

**APLICACIÓN DE REDES NEURONALES ARTIFICIALES PARA EL
PRONÓSTICO DE PRECIOS DE CAFÉ****APPLICATION OF ARTIFICIAL NEURONAL NETWORKS FOR COFFEE
PRICE FORECAST****Karen Shirley Cardozo Rueda****Fundación universitaria de San Gil – Unisangil**

Facultad de ciencias naturales e ingenierías, programa de ingeniería de sistemas.
Campus universitario Km 2, Vía San Gil - Charalá, San Gil, Santander, Colombia.
PBX +57 (7) 7245757
E-mail: {kcardozo@unisangil.edu.co }

Resumen: En este trabajo se aprovecha la capacidad para realizar pronósticos con modelos no lineales que poseen las redes neuronales artificiales (ANN), con información estructurada y modelos supervisados, empleándolas en la predicción de precios de café de tipo arábico. Sirviendo como apoyo a los pequeños y medianos empresarios cafeteros que cultivan este producto. Además, el modelo de pronóstico se encuentra establecido por el valor del cierre del dólar y del precio de café. También, se realiza el desarrollo teórico de los fundamentos básicos de las redes neuronales Backpropagation y ajuste de pesos, se realiza la caracterización y luego se realiza una simulación de ellas en el lenguaje de programación Python con las librerías de Numpy y Matplotlib. Los resultados evidencian la cantidad de aciertos que se consiguen a partir de este modelo y su desempeño en el aprendizaje en la reducción de errores.

Palabras clave: Backpropagation, perceptrón, redes neuronales artificiales, predicción de precio.

Abstract: This work employs the ability to make forecasts with non-linear models, structured information and supervised models, that artificial neural networks (ANN) make use of, to predict the prices of the arabic-type coffee, serving as support to small and medium coffee entrepreneurs that harvest this product. In addition, the forecasting model is established by the closing value of the dollar and the coffee price. Also, the theoretical development of the basic foundations of neural networks Backpropagation and weight adjustment algorithms. The characterization is performed, followed by a simulation of the forecast process using the Python programming language with the Numpy and Matplotlib libraries. The result indicates an astonishing amount of success achieved from this model and its performance at learning to minimize errors.

Keywords: Artificial neural networks, backpropagation, perceptron, price forecasting.

1. INTRODUCCIÓN

Una red neuronal es un sistema que permite establecer una relación lineal o no lineal entre las salidas y las entradas. Sus características están inspiradas en el sistema nervioso lo que les da varias ventajas tales como su capacidad de aprendizaje adaptativo, son auto-organizativas, pueden funcionar en paralelo en tiempo real y ofrecen tolerancia a fallos por la codificación redundante de la información.

Las Redes Neuronales Artificiales han sido empleadas para resolver numerosos problemas. Entre estos están los económicos y financieros, destacando en gran medida su aplicación en la predicción de series temporales y su capacidad para detectar y explotar la no-linealidad existente en los datos, aun en condiciones donde existen datos incompletos o la presencia de ruido; también se destacan por su desempeño en la solución de problemas complejos, donde el reconocimiento de modelos o comportamientos es importante (Villada *et al.*, 2012).

En este caso se utilizan técnicas de modelización que se utilizan con información estructurada que es aquella que se encuentra procesada y preparada para ser utilizada directamente a través de lenguajes estadísticos y de programación, las cuales pueden clasificarse como aprendizaje supervisado, en función de la información utilizada para el aprendizaje (Calvo *et al.*, 2018).

Cabe resaltar que los resultados a los pronósticos son más precisos cuando se encuentra en condiciones normales de fluctuación de precios y no bajo una calamidad o anormalidad. Bajo este criterio en las redes neuronales artificiales se crean curvas de aprendizaje, se aprende de los datos que ya se poseen, y después se evalúa el rendimiento del modelo y los posibles ajustes que puedan ser implementados en él.

