

Redes Neuronales Artificiales en predicción de Series de Tiempo. Una aplicación a la Industria

Luis Escobar R., Julio Valdes H., Santiago Zapata C.*

Abstract

The neural networks have been used successfully in many types of prediction problems because they are capable of modeling and predicting time series linear and nonlinear with a high degree of accuracy, capturing any kind of interrelation between the data and do not require knowledge prior to the problem that is being shaped.

This research focuses on evaluating the capability of showing the artificial neural networks in the prediction of time series, studying two sets taken from the field of industry: Monthly Electricity Generation and Consumption of Natural Gas Monthly. The neural network models obtained should be able to predict the next period, according to past periods.

The results obtained in each series realize the great ability of the neural networks used in the prediction of time series, yielding an average absolute percentage error of prediction less than 3% in the series Monthly Electricity Generation and less than 5% in the series Consumption of Natural Gas Monthly.

Keywords: Neural Networks, Time Series, Forecasting.

* Departamento de Informática y Computación. Facultad de Ingeniería, Universidad Tecnológica Metropolitana. Santiago, Chile. laescoba@utem.cl, jvaldesh@gmail.com, szapata@utem.cl

Resumen

Las redes neuronales han sido utilizadas exitosamente en muchos tipos de problemas de predicción debido a que son capaces de modelar y predecir series de tiempo lineales y no lineales con un alto grado de precisión, capturar cualquier tipo de interrelación entre los datos y no requieren de conocimiento previo del problema que se está modelando.

Esta investigación se centra en evaluar la capacidad que presentan las redes neuronales artificiales en la predicción de series de tiempo, estudiando dos series tomadas del campo de la industria: Generación de Electricidad Mensual y Consumo Mensual de Gas Natural. Los modelos de redes neuronales obtenidos deben ser capaces de predecir el siguiente periodo de acuerdo a periodos pasados.

Los resultados obtenidos en cada serie dan cuenta de la gran capacidad que tienen las redes neuronales aplicadas en la predicción de series de tiempo, obteniéndose un error absoluto medio porcentual de predicción inferior al 3% en la serie Generación de Electricidad Mensual e inferior al 5% en la serie Consumo Mensual de Gas Natural.

Palabras Claves: Redes Neuronales, Serie de tiempo, Predicción.

1. Introducción

La predicción de series de tiempo o predicción de series temporales es un área de investigación de mucho interés que está en desarrollo desde hace varias décadas. En especial, en las últimas tres décadas ha aumentado el interés en esta área dado el progreso en las Tecnologías de Información (TI), específicamente las mejores capacidades de procesamiento por parte de los computadores, lo cual permite realizar cálculos complejos en algunos minutos o incluso en algunos segundos. Este aumento de interés se ve reflejado por la diversidad de sus aplicaciones en diferentes disciplinas variando desde la economía a la ingeniería, donde la predicción de series de tiempo es un campo de investigación activo e importante actualmente y se estima que lo continuará siendo en el futuro [1].

La predicción de series de tiempo considera la hipótesis que dado un conjunto discreto de datos con respecto al tiempo y correspondientes a un mismo fenómeno, los valores futuros son dependientes de los valores pasados, es decir, buscando en los valores pasados de una serie de tiempo se puede predecir su comportamiento en el futuro.

La gran importancia que tiene el llevar a cabo predicciones precisas de los valores futuros, hacen necesario dedicar recursos en la investigación para la obtención de herramientas de pronósticos más exactos. Una predicción más precisa en la demanda de un producto permitirá optimizar la cadena de abastecimiento y de esta forma tener en stock la cantidad necesaria para vender sin perder ventas ni tampoco almacenar en bodega productos que no serán necesarios. Una mejor predicción del consumo de electricidad para una región es vital dado que ayudará en la toma de decisiones sobre qué cantidad producir para un lugar determinado en un periodo específico, utilizando los recursos energéticos necesarios minimizando costos operacionales para las estaciones eléctricas. De la misma forma, una predicción precisa de los índices bursátiles en el futuro permitirá tomar decisiones sobre la venta o compra de acciones en el momento exacto. Existen muchos ejemplos de series temporales que han sido objeto de análisis para predecir los valores futuros, principalmente en las áreas de la ciencia, finanzas, comercio e industria.

