelo de redes neuronales. En la primera etapa de la

				metodología híbrida, se ajusta un modelo ARIMA y, en la segunda, se toma como entradas de la red los residuales del modelo ARIMA y los datos originales.
S18	Wong, Xia and Chu [42]	2010	ADNN	Se considera un nuevo modelo ANN con métricas de adaptación para las entradas, y con un mecanismo de mezcla para las salidas de la red.
S19	Wu and Shahidehpour [43]	2010	Time series-AWNN	Proponen un modelo híbrido basado en una red neuronal Wavelet adaptativa (AWNN, por su sigla en inglés) y en modelos de series de tiempo, tales como el ARMAX y el GARCH, para pronosticar el valor diario de la electricidad en el mercado. Se encuentran mejores resultados en los pronósticos que los reportados en la literatura.
S20	Gheyas and Smith[44]	2011	GEFTS-GRNN	Presentan el modelo llamado ensamble de la red neuronal de regresión generalizada para pronosticar series de tiempo, el cual es un híbrido de distintos algoritmos de aprendizaje de máquina. Con este modelo se aprovechan las ventajas conjuntas que representan los algoritmos, pero tiene un alto costo computacional.
S21	Alavi and Gandomi[45]	2011	ANN-SA	Se considera un modelo ANN cuyo entrenamiento se hace por medio del algoritmo Temple Simulado (SA por su sigla en inglés). Este modelo se propone para estudiar algunas características relacionadas con fenómenos sísmicos, usando datos experimentales.
S22	Cui, Liu and Li [46]	2012	NWESN, BAESN, MESN	Proponen tres nuevos modelos basados en la red neuronal Echo state network (ESN) y en teoría compleja de redes. Aunque estos modelos tienen una estructura más compleja que el modelo original ESN, se muestra que con ellos se obtienen pronósticos más precisos.
S23	Yolcu, Egrioglu and Aladag [47]	2013	L&NL-ANN	Se presenta un nuevo modelo ANN que considera al mismo tiempo la estructura lineal y no lineal de una serie temporal. La red es entrenada usando el algoritmo de optimización de enjambre de partículas (PSO por su sigla en inglés). Los autores muestran que el modelo propuesto permite obtener mejores resultados comparado con algunos modelos tradicionales.
S24	Wang et al. [48]	2013	ARIMA-ANN	Se considera un modelo híbrido entre el ANN y el modelo ARIMA, con el fin de integrar las ventajas de ambos modelos. El nuevo modelo fue probado en tres bases de datos, obteniéndose buenos resultados.

TABLA II. EVALUACIÓN DE LA CALIDAD.

ID	REF.	QA1	QA2	QA3	QA4	QA5	QA6	QA7	PUNTAJE TOTAL	Q8	Q9	Q10	METODOLOGÍA
S1	[25]	S	S	N	N	P	S	S	4.5	2.5	0.692	1.893	HÍBRIDO
S2	[31]	S	S	P	P	N	S	P	4.5	1.3	2.580	2.274	OTRO
S3	[29]	S	N	P	N	S	S	P	4.0	8.5	0.361	0.797	HÍBRIDO *
S4	[30]	P	P	P	P	P	S	N	3.5	35.2	0.340	0.594	HÍBRIDO *
S5	[32]	S	S	S	S	P	S	S	6.5	1.8	3.490	2.739	COMBINACIÓN
S6	[33]	P	N	S	N	P	S	P	3.5	2.7	0.449	1.822	HÍBRIDO
S7	[34]	S	S	S	S	P	S	S	6.5	3.3	2.261	4.584	HÍBRIDO
S8	[20]	P	S	P	S	P	S	S	5.5	4.6	0.450	1.083	OTRO
S9	[35]	S	N	S	N	S	S	P	4.5	13.0	1.284	2.052	HÍBRIDO
S10	[36]	P	S	S	N	S	P	S	5.0	13.9	0.603	1.511	OTRO
S11	[37]	S	S	S	S	S	S	S	7.0	5.7	0.392	0.908	HÍBRIDO
S12	[38]	P	S	N	S	N	S	P	4.0	0.8	1.555	1.943	HÍBRIDO
S13	[39]	S	S	N	N	S	S	S	5.0	13.8	1.094	1.675	HÍBRIDO
S14	[40]	S	N	N	N	S	P	P	3.0	1.2	0.390	1.068	COMBINACIÓN
S15	[41]	S	S	P	N	S	S	P	5.0	11.0	2.064	1.985	HÍBRIDO
S16	[5]	S	S	S	S	S	S	S	7.0	10.5	1.678	1.836	OTRO
S17	[24]	S	P	N	N	P	S	N	3.0	14.0	1.173	1.766	HÍBRIDO *
S18	[42]	S	P	N	N	P	P	P	3.0	7.3	2.606	2.350	OTRO
S19	[43]	S	P	S	N	S	S	S	4.5	7.0	2.420	2.898	HÍBRIDO
S20	[44]	P	N	P	N	S	S	P	3.5	3.0	1.206	1.910	HÍBRIDO
S21	[45]	S	S	P	N	S	S	S	4.5	15.5	1.301	2.619	OTRO
S22	[46]	P	P	N	N	S	P	P	3.0	-	0.876	1.102	OTRO
S23	[47]	S	S	N	N	S	S	S	5.0	-	-	-	HÍBRIDO
S24	[48]	N	N	N	N	S	S	P	2.5	-	-	-	HÍBRIDO*