La implementación de ANN, brinda un apoyo necesario a las necesidades de los caficultores colombianos que cosechan café de tipo Arábico, dado que constantemente se encuentran expuestos a la incertidumbre de la variación en el precio del producto, considerando así, que estas proyecciones contribuirán a una mejor toma de decisiones por parte de los encargados de las ventas de la producción.

2. REDES NEURONALES ARTIFICIALES

Podemos definir una red neuronal como un sistema de tratamiento de información cuya unidad básica de procesamiento está inspirada en la célula principal del cerebro humano (Nielsen, 2015). Las ANN eran originalmente una simulación abstracta de los sistemas biológicos del cerebro, compuestos por un conjunto de unidades llamadas "neuronas" (o "nodos") conectados entre ellos. A diferencia del modelado de simulación, estos sistemas requieren un conocimiento previo de la relación entre parámetros. La ventaja de las ANN consiste en su capacidad para aprender de casos reales y volver a aprender cuando se ingresan nuevos datos en el sistema (Astray *et al.*, 2010).

En lugar de utilizar un modelo digital, en el que todos los cálculos manipulan ceros y unos, una red neuronal funciona creando conexiones entre elementos de procesamiento, el equivalente informático de las neuronas. La organización y los pesos de las conexiones determinan el resultado (Islam *et al.*, 2019).

Las redes neuronales son particularmente efectivas para predecir eventos cuando las NNA tienen una gran base de datos de entrenamiento para aprovechar. Existen diversos tipos de redes, las cuales se implementan en función de las operaciones matemáticas y un conjunto de parámetros necesarios para determinar la salida. (Djilali, L., et al, 2018).

3. ARQUITECTURA DE LAS REDES NEURONALES ARTIFICIALES

La red neuronal artificial se puede dividir en tres capas las cuales son: capa de entrada, capa oculta y capa de salida (da Silva *et al.*, 2016).

- Capa de entrada: Conocida como buffer de entrada, donde se presentan los datos a la red, esta capa recibe datos del entorno externo (Astray *et al.*, 2010). Estas entradas suelen estar normalizadas, lo que da como resultado una mejor precisión numérica para las operaciones matemáticas realizadas por la red.

- Capas ocultas: Las neuronas de entrada están conectadas indirectamente a las neuronas de salida a través de neuronas ocultas (Jiang *et al.*, 2019).

Estas capas están compuestas por neuronas que son responsables de extraer patrones asociados con los datos que se alimentan a la red neuronal.

- Capa de salida: Mantiene la respuesta de la red a una entrada. Los resultados del procesamiento realizado por las neuronas en las capas anteriores son producidos por estas neuronas (Desai *et al.*, 2019).

La Figura (1) muestra el aspecto de una Red Neuronal Artificial simple.




Fig. 1. Estructura de una red neuronal simple

4. ANN Y PRONÓSTICO DEL PRECIO DE ACCIONES

Para el desarrollo del modelo se procedió a recopilar los datos históricos del precio de las acciones de Café tipo Arábica y el precio del dólar, las cuales se negocian simultáneamente en las bolsas de valores de Colombia y Nueva York. Esta información fue obtenida del sitio oficial de indicadores web “dólar web”. Las variables de entrada corresponden a los precios de cierre diarios en dólares y como salida única se tiene el precio a pronosticar para el día siguiente.

El algoritmo que se utilizó fue el perceptrón multicapa con propagación hacia atrás o BP, que se refiere a una amplia familia de redes neuronales artificiales (ANN), cuya arquitectura consta de diferentes capas interconectadas. Las BP ANN representan una especie de ANN, cuyo algoritmo de aprendizaje se basa en la técnica del descenso más profundo. Si se les proporciona un número apropiado de unidades ocultas, también podrán minimizar el error de funciones no lineales de alta complejidad (Buscema, 1998). La función de

activación utilizada en el modelo neuronal fue la función sigmoidea, o función logística.

5. ALGORITMO DE APRENDIZAJE

Para realizar los pronósticos de precios de café se modeló una red de propagación hacia atrás (Backpropagation), en la cual existen cuatro pasos principales para su modelación; (i) Inicialización, (ii) Activación, (iii) Entrenamiento con pesas e (iv) Iteración utilizada en la tarea de clasificación (Basogain, 2008).