Durante las últimas décadas se han utilizado principalmente métodos estadísticos clásicos para realizar la predicción de series de tiempo, siendo los métodos de Holt-Winters (1960) y Box y Jenkins (1976) los más utilizados. Estos métodos son fáciles de desarrollar e implementar y relativamente fáciles de comprender e interpretar [11]. Pese a que se obtienen resultados satisfactorios aplicando estos métodos a series de tiempo lineales, al utilizarlos en series no lineales, las cuales son comunes en situaciones del mundo real, presentan limitaciones porque no son capaces de capturar las relaciones no lineales de los datos.

Dado que muchas de las series de tiempo que son de interés de análisis tienen una naturaleza no lineal, se hace necesario utilizar otras técnicas fuera de las clásicas para realizar la predicción de éstas y así obtener modelos más eficientes. En los últimos años las Redes Neuronales Artificiales (RNA) han sido exitosamente aplicadas como herramienta en la predicción de series de tiempo en un amplio rango de problemas en áreas de comercio, industria y ciencia [1]. Las RNA son una rama de la Inteligencia Artificial que consiste en el aprendizaje y procesamiento automático, inspirado en la forma en que funciona el sistema nervioso biológico. El objetivo de la utilización de RNA es conseguir respuestas similares a las que es capaz de dar el cerebro, que se caracterizan por su generalización y robustez. Las RNA son útiles en la predicción de series de tiempo dado que a diferencia de los métodos estadísticos clásicos, son capaces de capturar las relaciones lineales y no lineales entre los datos debido a su estructura no lineal que permite un modelo con más grados de libertad.

2. Formulación del Problema

El objetivo general de esta investigación es evaluar la capacidad de las Redes Neuronales Artificiales como herramienta de predicción, mediante el análisis de distintas configuraciones, utilizando el tipo de Red Neuronal más comúnmente utilizado en problemas de predicción: Perceptrón Multicapa y los algoritmos de aprendizaje Backpropagation y Resilient Propagation.

Neurona biológica

Las neuronas biológicas son células nerviosas que constituyen los elementos primordiales del sistema nervioso central. Una neurona es capaz de recibir información desde miles de otras neuronas, procesarla y luego generar una nueva información que enviará a otras neuronas con las que está conectada. Se estima que el cerebro está compuesto por más de diez billones de neuronas y que cada una está conectada a más de diez mil neuronas. Una neurona biológica está compuesta de: cuerpo celular o soma, axón y múltiples dendritas, como se muestra en la Figura 2.1.

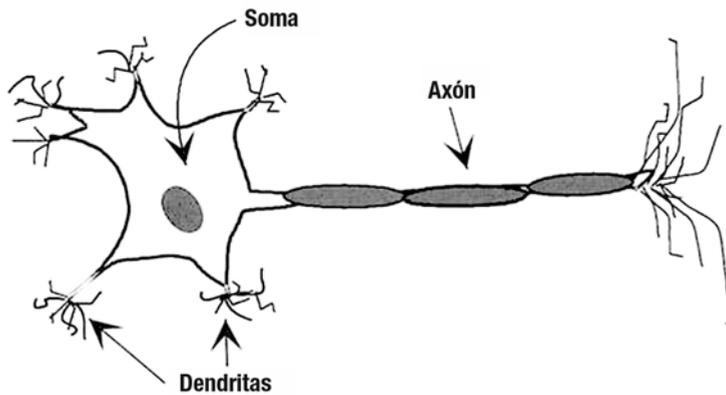


Figura 2.1 | Esquema de una neurona biológica

Fuente Internet: <http://alojamientos.us.es/gtocom/pid/pid10/RedesNeuronales.htm>

Neurona Artificial

Una neurona artificial o procesador elemental es una abstracción de una neurona biológica que opera como una unidad de procesamiento de información que es fundamental para la operación de una red neuronal. Una neurona artificial está compuesta de: un conjunto de entradas, un conjunto de pesos sinápticos, un “cuerpo celular” y una salida como se muestra en la Figura 2.2.

