

LAS REDES NEURONALES ARTIFICIALES EN LAS FINANZAS

Recepción: Noviembre de 2005 / Aceptación: Diciembre de 2005

(1) Javier Del Carpio Gallegos

RESUMEN

Este artículo muestra en forma sencilla cómo las Redes Neuronales Artificiales pueden aplicarse en las finanzas, en particular, en el área de predicción de variables económicas financieras.

Palabras Clave: Redes neuronales artificiales, finanzas, modelos financieros, pronósticos.

THE ARTIFICIAL NEURAL NETWORKS IN FINANCE ABSTRACT

This article shows how the artificial neural networks can be applied in finance, especially when we try to predict economic or financial variables.

Key Words: Artificial Neural Network, finance, financial modeling, forecasting.

INTRODUCCIÓN

En 1981, el Dr. White (1) realizó un trabajo que ilustraba el uso de las Redes Neuronales Artificiales en la predicción de variables financieras. Desde entonces, se ha incrementado el estudio de las aplicaciones de las Redes Neuronales Artificiales en el campo de las finanzas. En tal sentido, se ha aprovechado la característica de las Redes Neuronales Artificiales, que establece que éstas pueden “aprender”.

Una Red Neuronal Artificial es “un modelo matemático compuesto de un gran número de elementos organizados en niveles. Una Red Neuronal Artificial también puede ser vista como un sistema de cómputo, compuesto por un gran número de elementos interconectados que procesan la información, modificando sus respuestas dinámicas frente a variables externas”.

CONSTRUCCIÓN DE UNA RED NEURONAL ARTIFICIAL

La construcción de una Red Neuronal Artificial pasa por varias etapas:

1. Identificación de la variable financiera que se va a pronosticar.
2. Construcción del conjunto de datos que permitirán activar el proceso de aprendizaje de la Red Neuronal Artificial.
3. Activación del proceso de aprendizaje, con la selección de la arquitectura y los parámetros necesarios para la definición de los pesos de la conexión entre las neuronas.
4. Generalización de los reportes de salida para el pronóstico de la variable financiera.

Detallando cada una de las etapas anteriormente mencionadas tenemos:

Identificación de la variable financiera que se va a pronosticar

El primer paso en la construcción de una Red Neuronal Artificial, que tenga una aplicación financiera, es la definición de la variable financiera objetivo. Se puede decir que las Redes Neuronales Artificiales permiten enfrentar los problemas financieros con un enfoque distinto al de los modelos lineales.

Las aplicaciones de las Redes Neuronales Artificiales en el área financiera son muy diversas. Entre ellas se pueden encontrar, en la administración de los portafolios de inversión, la evaluación de acciones y bonos, las estrategias de cobertura y arbitraje, el análisis de la volatilidad

(1) Magister en Administración y Finanzas. Profesor del Departamento de Gestión y Producción Industrial, UNMSM.
E-mail: jdelcarpiog@unmsm.edu.pe

y correlación y la predicción de los precios de acciones, bonos, tasas de interés y de cambio, entre otros.

Una vez que se ha determinado la variable a estudiar, se debe establecer los límites de la medición del fenómeno. La selección de la variable independiente depende de los factores específicos y externos del analista financiero.

Construcción del conjunto de datos que permitirán activar el proceso de aprendizaje de la Red Neuronal Artificial

Los pasos relevantes en la construcción de una red neuronal son:

- La recolección de los datos
- El análisis
- La selección de las variables de entrada y salida

La recolección de la información debe considerar algunos principios fundamentales: Primero la información debe obtenerse de los mercados financieros. Se debe prestar particular atención a la preparación de los datos de entrada y salida. El proceso para identificar los datos requeridos depende del problema que se esté analizando.

En ese sentido podemos decir que una Red Neuronal que permita pronosticar series de tiempo de variables financieras se puede establecer usando diferentes tipos de información:

- a. Aquella relacionada directamente con la variable de salida (en el mercado seleccionado).

- b. Aquella información resultante de las operaciones relacionadas con la variable de salida.
- c. Aquella que depende de los componentes fundamentales.

Esta situación se puede apreciar en la Figura 1 “Variables de Entrada de una Red Neuronal para Pronósticos Financieros”.

Activación del proceso de aprendizaje, con la selección de la arquitectura y los parámetros necesarios para la definición de los pesos de la conexión entre las neuronas

La construcción de una Red Neuronal pasa necesariamente por algunos pasos que permiten fijar los parámetros que son útiles para el proceso de aprendizaje adecuado para la solución del problema.

La primera fase del análisis radica en seleccionar la arquitectura más adecuada para el proceso de aprendizaje. La parte crítica de esta fase depende del mecanismo de conexión de los nodos de entrada entre ellos y luego de la conexión de éstos con los nodos de salida, por medio de las capas ocultas, lo cual se convierte en un elemento decisivo para el éxito de la operación.