Los elementos básicos de procesamiento de información de la red neuronal comienzan con la neurona conectada por enlaces. Cada enlace tiene su propio peso y cada neurona consta de más de un peso, además del peso ajustado. Desde la neurona de entrada, los enlaces se moverán hacia los otros nodos. Esto se conoce como red neuronal feed-forward (FF). Cada enlace tiene un peso numérico y asociado que lo conecta a través de la salida. Todos los enlaces conectados se denominan perceptrón. Después de que los enlaces de entrada se hayan ponderado individualmente, se sumarán para formar una función de activación (Farizawani *et al.*, 2020).

En la figura 2 se muestra un proceso elemental de ANN con algoritmos de propagación hacia atrás.




Fig. 2. Estructura de una red neuronal perceptrón backpropagation.

La red neuronal se encuentra activada a través de la función sigmoidea, la cual es una función de activación no lineal popular que tiene un rango de (0-1), como se observa en la primera fórmula. Además se caracteriza porque siempre se reduce para encajar entre las dos asíntotas horizontales de la función sigmoidea en $y = 0$ e $y = 1$ (Aidan, 2019).

$$S(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

6. PROCESO DE APRENDIZAJE

La Red Neuronal Artificial está compuesta por una matriz que contiene los valores diarios de las variables correspondientes al precio de cierre del café (en dólares) y del dólar. Teniendo el precio del café y dólar como variable de entrada (input) y el precio del café como variable de salida (output).

Como se muestra en la tabla 1, se presentan algunos de los datos de entrenamiento de la red neuronal realizando un proceso de adaptación antes de ser utilizados, teniendo en cuenta que la información corresponde a los precios de finales del año 2019 y comienzos del 2020.

De izquierda a derecha se encuentran los datos de la fecha de recopilación de la información, dato correspondiente al café donde se dividió el precio de cierre en dos millones, dato del dólar donde se divide en seis mil y resultado esperado donde: 1 corresponde a la salida que sube y 0 a la que baja.

Tabla 1. Parte de los datos de entrenamiento.

Datos tratados			
Noviembre	Café	Dólar	Resultado
1	0.4255	0.56388167	1
7	0.4425	0.55327333	1
8	0.4435	0.55450333	1
12	0.4475	0.556835	0
19	0.449	0.57462333	0
20	0.4375	0.572415	1
Diciembre			
2	0.4925	0.58708	1
3	0.502	0.58473167	1
Enero			
16	0.5075	0.54945667	0
17	0.455	0.55223333	0
21	0.435	0.55346167	1
23	0.436	0.556295	1
24	0.445	0.55896	0
28	0.4375	0.5664	0
29	0.4315	0.56543333	0
30	0.566	0.56585	0
31	0.55333333	0.568575	1

7. RESULTADOS

El entrenamiento de los datos causa una disminución considerable en el índice de error presentado como se observa en la figura 3. Este gráfico se generó con la librería de Matplotlib, en la cual se puede observar la iteración de los datos de entrenamiento ejecutados en 2000 ocasiones en las cuales se reajustaban lo que causa una disminución del error final y por ende en el pronóstico generado.




Fig.3. Gráfico de errores

Una vez entrenado el modelo de red se procedió a probar la NNA en repetidas ocasiones para verificar la calidad del entrenamiento. En la tabla 2 se encuentran los datos que se utilizaron para realizar dichas pruebas, cabe resaltar que en esta imagen los datos se encuentran sin el procesamiento necesario para la inserción dentro de la red y con la salida que se espera encontrada en la casilla de Resultado.

