

PRONÓSTICOS DE VENTAS UTILIZANDO **BOX-JENKINS** Y **REDES NEURONALES** PARA UNA INDUSTRIA DEL SECTOR GRÁFICO

Cristian Quero Varas
Magíster en Ingeniería Industrial

Omar Carrasco Carvajal
Magíster en Economía Financiera.

La presente investigación realiza proyecciones utilizando como base las series de tiempo de venta de tres productos de la industria gráfica. Para estimar las proyecciones se utilizan dos metodologías Box Jenkins (ARIMA) y Redes Neuronales. Los productos proyectados son representativos de la industria gráfica y se encuentran en diferentes etapas de ciclo de vida, se selecciona el mejor modelo de proyecciones utilizando el indicador de los Errores Cuadráticos Medios. Se concluye con el estudio que los modelos de redes neuronales son capaces de capturar de mejor manera la características de la serie de tiempo teniendo un mayor grado de precisión en sus proyecciones, siendo en promedio un 40% más precisos que los modelos ARIMA. Esta investigación aporta a la gestión de la toma de decisiones de compras y presupuestos para una empresa de la industria gráfica y además facilitar una herramienta de proyección para el sector más sencilla.

Palabras claves: ARIMA, Redes Neuronales, Box Jenkins, Pronóstico de Demanda.

Introducción

Los pronósticos de ventas son claves para las compañías ya que les permiten tomar decisiones sobre las acciones que deberían seguir en el futuro tanto de corto y largo plazo. Además de visualizar las potenciales inversiones para la compañía, a partir de las proyecciones que generan cargas de trabajos y distribución de ellas.

Para lograr una proyección de una serie de tiempo (ventas en el tiempo) como la que se muestra más abajo, existe una amplia gama de investigaciones sobre distintos métodos de predicción de demanda fundamentalmente estadísticos como son los tradicionales, entre los que destacan los modelos ARIMA por sus siglas en Inglés (Autoregressive integrated moving average) los cuales han sido ampliamente estudiados y utilizados en la proyección en el ámbito de las finanzas y la economía debido a que son altamente eficientes en manejar series de datos no estacionarias como por ejemplo en pronóstico de precios de la electricidad [1], pero dado que en la realidad la linealidad es muy difícil de en-

contrar no parece ser muy razonable asumir de antemano que una serie de tiempo en particular, es generada por un proceso lineal, cuando en el mundo real los sistemas son regularmente no lineales [2]. Debido al comportamiento no lineal que presenta un pronóstico de ventas, las redes neuronales artificiales, ANNs, por sus siglas en inglés (Artificial Neural Networks) son un excelente candidato para la predicción de esta estimación. Las ANNs son usadas en modelos y sistemas altamente no lineales [3]. Otra característica importante en las redes neuronales artificiales o RNA empleadas para pronósticos, es que los datos no deben de ser analizados para probar el supuesto de tendencia o estacionalidad en la serie de tiempo previo a la realización del pronóstico [4], no requiere establecer el patrón de comportamiento de la serie de tiempo para establecer para que un pronóstico sea eficiente, esto les entrega una gran ventaja sobre los modelos tradicionales de series de tiempo. Actualmente la gran mayoría de las compañías están en la búsqueda de los algoritmos más sencillos que permitan pronosticar de manera rápida y confiable la demanda futura para un producto o grupo de estos.

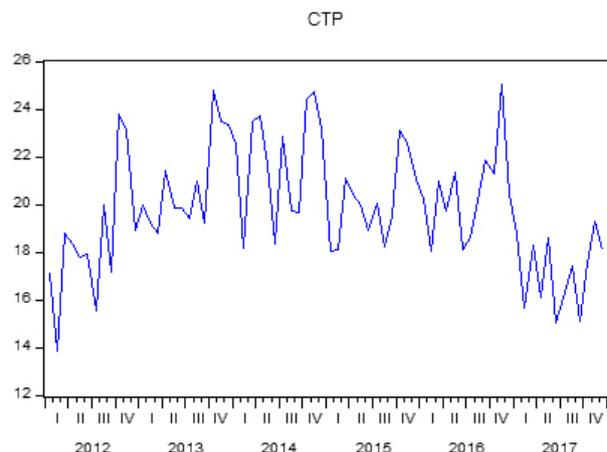


Figura 1
Serie de Tiempo: Ventas por mes

Desarrollo

En este trabajo, tal como se mencionó, se abordan el uso de 2 metodologías para generar proyecciones, la primera es ARIMA (p, d, q) que plantea una ecuación general y selecciona aquella que cumpla inicialmente con la estacionariedad y genere ruido blanco en los errores del modelo proyectado, tal como se muestra en la siguiente ecuación:

$$X_t^d = C + \phi_1 X_{t-1}^d + \dots + \phi_p X_{t-p}^d + \theta_1 \varepsilon_{t-1}^d + \theta_2 \varepsilon_{t-2}^d + \dots + \theta_1 \varepsilon_{t-1}^d + \theta_q \varepsilon_{t-q}^d + \varepsilon_t^d$$

.....