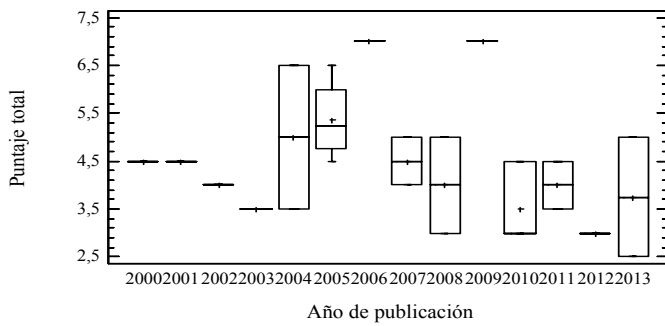


Figura 1. Diagrama de cajas de los puntajes de calidad de los estudios por año.

Adicionalmente al analizar los indicadores SJR y SNIP (columnas 12 y 13 de la Tabla II), se encontró que no hay una relación significativa entre ellos y el puntaje total obtenido. El coeficiente de correlación de Spearman entre el SJR y el puntaje fue 0,2462 (valor- $p = 0,2821$) y entre el SNIP y el puntaje fue 0,2690 (valor- $p = 0,2384$).

IV. DISCUSIÓN

En esta sección se responden las preguntas de investigación planteadas.

A. RQ1. ¿Cuáles son los nuevos modelos basados en redes neuronales artificiales que han sido propuestos desde el año 2000 hasta el año 2013?

Entre los años 2000 a 2013 se han desarrollado 24 nuevos modelos que cumplen con todos los criterios de inclusión e exclusión definidos en esta investigación, los cuales aparecen relacionados en la Tabla I.

B. RQ2. ¿Cuáles de los modelos propuestos consideran una estructura diferente a la autorregresiva?

Se estableció que únicamente el 17% de los modelos revisados en este estudio consideran un proceso diferente al Autorregresivo. En los modelos propuestos por Khashei and Bijari [24], Tseng, Yu and Tzeng [29], Zhang [30] y Wang et al. [48] se usa una metodología híbrida similar: inicialmente se ajusta un modelo lineal de series de tiempo, y posteriormente se usan los residuales de éste modelo como las variables de entrada de un modelo ANN. Adicionalmente, los autores presentan evidencias de que las predicciones obtenidas con los modelos híbridos son más precisas que las obtenidas por modelos tradicionales de redes neuronales artificiales, tales como el backpropagation con una sola capa oculta.

Sin embargo, los cuatro modelos encontrados en este estudio tienen un bajo puntaje, lo que indica que ellos no cumplen completamente con la especificación de un proceso sistemático para la construcción del modelo.

Por otra parte, si bien la teoría indica que un modelo AR de un orden suficientemente alto puede aproximar con suficiente precisión un proceso MA de bajo orden, en el caso no lineal esto no se cumple. Burgess y Refenes [27] demuestran empíricamente que un modelo no lineal autorregresivo (NAR) de un alto orden no es capaz de

representar un proceso de promedios móviles no lineal (NLMA) de bajo orden. En este caso, se produce una disminución en el contenido de información capturada por el modelo NAR, posiblemente explicada por el incremento en la varianza debido al alto número requerido de parámetros. Esto causa la degradación de la capacidad de generalización del modelo.

Así, de la pregunta de investigación RQ2 emerge las temáticas futuras de investigación que no están relacionadas únicamente con los ítems faltantes en el proceso sistemático de construcción de los modelos (véase la Tabla I), sino también con la ausencia de algoritmos para estimar los parámetros de modelos que usan las innovaciones o residuos pasados como entradas en los modelos de redes neuronales en la misma forma que se hace en los modelos autorregresivos, con el fin de poder pronosticar series que inherentemente siguen procesos de promedios móviles no lineales.