En la literatura existen algoritmos para maximizar la selección de la arquitectura, pero por encima de todo, está la experiencia y la fase de prueba, los cuales se convierten en los mejores criterios de selección.

Se puede afirmar que los parámetros para determinar la definición de la arquitectura son:

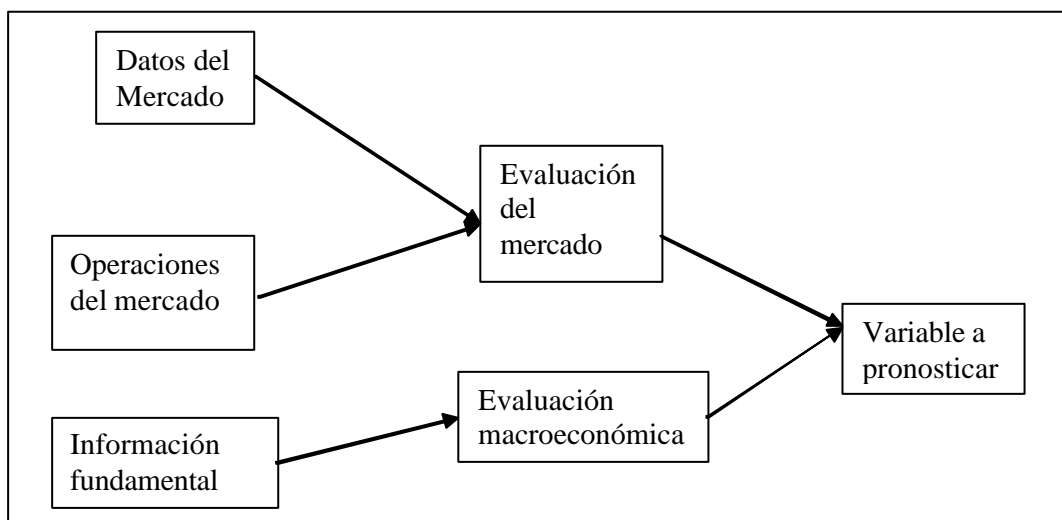


Figura 1. Variables de entrada de una Red Neuronal Artificial para pronósticos financieros

>>> Las redes neuronales artificiales en las Finanzas




Figura 2. Arquitectura de propagación hacia atrás, conexión estándar

a. La división temporal de la base de datos

Una vez que la variable de salida y el contenido de la base de datos se hayan definido, de lo cual se obtendrán las variables de entrada, las series de tiempo históricas deberán subdividirse en períodos de tiempo, lo que se delimitará por el proceso de aprendizaje y evaluación.

b. El número de las capas ocultas y el número de neuronas que se va a insertar en cada capa

Para la determinación del número de capas, existen numerosas contribuciones, metodologías que establecen que una sola capa oculta es suficiente para aproximar, con un alto grado de exactitud, las funciones no lineales más recurrentes. Con relación al número de neuronas asignadas a las capas ocultas, se debe seleccionar aquel número que permita minimizar el riesgo de un sobreaprendizaje, que exige un mayor número de variables de entrada, pero que no asegura tener un pronóstico más confiable.

c. Los mecanismos de conexión entre las diferentes capas

La arquitectura conocida como Redes de Propagación hacia Atrás, o “Back Propagation” se emplea mucho por su habilidad para generalizar resultados para un amplio número de problemas financieros. Este tipo de arquitectura se define como supervisada, es decir, aquella cuyo aprendizaje se ve condicionado por las variables de entrada y de salida. Las posibilidades de conexión que existen son:

- **Conexión estándar:** En este caso las conexiones son entre las capas de entrada y salida, pasando por una capa oculta, como se muestra en la Figura 2.

- **Conexión con salto:** En el caso más simple, la capa de entrada se vincula, no solamente con la capa oculta, sino también con la capa de salida, tal como se muestra en la Figura 3.

- **Conexión recurrente:** En este caso las conexiones proporcionan la posibilidad que las capas ocultas puedan retroalimentar a las variables de entrada, mediante procesos iterativos, tal como se muestra en la Figura 4.

d. La función de activación

Las funciones típicas de activación son:

- Lineal
- Logística
- Sinusoidal
- Gaussiana

e. Las reglas de aprendizaje

La selección de la regla de aprendizaje es problema muy particular, cuando se aplican las Redes Neuronales Artificiales, por cuanto se tiene que decidir qué tasa de cambio de la Red debe modificar la definición de los pesos de las neuronas. Si la tasa de cambio es muy alta, no se puede lograr la convergencia y nos veríamos en la situación de reducir la tasa de cambio.




Figura 3. Arquitectura de propagación hacia atrás, conexión con salto




Figura 2. Arquitectura de propagación hacia atrás, conexión recurrente

El proceso de aprendizaje de la Red pasa por un proceso progresivo que permita la mejor fijación de los parámetros correctos. La recomendación es que se eviten las variaciones radicales de los parámetros.

f. Los indicadores de error de la Red Neuronal

Una vez que hemos fijado las características iniciales de la Red Neuronal, se hace necesario determinar en qué momento se debe detener el proceso de aprendizaje. Estos criterios tienen que estar relacionados con el conjunto de pruebas.