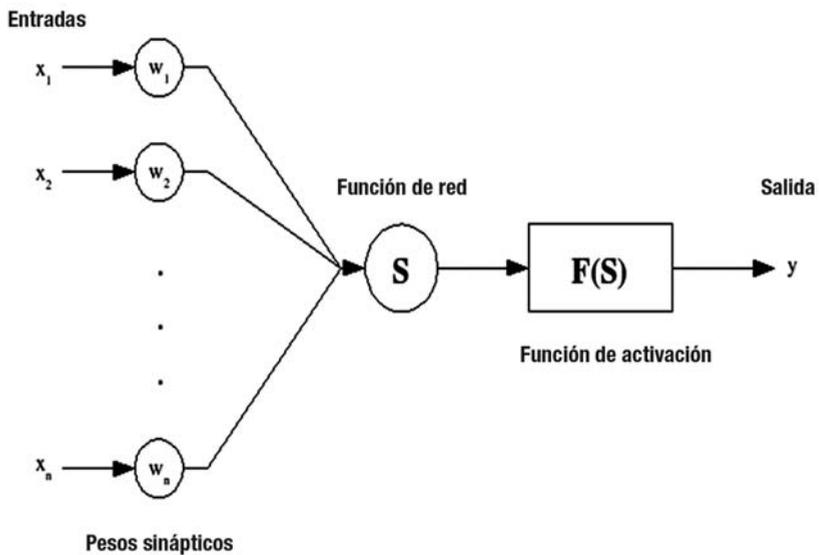


Figura 2.2 | Esquema de una neurona artificial

Fuente: elaboración propia basado en figura «Predicción con redes neuronales: comparación con las metodologías de Box Jenkins» / Joanna Verónica Collantes Duarte, Tesis (Magister scientiae) Universidad de Los Andes, Facultad de Ciencias Económicas y Sociales, Instituto de Estadística Aplicada y Computación, Mérida, Venezuela, 2001.

Redes Neuronales Artificiales

Una Red Neuronal Artificial (RNA) es un paradigma de procesamiento de la información que es inspirado en el modo en que un sistema nervioso biológico, como el cerebro, procesa la información. Una RNA está compuesta por un conjunto de neuronas artificiales o procesadores elementales, los cuales interconectados de alguna manera trabajan para obtener la solución de un problema específico. En la literatura existen diversas definiciones para una RNA pero una de las más certeras con el propósito de resumir su todo es la siguiente:

“Una Red Neuronal es un conjunto de procesadores elementales interconectados, no lineal ni estacionario, que realiza al menos alguna de las siguientes funciones: Aprendizaje, Memorización, Generalización o Abstracción de características esenciales, a partir de un conjunto de ejemplos” [12]

En el estudio de las RNA deben considerarse tres aspectos fundamentales: La arquitectura, el aprendizaje y la capacidad de generalización de la red [13].

a) Arquitectura de red

El término arquitectura de la red está relacionado con el diseño estructural de la red y busca determinar los siguientes elementos: la cantidad de entradas y salidas, la cantidad de nodos ocultos, la función de red y de activación asociada a cada nodo, la forma en que los nodos están interconectados, la dirección que sigue la información, y la selección de un conjunto de datos adecuado para realizar el entrenamiento y la validación del modelo obtenido.

b) Aprendizaje

El aprendizaje o entrenamiento es el proceso en el cual los pesos sinápticos de la red son ajustados con el objetivo de capturar la información que se presenta, y de esta forma obtener respuestas adecuadas. Este proceso básicamente consiste en la presentación de un conjunto de datos, conocido como conjunto de patrones de entrenamiento, un número determinado de veces, conocido como ciclos, hasta que se produzca uno de los siguientes eventos:

- El error entre la salida de la red y la deseada alcance un valor aceptable.
- Se alcance el número máximo de ciclos.

El aprendizaje se lleva a cabo mediante el uso de algoritmos de entrenamientos.

c) Capacidad de Generalización

La capacidad de generalización de una red tiene relación con la recuperación de la información que es almacenada en los pesos de las conexiones durante el entrenamiento, evaluando los resultados con un conjunto de datos diferente del

utilizado en el proceso de aprendizaje, en el que pueden existir patrones diferentes. Se espera que cuando se presenten patrones que no han sido enseñados a la red, ésta sea capaz de entregar una respuesta cercana a la deseada. Mientras más precisa es la respuesta entregada por la red, más capacidad de generalización tendrá ésta.

Para que una red neuronal sea capaz de generalizar de buena forma es necesario contar con un conjunto de datos de entrenamiento suficientemente representativo de la globalidad del problema en cuestión.

3. Solución del Problema

La aplicación de Redes Neuronales Artificiales a la predicción de series de tiempo se realiza en esta investigación de acuerdo a las siguientes etapas: Búsqueda de las variables de entrada, preparación del conjunto de datos, creación de la red, entrenamiento, validación y cálculo de los factores de comparación.