Tabla 2. Datos de la prueba de la NNA sin procesar

Fecha	Café	Dólar	Resultado
25 de Noviembre del 2019	938,000	3410.77	964,000
18 de Noviembre del 2019	895,000	3421.26	898,000
02 de Marzo del 2020	997,000	3539.86	1,014,000
25 de Febrero del 2020	965,000	3431.6	955,000
23 de Julio del 2019	786,000	3,178	770,000
24 de Julio del 2019	770,000	3,188	762,000

En la tabla 3 se evidencian los datos post procesamiento y ya ejecutados en la red. Se halló que de seis datos empleados en la prueba de la red solo uno no proyecta la salida necesaria para cumplir con el correcto pronóstico.

*Tabla 3. Datos de la prueba de la NNA
procesados*

				Output
1	0.469	0.341077	0.76979446	
1	0.4475	0.342126	0.6149717	
1	0.4985	0.353986	0.83708113	
0	0.4825	0.34316	0.82617866	
0	0.393	0.317776	0.42605405	
0	0.385	0.318801	0.35453748	

8. CONCLUSIONES

Las redes neuronales artificiales presentan ventajas al ser algoritmos sencillos de modelar e implementar, siendo una herramienta efectiva en el pronóstico de precios de café de tipo arábigo. Además, permiten tener un seguimiento y corrección de errores lo que beneficia en la mejora de resultados.

REFERENCIAS

- Aidan, W. (2019), "Introduction to Neural Networks in Python", *towards data science*.
- Astray, G., Castillo, J. X., Ferreiro-Lage, J. A., Galvez, J. F., & Mejuto, J. C. (2010), "Artificial neural networks: a promising tool to evaluate the authenticity of wine Redes". *CyTA – Journal of Food*, vol. 8(1).
- Basogain, X. (2008), Redes neuronales artificiales y sus aplicaciones Dpto. Ingeniería de Sistemas y Automática, Escuela Superior de Ingeniería Bilbao.
- Buscema, M.b (1998), "Back propagation neural networks", *Subs. use & misuse*, vol.33 (2), p.p 233-270.
- Calvo, J., Guzman, M. and Ramos, D. (2018), *Machine Learning, Una Pieza Clave En La Transformación De Los Modelos De Negocio*, Management Solutions.
- da Silva I.N., Hernane Spatti D., Andrade Flauzino R., Liboni L.H.B., dos Reis Alves S.F. (2016), "Artificial Neural Network Architectures and Training Processes", *Artificial Neural Networks. Springer, Cham*, pp 21-28.
- Desai, S. D., Giraddi, S., Narayankar, P., Pudukalakatti, N. R., & Sulegaon, S. (2019), "Back-propagation neural network versus

logistic regression in heart disease classification", *Advanced computing and communication technologies*, pp. 133-144, Singapore.

- Djilali, L., Suarez, O. J., Sanchez, E. N., Alanis, A. Y., & Garcia, A. P. (2018). Real-time neural backstepping control for a helicopter prototype. Paper presented at the 2017 IEEE Latin American Conference on Computational Intelligence, LA-CCI 2017 - Proceedings, , 2017-November 1-6. doi:10.1109/LA-CCI.2017.8285689
- Farizawani, A. G., Puteh, M., Marina, Y., & Rivaie, A. (2020), "A review of artificial neural network learning rule based on multiple variant of conjugate gradient approaches", *Journal of Physics: Conference Series*, Vol. 1529, No. 2, p.p 022040.
- Nielsen, M. A. (2015), neural networks and deep learning, *CA: Determination press*, Vol. 2018, San Francisco.
- Islam, Mohaiminul & Chen, Guorong & Jin, Shangzh.(2019), "An Overview of Neural Network. American Journal of Neural Networks and Applications", Vol. 5, No. 1, pp. 7-11. doi: 10.11648/j.ajnn.20190501.12
- Jiang, Jingchao & Hu, Guobiao & Li, Xiao & Xu, Xun & Zheng, Pai & Stringer, Jonathan. (2019), "Analysis and Prediction of Printable Bridge Length in Fused Deposition Modelling Based on Back Propagation Neural Network", *Virtual and Physical Prototyping*, vol. 14(3), p.p 253-266.
- Villada, F., Muñoz, N., & García, E. (2012), "Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores", *Inf. tecnol* vol.23, no. 4, pp. 11-20.