AR(p)

.....

MA(q)

Ecuación 1

Demostración de modelo ARIMA

Donde p denota el número de términos autoregresivos, d el número de veces que la serie debe ser diferenciada para hacerla estacionaria y q el número de términos de la media móvil invertible [11]. Por otro lado las Redes neuronales Artificiales (RNA) se originaron basándose en el modelamiento matemático de cómo funciona el cerebro en los humanos. Las neuronas biológicas proporcionan la transmisión de señales eléctricas que son recibidas como entradas, y cuando estas señales llegan a cierto nivel la neurona se activa y las señales toman un camino y generan una salida. Una neurona artificial (véase la figura 2) simula el comportamiento de una neurona biológica. [13] desarrollaron el primer modelo de neurona artificial en 1943. Las RNA consisten en un conjunto de neuronas o nodos interconectados. Cada nodo está asociado con un conjunto de pesos o ponderaciones y puede ser visto como una unidad de cálculo. La función de activación es una función no lineal. Las conexiones determinan el flujo de información entre los nodos. Mediante el ajuste de los pesos de los nodos, se puede obtener el rendimiento específico o deseado para un determinado conjunto de entradas. Los pesos se ajustan mediante un algoritmo de aprendizaje y a este proceso se llama entrenamiento o aprendizaje.

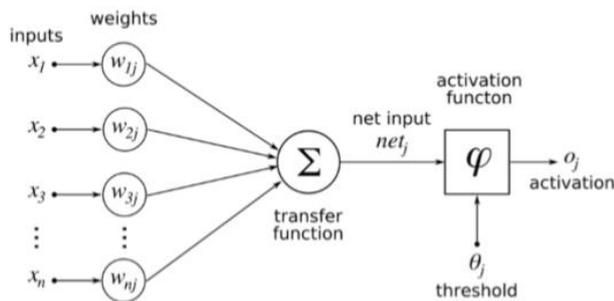


Figura 2

Proceso básico de neurona, Fuente "https://commons.wikimedia.org/wiki/User:Chrislb," [Online].

Explicación Redes Neuronales

Para comenzar se debe realizar un análisis del sistema que ha de utilizar esta red neuronal, identificando variables de entrada y salida, así como la obtención de los datos observados para el conjunto de datos de entrenamiento y de validación de la red. Posteriormente se deben revisar los datos en búsqueda de datos erróneos para el escenario del sistema, además, estos datos han de ser normalizados para optimizar el aprendizaje de la red neuronal. Una vez conseguido, se procede a diseñar la red neuronal con sus respectivas neuronas de entrada, salida y en capa(s) oculta(s), definiendo parámetros iniciales para el entrenamiento. Una vez desarrollada la red, se debe entrenar con el primer conjunto de datos para su optimización de parámetros como de estructura interna para encontrar el modelo óptimo mediante la reducción de la raíz del ECM o RMSE (Error cuadrático medio). Una vez entrenada la red, esta debe ser validada para certificar que es capaz de funcionar con valores no vistos antes, mediante el conjunto de parámetros validados. Para el periodo de entrenamiento se entregaran los datos de los periodos correspondientes desde 01-2012 hasta 12-2017 y se deja el periodo correspondiente de enero a junio 2018 para la comparación de los pronósticos. La red neuronal a implementar corresponde a un modelo auto regresivo [20] que requiere de entrada 12 meses de información y que posee como salida la predicción de 6 meses posteriores. Con esta información se puede definir la red neuronal como un perceptron multicapa con una arquitectura de 12x12x6, es decir, 12 neuronas en la entrada, 12 neuronas en capa oculta y 6 neuronas en la capa de salida según se recomienda en [21]. Los parámetros utilizados para el entrenamiento corresponden a $\alpha = 0,001$ y un total de 4000 épocas para un correcto aprendizaje de la red, este último es alto debido a la baja cantidad en los datos presentados según recomendaciones en [19].

A continuación se muestran los resultados obtenidos para seis meses con las dos metodologías para una de las líneas de productos, seleccionando aquél de menor RMSE, siendo en este caso el de Redes neuronales:

Año	Mes	Ventas Mt2 CTP	Proyección T+1 RNA	Proyección T+2 RNA	Proyección T+3 RNA	Proyección T+4 RNA	Proyección T+5 RNA	Proyección T+6 RNA	ARMA (1,1, 12, 12, 13) Binarias
2018	Enero	16.972	17.791	18.369	18.654	17.447	17.745	17.250	19.615
	Febrero	16.193		17.713	18.333	15.495	17.671	15.797	17.523
	Marzo	15.124			18.592	18.295	16.769	16.380	20.445
	Abril	17.793				18.827	18.945	18.196	20.645
	Mayo	15.869					18.594	19.439	20.263
	Junio	9.784						18.106	18.195
		RMSE	818	1.459	2.545	1.720	1.688	3.741	4.748

Tabla 1

Registro comparativo de la actividad para el Proyecto 3.