3.1 Búsqueda de las variables de entrada

Esta etapa tiene como objetivo identificar los retrasos o rezagos de la serie de tiempo que deben considerarse como variables de entrada en la red neuronal.

3.2 Preparación del conjunto de datos

Esta etapa tiene como objetivo realizar el escalamiento de los datos. El escalamiento de los datos consiste en la normalización de estos en el intervalo $[0, 1]$.

3.3 Creación de la red

Esta etapa tiene como objetivo determinar cada elemento que compone la arquitectura de la red.

3.4 Entrenamiento

En esta etapa se define el algoritmo de entrenamiento y los parámetros de configuración propios de éste. Se consideran dos algoritmos de entrenamiento supervisado, que ajustan los pesos sinápticos mediante la minimización del error: Backpropagation y Resilient Propagation.

3.5 Validación

Esta etapa tiene como objetivo realizar la validación del proceso de aprendizaje de la red. Se presenta a la red el conjunto de datos seleccionados para este fin y se obtienen los valores de la predicción del siguiente periodo para cada patrón de datos.

3.6 Cálculo de los factores de comparación

El objetivo de esta etapa consiste en calcular los factores que serán utilizados en el análisis de los resultados al comparar los distintos modelos de redes neuronales obtenidos y elegir la más efectiva en la predicción de una serie de tiempo específica. Para llevar a cabo esta tarea se obtienen los siguientes factores: Error Absoluto Medio Porcentual (EAMP), Coeficiente de correlación (R), Representación gráfica de las series, Representación gráfica del EAMP.

Análisis de los Resultados

En esta sección se describen los resultados obtenidos al aplicar la metodología propuesta en el punto anterior a la predicción de series de tiempo. Como parte de esta investigación se consideran dos series de tiempo tomadas del campo de la industria: Generación de Electricidad Mensual y Consumo Mensual de Gas Natural.

Se evalúan diferentes redes neuronales de acuerdo a las variables de entradas y algoritmo de aprendizaje utilizados. La búsqueda de las variables de entrada se realiza de acuerdo a los siguientes criterios: comportamiento de la serie y periodos sucesivos correspondientes a un ciclo. Una vez que se determinan las variables de entrada se debe considerar el algoritmo de aprendizaje para la etapa de entrenamiento, utilizándose en primer lugar el algoritmo Backpropagation y luego Resilient Propagation, con las configuraciones de parámetros correspondientes a cada algoritmo.

Al realizar la comparación de los resultados obtenidos se intenta buscar una configuración o modelo en el cual se obtenga un Error Absoluto Medio Porcentual (EAMP) lo suficientemente pequeño tanto para el conjunto de entrenamiento como para el de validación. Además, mediante el coeficiente de correlación (R) se puede comprobar el ajuste que se produce entre los datos entregados por la red y los datos esperados, lo cuál es utilizado como un parámetro de verificación de los resultados obtenidos en el EAMP.

a) Serie: Generación de Electricidad Mensual

Esta serie temporal contiene datos sobre la generación mensual de electricidad total en la industria eléctrica de Estados Unidos desde Enero de 1990 a Julio de 2007. En la Figura 5.1 se puede observar la representación gráfica de esta serie de tiempo, donde los valores se encuentran en millones de kilowatts hora.