Por otro lado, los parámetros de aprendizaje se relacionan con los indicadores de error, tales como:

- Error medio
- Error máximo
- Número de ciclos sin mejora en el error

Se puede fijar un valor para estos parámetros que permitan que la Red Neuronal se detenga cuando haya alcanzado el valor deseado.

Otro criterio de aceptación es la convergencia. Si los errores se consideran modestos, pero la oscilación tiene una alta divergencia, es oportuno verificar la adecuación de los parámetros.

Generalización de los reportes de salida para el pronóstico de la variable financiera

Una vez que los indicadores son favorables para la Red Neuronal, es necesario verificar la bondad del pronóstico. Es posible que el modelo sea exitoso en la selección de los conjuntos de aprendizaje y de prueba, pero sea inadecuado en el proceso del pronóstico.

Los modelos de Redes Neuronales Artificiales

Es importante señalar que el análisis económico ha evitado preguntas sobre cómo los agentes económicos toman decisiones cuando ellos interactúan con el mundo real; esto se debe a que la mayoría de los modelos formales no son muy adecuados para poder resolver problemas como esos. De la revisión de las

investigaciones relacionadas con este tema, se puede citar los siguientes casos:

En el caso de los Doctores Pablo García Estévez y Prosper Lamothe Fernández [2], éstos pretendieron “encontrar una metodología que nos permita obtener un algoritmo matemático que explique la volatilidad implícita de las opciones sobre el índice bursátil IBEX-35”. Se llega, entonces, a la conclusión de que el modelo de Black Scholes no es cien por cien eficiente, y que las Redes Neuronales dejan crear algoritmos que permiten lograr mejores pronósticos.

De manera similar, los Doctores Shaikh A. Hamid y Abraham Habib [1] también estudiaron la aplicación de las Redes Neuronales, en lo que respecta a la valoración de opciones y concluyeron que “las Redes Neuronales pueden tener una aplicación promisoría en la valoración de opciones, tanto en la determinación del precio de la opción como en la volatilidad implícita”.

En lo que respecta al campo de las predicciones, podemos citar el trabajo de los Doctores Defu Zhang, Qingshan Jiang, Xin Li [5] que, aplicando una Red Neuronal del tipo multicapa “Back propagation”, diseñaron un “sistema que puede pronosticar las señales de compra y venta, de acuerdo con la predicción de las futuras tendencias del mercado de valores y, de esta manera, proporcionar apoyo a la toma de decisiones por parte de los inversionistas”.

Por otro lado, el Doctor Jorge de Andrés Sánchez [3], quien trabajando la información sobre la situación financiera de los bancos españoles en el periodo 1990-2001, logró encontrar que las Redes Neuronales pueden ser de mucha utilidad en “la predicción de la quiebra y de la estimación de los rendimientos de cartera de valores”.

CONCLUSIONES

A pesar de la complejidad del aprendizaje de las Redes Neuronales, la revisión de la literatura permite evi-

>>> *Las redes neuronales artificiales en las Finanzas*

denciar su amplia aplicación en el tema financiero, en especial, en el pronóstico de variables financieras.

La mayoría de los temas relacionados tienen que ver con la predicción de quiebra o la predicción de rendimientos de valores, que ayuden a tomar mejores decisiones financieras. Asimismo, las Redes Neuronales pueden emplearse como herramientas complementarias a los enfoques tradicionales de análisis multivariante.

BIBLIOGRAFÍA

1. Hamid S., Habib A. (2005). *Can Neural Networks Learn the Black- Scholes Model?: A simplified approach*. Working paper No. 2005-01, The Center for Financial studies, Southern New Hampshire University, www.snhu.edu/cfs, consulta hecha el 11 octubre 2005.
2. Lamothe, Prosper; García, Pablo. (2004). *La volatilidad implícita en las opciones sobre índices bursátiles. Propuesta de Metodología de Estimación*. Documento de Trabajo 0407. Doctorado en Finanzas de Empresa, Universidad Complutense. Universidad Autónoma.
3. Sánchez, Jorge de Andrés. (2003). *Dos aplicaciones empíricas de las Redes Neuronales Artificiales a la clasificación y la predicción financiera en el Mercado español*. Revista Asturiana de Economía No 28 . p. 61- 87.
4. White, H. (1988). *Economic Prediction using Neural Networks: The case of IBM Daily Stock Returns*. Proceedings of the IEEE International Conference on Neural Networks. Chicago. publicado en Neural Networks in Finance and Investing. Ed Trippi y Turban. Probus Publishing Company. p. 11459-11482.
5. Zhang D., Jiang Q., Li X. (2004). *Application of Neural Networks in Financial Data Mining*. International Journal of Computational Intelligence, Volume 1. Number 2., p. 116-119.