Conclusiones

En esta investigación se puede concluir que existen diferencia entre la metodología de Box Jenkins y la utilización de redes neuronales para esta industria: entre ellas se destacan que para trabajar con redes neuronales no es necesario probar ninguna distribución en los datos de origen, estos pueden o no tener correlación y pueden ser trabajados en nivel. Lo anterior se cumple porque las RNA aprenden sobre sus mismos datos y su propio comportamiento dando una gran ventaja ya que son técnicamente mucho más eficientes y requieren un nivel de recursos mucho menor. Buscando probar este mismo punto para esta investigación se utilizó la misma arquitectura en la red neuronal para las tres series de datos, arrojando buenos resultados en todos los casos, esto prueba que en términos técnicos, de fiabilidad de los pronósticos las redes neuronales que actúan con inteligencia artificial son más eficientes y pueden ser usada para distintas series sin necesidad de generar nuevas pruebas. Las compañías quedan con una herramienta que les facilita aumentar su nivel de servicio, bajar sus niveles de inventario con un menor costo operacional, en virtud que pueden generar proyecciones con mayor grado de certeza a un menor costo operacional. En el futuro sería importante utilizar este estudio como base y generar una mayor cantidad de pruebas con series de datos que posean distintos comportamientos, permitiendo probar que la arquitectura de red neuronal utilizada para esta investigación sea capaz de predecir de manera eficiente y con bajos niveles de error, entregando herramientas de proyección de demanda con buenos niveles de precisión pero con niveles de esfuerzo de recurso bastante menores que en la actualidad.

Bibliografía

- [1] M. Zheng, Z. Yan, Y. Ni, G. Li y Y. Nie, "Pronóstico de precios de la electricidad con la confianza de intervalo estimación a través de un enfoque ARIMA extendida" IEE proceso- generación, transmisión y distribución, vol. 153, 3, pp 187 - 195, 2006.
- [2] ZHANG G., PATUWO B. E., HU M. Forecasting with artificial neural networks: the state of the art. International Journal of Forecasting, v. 14, p. 35-62, 1997.
- [3] Azadeh, A., Sheikhalishahi, M., Shahmiri S. (2012) A hybrid neuro-fuzzy simulation approach for improvement of natural gas price forecasting in industrial sectors with vague indicators. The International Journal of Advanced Manufacturing Technology. Springer Link. Volume 62, Issue 14, pp 15-33.
- [4] Ruelas y Laguna, (2013)Comparación de predicción basada en redes neuronales, p.91-105.
- [5] CHU, C. ZHANG, G. A comparative study of linear and nonlinear models for aggregate retail sales forecasting. International Journal of Production Economics, v. 86, p. 217-231, 2003.
- [6] Michael Gilliland, Analytics Magazine "The Business Forecasting Deal", (2011).
- [7] Fildes, Goodwin Good and Bad Judgment in Forecasting: Lessons from Four Companies (2007)
- [8] Charlie Chase, how machine learning is disrupting demand planning, (2018).
- [9] Tom Gruber, Co-creador de Siri (TED Talk, 2017).
- [10] Moghram y S. Rahman, "Análisis y evaluación de cinco a Corto Plazo de carga Forecasting Técnicas" IEEE Transactions on Power Systems, vol. 4, no. 4, pp. 1484-1491, noviembre 1989.
- [11] Jhon Villavicencio " Introducción a series de Tiempo) Pagina 19, 1997.
- [12] Stuart J. y P. Norvig, inteligencia artificial - un enfoque moderno, Prentice Hall, 1994.
- [13] McCulloch y Pitts , Threshold Logic Unit (TLU), o Linear Threshold Unit, 1943.
- [14] Enders, W. 2004. Applied econometrics. Time series. John Wiley and Sons. Hoboken New York. USA
- [15] Gujarati, D. N., Porter, D. N. 2010. Econometría. 5ta ed. Mc Graw-Hill. México, D. F.
- [16] Ngurah Agung, I. G. 2009. Time series data analysis using eviews. John Wiley & Sons. Singapore.
- [17] Evans, M. K. 2003. Practical business forecasting. Blackwell Publishers. Malden Massachussets USA.
- [18] Pindick, R. S., Rubinfeld, D. L. 2001. Econometría modelos y pronósticos. 4ta ed. Mc GrawHill. Mexico D.F.
- [19] C. M. Bishop, Neural networks and their applications. Aston University, Birmingham, United Kingdom, 1994.
- [20] G. Peter Zhang, Min Qi Neural network forecasting for seasonal and trend time series. pp. 501-514 European Journal of Operational Research 160,2005.
- [21] Z. Tang, C. de Almeida, P.A. Fishwick, Time series forecasting using neural networks vs. Box- Jenkins methodology. University of Florida, Gainesville, United States, 1991.