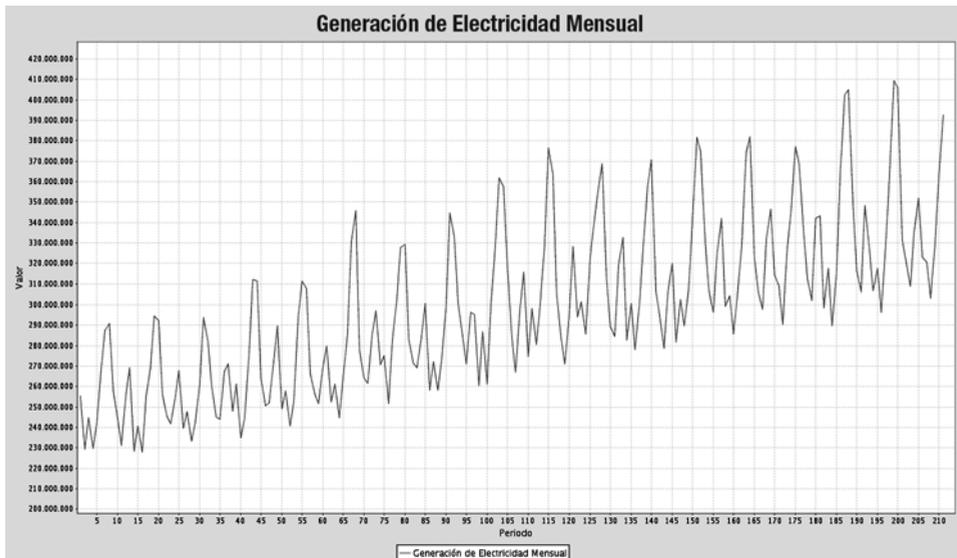


Figura 5.1 | **Generación de Electricidad Mensual**

Se puede observar en la Figura 5.1 que la serie presenta una tendencia creciente y variaciones estacionales bastante definidas.

En la Figura 5.2 se representan gráficamente la serie real que corresponde a los datos esperados y la serie predicción que corresponde a la entregada por la red, utilizando la siguiente configuración en la cual se obtuvieron los mejores resultados:

- Variables de entrada: $\{x(t), x(t-1), \dots, x(t-11)\}$
- Algoritmo de aprendizaje: Resilient Propagation
- Ciclos de entrenamiento: 900
- Nodos capa oculta: 19

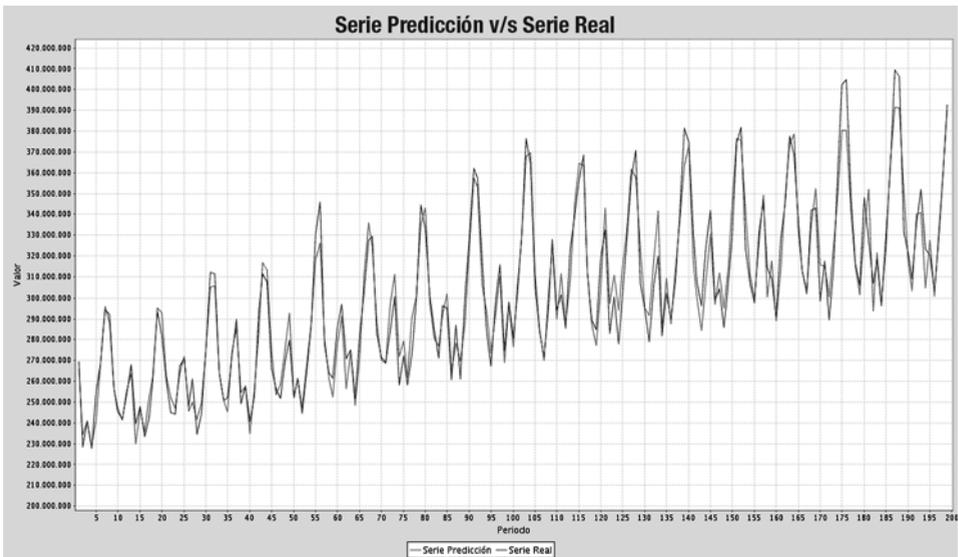


Figura 5.2 | **Generación de Electricidad Mensual. Serie Real versus Serie Predicción**

Se observa en la Figura 5.2 que el ajuste entre las dos series es bastante bueno, lo cual es respaldado por el EAMP de 1,719% en el entrenamiento y de 2,888% en la validación, y el coeficiente de correlación R de 0,983 en el entrenamiento y de 0,949 en la validación, obteniendo una correlación prácticamente perfecta en el conjunto de entrenamiento y muy cercana a 1 en el conjunto de validación. Además, el EAMP permanece oscilando entre 0% y 6% durante toda la serie de tiempo, no superando el 8% de error en su punto máximo.

Al disminuir la cantidad de datos asignados a entrenamiento desde un 80% a un 60% y utilizando un 40% de los datos para la validación, se obtiene un EAMP de entrenamiento del 1,929% y en validación se obtiene un 2,746%. El coeficiente de correlación R obtenido en entrenamiento es 0,977 y en validación se obtiene 0,940. Estos resultados indican la capacidad que tiene la configuración de red neuronal elegida para aprender desde un conjunto de datos menor (60%) y mantener el EAMP de validación, obtenido con el 20% de los datos, considerando que se utiliza un conjunto de datos mayor (40%), donde es más probable encontrar patrones diferentes de los aprendidos.