C. RQ3. ¿Los estudios publicados presentan una aproximación sistemática, paso a paso, para la construcción del modelo?

Del puntaje asociado a cada estudio (Tabla II), se concluye que únicamente el 8% de los nuevos modelos abordan explícitamente: la selección de la arquitectura, la determinación de la complejidad del modelo, la selección de las variables relevantes, la estimación de los parámetros y la aplicación y evaluación del modelo propuesto.

Típicamente, los modelos propuestos del año 2000 al año 2013 presentan una formulación matemática y la selección de la arquitectura, el proceso de estimación de parámetros y la aplicación a datos reales.

Sin embargo, es necesario realizar investigaciones sobre los siguientes aspectos:

- Especificación de criterios para la selección de las variables relevantes
- Desarrollo de una metodología para determinar la arquitectura óptima del modelo de redes neuronales seleccionado.
- El desarrollo de metodologías para la evaluación del modelo en términos de la captura de las principales características de la serie y de su generalización.

Otro aspecto importante aquí es el hecho de que estos modelos son usados como referencia para nuevos estudios, aunque los problemas señalados sobre su proceso de especificación no han sido resueltos.

D. RQ4. ¿Cuáles son los problemas pendientes por resolver en las nuevas aproximaciones propuestas?

En la Tabla II, las columnas 3 a 10 presentan las áreas pendientes por investigación; ellas son identificadas con las letras P y N.

V. CONCLUSIONES

En ese estudio se analizaron los artículos publicados en la literatura más relevante durante el periodo 2000-2013, en los

que se proponen nuevos modelos basados en redes neuronales artificiales para el pronóstico de series de tiempo no lineales. Para cada uno de los artículos analizados se discutieron los problemas vigentes por ser resueltos.

En general, se observó que los modelos planteados, en los estudios seleccionados, no satisfacen completamente un procedimiento sistemático para la construcción de un modelo ANN. La especificación matemática del modelo y la definición explícita procedimiento de entrenamiento, se realiza parcial o totalmente en los 24 estudios seleccionados; sin embargo, esto no ocurre con las otras etapas de construcción que deben satisfacer un modelo ANN.

Así mismo, se concluyó que en la literatura no se presentan modelos ANN que consideren explícitamente la inclusión de términos MA, los cuales parecen estar presentes en muchas series de tiempo reales.