Al agregar una distorsión aleatoria entre $[-5\%, +5\%]$ a cada uno de los datos del conjunto de validación, se obtiene un EAMP de 3,459% y un coeficiente de correlación igual a 0,917 para el conjunto de datos mencionados. Esto indica que una vez aprendido los patrones correspondientes al conjunto de datos de aprendizaje, la configuración de red escogida es capaz de generalizar en la predicción y ser tolerante a pequeñas distorsiones existentes en los datos, manteniéndose buenos

resultados no superando en un 1% la diferencia entre el EAMP para el conjunto de validación con distorsión y el conjunto de datos sin distorsión.

b) Serie: Consumo Mensual de Gas Natural

Esta serie temporal contiene datos sobre el consumo mensual de gas natural en Estados Unidos desde Enero de 2001 a Agosto de 2007. En la Figura 5.4 se puede observar la representación gráfica de esta serie de tiempo, donde los valores se encuentran en billones de pies cúbicos.

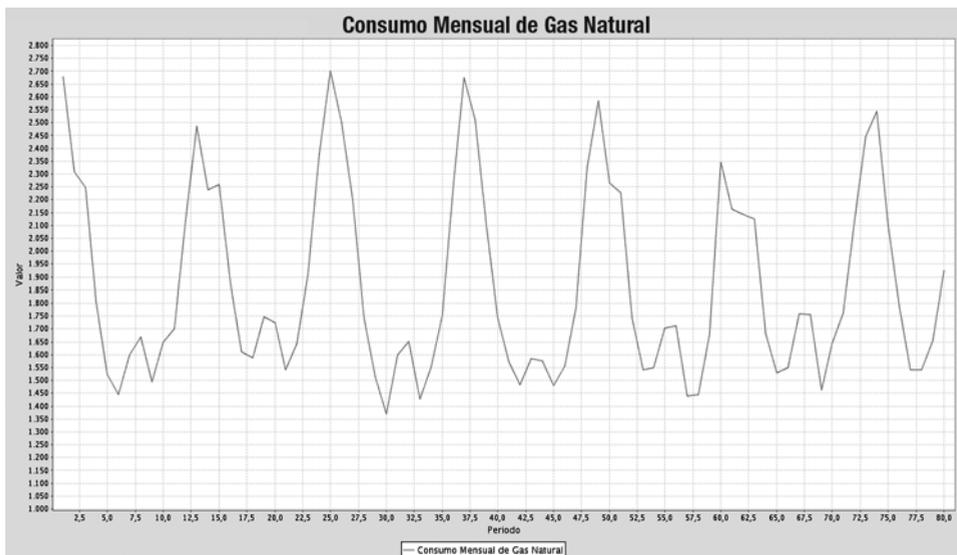


Figura 5.4 | Consumo Mensual de Gas Natural

Se puede observar en la Figura 5.4 que la serie no presenta una tendencia clara pero sí variaciones estacionales bastante definidas en el periodo de un año, presentándose un alto consumo en el invierno y un consumo más bajo en verano justificado principalmente por la temperatura.

En la Figura 5.5 se representan gráficamente la serie real que corresponde a los datos esperados y la serie predicción que corresponde a la entregada por la red, utilizando la siguiente configuración en la cual se obtuvieron los mejores resultados:

- Variables de entrada: $\{x(t), x(t-10), x(t-11)\}$
- Algoritmo de aprendizaje: Resilient Propagation
- Ciclos de entrenamiento: 900
- Nodos capa oculta: 4