REFERENCIAS

- [1] J. G. De Gooijer and R. J. Hyndman, "25 years of time series forecasting," *International Journal of Forecasting*, vol. 22, no. 3, pp. 443–473, Jan. 2006.
- [2] N. K. Kasabov, *Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering*. The MIT Press, 1996.
- [3] T. Teräsvirta, "Forecasting economic variables with nonlinear models," *SSE/EFI Working Paper Series in Economics and Finance*, 598, 2005.
- [4] R. S. Tsay, *Analysis of Financial Time Series*, Jhon Wiley & Sons. Third Edition, 2010.
- [5] Y. Chen and F.-J. Chang, "Evolutionary artificial neural networks for hydrological systems forecasting," *Journal of Hydrology*, vol. 367, no. 1–2, pp. 125–137, Mar. 2009.
- [6] H. Tong, *Non-Linear Time Series: A Dynamical System Approach*. Oxford University Press (UK), 1993.
- [7] M. P. Clements, P. H. Franses, and N. R. Swanson, "Forecasting economic and financial time-series with non-linear models," *International Journal of Forecasting*, vol. 20, no. 2, pp. 169–183, Apr. 2004.
- [8] R. F. Engle, "Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation," *Econometrica*, vol. 50, no. 4, p. 987, Jul. 1982.
- [9] S. Lundbergh and T. Teräsvirta, "Forecasting with smooth autoregressive models", In Clements, M., Hendry, D. (Eds.), *A Companion to Economic Forecasting*. Blackwell, pp. 485-509. Chap. 21, 2002.
- [10] H. White, "An additional hidden unit test for neglected nonlinearity in multilayer feedforward networks", in *Proceedings of the International Joint Conference on Neural Networks*, vol 2, pp. 451-455. Washington, DC, IEEE Press, NY., 1989.
- [11] T. Masters, *Practical Neural Network Recipes in C++*. Morgan Kaufmann, 1993.
- [12] G. E. P. Box and G. M. Jenkins, *Time Series Analysis Forecasting and Control*. San Francisco: Holden-Day, 1970.
- [13] I. Kaastra and M. Boyd, "Designing a neural network for forecasting financial and economic time series," *Neurocomputing*, vol. 10, no. 3, pp. 215–236, Apr. 1996.
- [14] C. W. J. Granger and T. Teräsvirta, *Modelling Nonlinear Economic Relationships*. Oxford University Press, USA, 1993.
- [15] T. Teräsvirta, "Specification, estimation and evaluation of smooth transition autoregressive models," *Journal of the American Statistical Association*, vol. 89, no. 425, pp. 208–218, Mar. 1994.
- [16] P. H. Franses and D. van Dijk, *Non-Linear Time Series Models in Empirical Finance*, 1st ed. Cambridge University Press, 2000.
- [17] U. Anders and O. Korn, "Model selection in neural networks," *Neural Networks*, vol. 12, no. 2, pp. 309–323, Mar. 1999.
- [18] M. Paliwal and U. A. Kumar, "Neural networks and statistical techniques: A review of applications," *Expert Systems with Applications*, vol. 36, no. 1, pp. 2–17, Jan. 2009.
- [19] G. Zhang, B. E. Patuwo, and M. Y. Hu, "Forecasting with artificial neural networks: the state of art," *International Journal of Forecasting*, vol. 14, no. 1, pp. 35–62, Mar. 1998.
- [20] M. Ghiassi and H. Saidane, "A dynamic architecture for artificial neural networks," *Neurocomputing*, vol. 63, pp. 397–413, Jan. 2005.
- [21] J. D. Velásquez Henao, C. J. Franco Cardona, and Y. Olaya Morales, "A review of DAN2 (Dynamic Architecture for Artificial Neural Networks) model in time series forecasting," *Ingeniería y universidad*, vol. 16, no. 1, pp. 135–146, 2012.
- [22] Teräsvirta, C.-F. Lin, and C. W. J. Granger, "Power of the Neural Network Linearity Test," *Journal of Time Series Analysis*, vol. 14, no. 2, pp. 209–220, 1993.
- [23] T.-H. Lee, H. White and C.W.J. Granger, "Testing for neglected nonlinearity in time series models", *Journal of Econometrics*, vol. 56, pp. 269-290, 1993.
- [24] M. Khashei and M. Bijari, "A artificial neural network (p,d,q) model for time series forecasting," *Expert Systems with Applications*, vol. 37, no. 1, pp. 479–489, Jan. 2010.
- [25] A. Veiga and M. C. Medeiros, "A hybrid linear-neural model for time series forecasting," *IEEE Transactions on Neural Networks*, vol. 11, no. 6, pp. 1402–1412, Nov. 2000.
- [26] M. Qi and G. P. Zhang, "An investigation of model selection criteria for neural network time series forecasting," *European Journal of Operational Research*, vol. 132, no. 3, pp. 666–680, Aug. 2001.
- [27] A. N. Burgess and A.-P. . Refenes, "Modelling non-linear moving average processes using neural networks with error feedback: An application to implied volatility forecasting," *Signal Processing*, vol. 74, no. 1, pp. 89–99, Apr. 1999.
- [28] B.A. Kitchenham. *Procedures for Undertaking Systematic Reviews*. Joint Technical Report, Computer Science Department, Keele University (TR/SE- 0401) and National ICT Australia Ltd. (0400011T.1), 2004.
- [29] F.-M. Tseng, H.-C. Yu, and G.-H. Tzeng, "Combining neural network model with seasonal time series ARIMA model," *Technological Forecasting and Social Change*, vol. 69, no. 1, pp. 71–87, Jan. 2002.
- [30] G. P. Zhang, "Time series forecasting using a hybrid ARIMA and neural network model," *Neurocomputing*, vol. 50, pp. 159–175, Jan. 2003.
- [31] T. L. La, and S. P.-S. Wong, "Stochastic Neural Networks With Applications to Nonlinear Time Series," *Journal of the American Statistical Association*, vol. 96, pp. 968–981, 2001.
- [32] S M. Suárez-Fariñas, C. E. Pedreira and M. C. Medeiros. "Local Global Neural Networks: A New Approach for Nonlinear Time Series Modeling," *Journal of the American Statistical Association*, vol. 99, no. 468, pp. 1092-1107, Dec. 2004.
- [33] E. W. M. Lee, R. K. K. Yuen, S. M. Lo, K. C. Lam, and G. H. Yeoh, "A novel artificial neural network fire model for prediction of thermal interface location in single compartment fire," *Fire Safety Journal*, vol. 39, no. 1, pp. 67–87, Feb. 2004.
- [34] M. C. Medeiros and A. Veiga, "A Flexible Coefficient Smooth Transition Time Series Model," *IEEE Transactions on Neural Networks*, vol. 16, no. 1, pp. 97–113, Jan. 2005.
- [35] L. Yu, S. Wang, and K. K. Lai, "A novel nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign exchange rates," *Computers & Operations Research*, vol. 32, no. 10, pp. 2523–2541, Oct. 2005.
- [36] Y. Chen, B. Yang, J. Dong, and A. Abraham, "Time-series forecasting using flexible neural tree model," *Information Sciences*, vol. 174, no. 3–4, pp. 219–235, Aug. 2005.
- [37] M. C. Medeiros, T. Teräsvirta, and G. Rech, "Building neural network models for time series: a statistical approach," *Journal of Forecasting*, vol. 25, no. 1, pp. 49–75, 2006.
- [38] B. Pang, S. Guo, L. Xiong, and C. Li, "A nonlinear perturbation model based on artificial neural network," *Journal of Hydrology*, vol. 333, no. 2–4, pp. 504–516, Feb. 2007.
- [39] Md. R. Hassan, B. Nath, and M. Kirley, "A fusion model of HMM, ANN and GA for stock market forecasting," *Expert Systems with Applications*, vol. 33, no. 1, pp. 171–180, Jul. 2007.
- [40] W. Li, Y. Luo, Q. Zhu, J. Liu, and J. Le, "Applications of AR*-GRNN model for financial time series forecasting," *Neural Comput & Applic*, vol. 17, no. 5–6, pp. 441–448, Oct. 2008.
- [41] M. Khashei, S. Reza Hejazi, and M. Bijari, "A new hybrid artificial neural networks and fuzzy regression model for time series forecasting," *Fuzzy Sets and Systems*, vol. 159, no. 7, pp. 769–786, Apr. 2008.
- [42] W. K. Wong, M. Xia, and W. C. Chu, "Adaptive neural network model for time-series forecasting," *European Journal of Operational Research*, vol. 207, no. 2, pp. 807–816, Dec. 2010.
- [43] L. Wu and M. Shahidepour, "A Hybrid Model for Day-Ahead Price Forecasting," *IEEE Transactions on Power Systems*, vol. 25, no. 3, pp. 1519-1530, Aug. 2010.