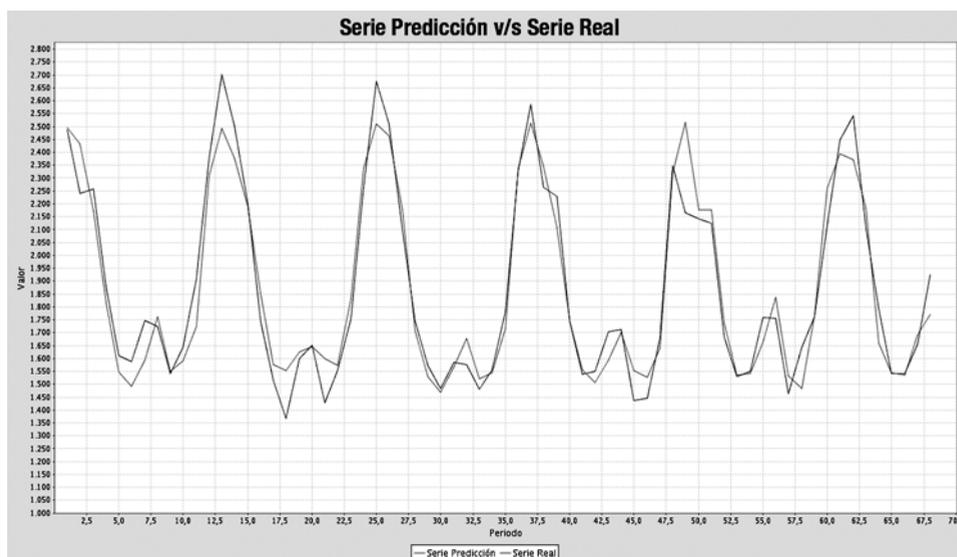


Figura 5.5 | Consumo Mensual de Gas Natural. Serie Real versus Serie Predicción

Se observa en la Figura 5.5 que el ajuste entre las dos series es bastante bueno, lo cual es respaldado por el EAMP de 3,951% en el entrenamiento y de 4,447% en la validación, y el coeficiente de correlación R de 0,964 en el entrenamiento y de 0,947 en la validación, obteniendo una correlación muy cercana a 1 tanto en el conjunto de entrenamiento como en el de validación. Además el EAMP permanece oscilando principalmente entre 0% y 10% durante toda la serie de tiempo y alcanza su punto máximo no superando el 17% de error.

Al disminuir la cantidad de datos asignados a entrenamiento desde un 80% a un 60% y utilizando un 40% de los datos para la validación, se obtiene un EAMP de entrenamiento del 3,512% y en validación se obtiene un 5,439%. El coeficiente de correlación R obtenido en entrenamiento es 0,977 y en validación se obtiene 0,911. Estos resultados indican la capacidad que tiene la configuración de red neuronal elegida para aprender desde un conjunto de datos menor (60%) y aumentar el EAMP de validación tan sólo en un 1%, considerando que dado los pocos datos de esta serie, un 20% de datos en la etapa de entrenamiento resulta muy significativo siendo muy probable encontrar patrones diferentes de los aprendidos.

Al agregar una distorsión aleatoria entre [-5%, +5%] a cada uno de los datos del conjunto de validación, se obtiene un EAMP de 6,023% y un coeficiente de correlación igual a 0,905 para el conjunto de datos mencionados. Esto indica que una vez aprendido los patrones correspondientes al conjunto de datos de aprendizaje, la configuración de red escogida es capaz de generalizar en la predicción y ser tolerante a pequeñas distorsiones existentes en los datos, obteniéndose una diferencia

entre el EAMP en el conjunto de datos de validación con distorsión y el conjunto de datos sin distorsión inferior al 2%.

Trabajos Futuros

Con el objetivo de obtener mejores resultados en la predicción de series de tiempo mediante Redes Neuronales, se mencionan algunas técnicas que pueden ser útiles en la optimización de los modelos neuronales enfocándose en la determinación de los componentes de la arquitectura de red.

a) Búsqueda de las variables de entrada

Para apoyar el proceso de búsqueda de las variables de entrada de la red puede ser útil hacer uso de algunas técnicas del campo estadístico como: coeficientes de autocorrelación y análisis de componentes principales.

b) Selección de la arquitectura de red

Se puede hacer uso de otro modelo de red neuronal para la predicción de series de tiempo, como las Redes Recurrentes de Elman o Redes Función de Base Radial.

4. Conclusión

En esta investigación se han utilizado las redes neuronales artificiales en la predicción de dos series de tiempo tomadas del campo de la industria: Generación de Electricidad Mensual y Consumo Mensual de Gas Natural.

Como parte del objetivo general de esta investigación se ha evaluado la capacidad que tienen las redes neuronales artificiales en la predicción de series de tiempo, resultando efectivas en esta tarea y demostrando que son una herramienta útil en la predicción de series de tiempo.