- [44] I.A. Gheyas and L.S. Smith, "A novel neural network ensemble architecture for time series forecasting," *Neurocomputing*, vol. 74, pp. 3855–3864, Aug. 2011.
- [45] A.H. Alavi and A.H. Gandomi, "Prediction of principal ground-motion parameters using a hybrid method coupling artificial neural networks and simulated annealing," *Computer and Structures*, vol.89,pp.2176-2194, Oct. 2011.
- [46] H. Cui, X.Liu and L. Li, "The architecture of dynamic reservoir in the echo state network," *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 22, no.3, 033127, Aug., 2012.
- [47] U. Yolcu, E. Egrioglu and C.H. Aladag, "A new linear & nonlinear artificial neural network model for time series forecasting," *Decision Support Systems*, vol.54, no.3, pp. 1340–1347, 2013.
- [48] L. Wang, H. Zou, J. Su, L.Li and S. Chaudhry, "An ARIMA ANN Hybrid Model for Time Series Forecasting," *Systems Research and Behavioral Science*, vol. 30, no.3, pp. 244-259, May., 2013.



Myladis Cogollo is Assistant Professor at the EAFIT University, Medellín, Colombia. She received a M.Sc. in Science-Statistics in 2008 and is currently a PhD(C) in Systems Engineering, both from the Universidad Nacional de Colombia. Her current research interests are time series forecasting, artificial neural networks and statistical analysis of data.



Juan D. Velásquez received the Engineering degree in Civil Engineering in 1994, the MS degree in Systems Engineering in 1997, and the PhD degree in Energetic Systems in 2009, all of them from the Universidad Nacional de Colombia. Medellín, Colombia. From 1994 to 1999, he worked for electricity utilities and consulting companies within the power sector and since 2000 for the Universidad Nacional de Colombia. Currently, he is a Titular Professor in the Computing and Decision Sciences Department, Facultad de Minas, Universidad Nacional de Colombia. His research interest includes: simulation, modeling and forecasting in energy markets; nonlinear time-series analysis and forecasting using statistical and computational intelligence techniques; and optimization using metaheuristics.