Uno de los principales inconvenientes en la utilización de redes neuronales es la elección de cada elemento de la arquitectura de red, obteniéndose en muchos casos por ensayo y error dentro de un conjunto acotado de posibles valores. En este trabajo de título se evalúan algunas sugerencias establecidas en la literatura para seleccionar estos elementos basado principalmente en el análisis de cada serie de tiempo, obteniéndose buenos resultados.

En la serie Generación de Electricidad Mensual los resultados que se obtienen son bastante satisfactorios dado que el Error Absoluto Medio Porcentual al evaluar la mejor configuración de red neuronal es inferior al 3%, existiendo una correlación entre la serie de datos entregados por la red y los esperados de 0,949. Al variar la cantidad de datos utilizados en el entrenamiento desde un 80% a un 60% los resultados

obtenidos no se ven afectados siendo capaz de generalizar en un conjunto de datos donde existe mayor probabilidad de encontrar patrones desconocidos. Este comportamiento puede justificarse dada la tendencia y estacionalidad bastante definida de esta serie de tiempo y la suficiente cantidad de patrones con los que se cuenta. Al aplicar una distorsión aleatoria entre $[-5\%, +5\%]$ a los datos de validación se produce un aumento del Error Absoluto Medio Porcentual de menos del 1%, lo cual demuestra la capacidad que tienen las redes neuronales de tolerar ruido en los datos.

En la serie Consumo Mensual de Gas Natural se obtiene un Error Absoluto Medio Porcentual bastante pequeño al evaluar la mejor configuración de red neuronal, obteniéndose un 4,447% y un coeficiente de correlación entre la serie de datos entregados por la red y los esperados de 0,947. Al variar la cantidad de datos utilizados en el entrenamiento desde un 80% a un 60% se obtiene un aumento en el Error Absoluto Medio Porcentual del 1% lo cual puede justificarse dada la baja cantidad de datos utilizados para entrenamiento. Al aplicar una distorsión aleatoria entre $[-5\%, +5\%]$ a los datos de validación se produce un aumento del Error Absoluto Medio Porcentual cercano al 2%, lo cual pone en evidencia la capacidad que tienen las redes neuronales de tolerar ruido en los datos.

Al evaluar los resultados obtenidos con cada configuración en ambas series se puede observar que el algoritmo Resilient Propagation presenta una gran ventaja sobre Backpropagation, obteniéndose mejores resultados y un tiempo de procesamiento bastante menor en la mayoría de los casos de estudio.

References:

- [1] Zhang, Peter: "Neural Networks in Business Forecasting", 1ª edición, Idea Group Publishing, E.U.A. 2004.
- [2] Freeman, James y Skapura, David: "Redes Neuronales Algoritmos, aplicaciones y técnicas de programación", 1ª edición, Addison-Wesley Iberoamericana, E.U.A 1993.
- [3] Kasabov, Nikola: "Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering", 1ª edición, The MIT Press, E.U.A. 1996.
- [4] Rabunal, Juan y Dorado, Julian: "Artificial Neural Networks in Real-Life Applications", 1ª edición, Idea Group Publishing, E.U.A. 2006.
- [5] McNelis, Paul: "Neural Networks in Finance: Gaining Predictive Edge in the Market", 1ª edición, Elsevier Academic Press, E.U.A. 2005.

- [6] Rojas, Raúl: “Neural Networks. A Systematic Introduction”, 1ª edición, Springer, E.U.A. 1996.
- [7] Gujarati, Damodar: “Econometría”, 1ª edición, Mc Graw-Hill, México 2004.
- [8] Faraway, Julian y Chatfield, Chris: “Time series forecasting with neural networks: a comparative study using the airline data”, *Applied Statistics*, Volumen 47, pp. 231-250, 1998.
- [9] Kaastra, Iebling y Boyd, Milton: “Designing a neural network for forecasting financial and economic time series”, *Neurocomputing*, Volumen 10, pp. 215-236, 1996.
- [10] Shlens, Jonathon: “Time Series Prediction with Artificial Neural Networks”, 1999.
- [11] Collantes, Joanna: “Predicción con Redes Neuronales: Comparación con las Metodologías de Box y Jenkins”, Universidad de los Andes, Venezuela 2001.
- [12] Requena, Ignacio: “Introducción a las Redes Neuronales Artificiales. Neurocomputación”, Universidad de Granada, España.
- [13] Correa, Rafael: “Redes Neuronales Artificiales en Ingeniería y Física Nuclear. Caracterización de espectros PIXE”, Universidad de Granada, España 2006.

