

Modelación y simulación de una red neural para el estudio de la relación oferta – demanda

**Modeling and simulation of a neural network for the study of the supply – demand
relationship**

Gelmar García Vidal¹

Universidad UTE. gelmar.garcia@ute.edu.ec

Laritz Guzmán Vilar²

Investigadora independiente. laritza.guzman@yahoo.es

Recibido: mayo/2023

Aceptado: septiembre/2023

Publicado: diciembre/2023

Cómo citar:

García, G., Guzmán, L. (2023). Modelación y simulación de una red neural para el estudio de la relación oferta – demanda. *Revista Científica Mundo Recursivo*, 6(2), 159-174.

¹ Ingeniero Industrial (1994), Doctor en Ciencias Económicas (2006). Autor de múltiples publicaciones y director de varias tesis doctorales y de maestrías. Profesor de la Universidad UTE Ecuador.

² Licenciada en Historia del Arte. Master en Gestión Turística. Doctora en Arte por la Universidad de Granada (España).

RESUMEN

En este artículo se construye y prueba una red neural de alimentación de dos capas para analizar la relación entre la demanda y oferta de productos agropecuarios en una instalación turística de Santo Domingo de los Tsáchilas, Ecuador. Se consideró la demanda estimada de la instalación y la oferta pronosticada a cubrir por los proveedores de 35 productos que ocupan el 80% del peso en las compras en valores monetarios. Se utiliza la red de alimentación de dos capas entrenada con la regla de aprendizaje *back propagation* de errores. La red construida se encontró que era precisa en el modelado de la demanda y la oferta para las condiciones de estudiadas y también, en la predicción de esta relación con nuevos datos de entrada que se mantienen al margen de la red neural entrenada. Los resultados pueden favorecer el perfeccionamiento de la gestión de compra en la instalación turística.

Palabras claves: oferta, demanda, redes neuronales

ABSTRACT

In this article, a two-layer feed forward neural network is built and tested to analyze the relationship between demand and supply of agricultural products in a tourist facility in Santo Domingo de los Tsáchilas, Ecuador. The estimated demand of the facility and the predicted supply to be covered by the suppliers of 35 products that occupy 80% of the weight in purchases in monetary values were considered. The two-layer feed forward network trained with the error back propagation learning rule is used. The constructed network was found to be accurate in modeling demand and supply for the conditions studied and also in predicting this relationship with new input data that is kept outside the trained neural network. The results can favor the improvement of purchasing management in the tourist facility.

Keywords: supply, demand, neural networks

INTRODUCCIÓN

La logística se define como el procedimiento encargado de administrar los flujos de materiales e información relacionados con las materias primas, el inventario en proceso, los productos terminados, los servicios y los residuos, desde el proveedor hasta el cliente final (Carter, 2011; Carter & Rogers, 2008; Samaranayake & Laosirihongthong, 2016). Este proceso transita por las etapas de gestión de los aprovisionamientos, producción, distribución física y de los residuales (Aguilar, 2009; Feitó Cespón, Cespón Castro, & Rubio Rodríguez, 2016). Dentro de estas etapas, sin disminuir el aporte de ninguna, se destaca la importancia de la actividad de aprovisionamiento al ser la que da origen al resto de las que participan en el proceso logístico.

La actividad de aprovisionamiento está integrada por una serie de actividades entre las que destacan: definición del volumen de compra en función del pronóstico de la demanda y de la disponibilidad financiera, selección de los proveedores, gestión de compra, transporte, control de entrada y control de inventarios, de lo que se infiere el alto grado de complejidad de esta actividad dado la cantidad de variables que se deben considerar en la misma (Aguilar, 2009; Feitó Cespón, et al., 2016; Jia, Lu, Jia, & Lv, 2011; Parada Gutiérrez, 2009; Park & Seo, 2013; Torres Navarro & Córdova Neira, 2014).

La función de compras, como elemento del aprovisionamiento, es quizás una de las más expuestas en una organización, ya que concentra las presiones de la alta dirección en lo que a insumos se refiere en estrecha relación con las expectativas de los clientes para que sean satisfechas sus necesidades (Jia, et al., 2011; Park & Seo, 2013; Singh, 2014). Lo anterior, convierte a la función de compra en un elemento estratégico de la organización.

El conocimiento de la demanda de suministros para la organización, así como, el estudio de la oferta existente para satisfacerla, permitirá realizar compras más económicas, definir con exactitud las especificaciones, concentrarse en las relaciones con los proveedores y prever las necesidades conjuntamente con los diferentes departamentos de la empresa para evitar compras innecesarias (Carter, 2011; Carter & Rogers, 2008; Jia, et al., 2011; Park & Seo, 2013; Singh, 2014).

La situación del análisis de la demanda y oferta de materiales e insumos por la función de compra se agudiza en algunos tipos de organizaciones como es el caso de las turísticas. La alta variabilidad de las necesidades de sus clientes hace que su demanda de insumos al mercado de

oferentes sea alta en cantidad, calidad, variedad, oportunidad, precios, etc., para poder cubrir el tipo de actividad que realiza. Entre estos insumos, los productos agropecuarios y agroindustriales son los que tornan más compleja la situación por características tales como: su carácter perecedero, vocación regional para algunas variantes de ellos y el incremento de sus precios en las últimas décadas (Bosco Gimeno, 1999; Mota, 2012; Parada Gutiérrez, 2009).

En correspondencia con lo anteriormente descrito, se considera que es posible contribuir a la mejora de la gestión de compra aplicando redes neuronales para modelar y simular la relación entre demanda estimada reales de una organización con las proyecciones productivas de los proveedores del territorio. Lo anterior constituye el objetivo del presente estudio.

DESARROLLO

El concepto de logística se asocia a la aplicación del enfoque en sistema a la solución de problemas que (1) garanticen que las actividades de diseño, dirección y operación de los flujos material, informativo y financiero, desde sus fuentes de origen hasta sus destinos finales se ejecuten de forma racional y coordinada y (2) aseguren la provisión al cliente de los productos y servicios en la cantidad, calidad, plazos, costos, lugar y la información demandados, con elevada competitividad y garantizando la preservación del medio ambiente (Dotoli, Epicoco, & Falagario, 2015; Park & Seo, 2013; Servera-Francés, 2010). El primer tipo de problema a resolver por la logística se relaciona con el aprovisionamiento, función compleja y clave dentro de la actividad de las organizaciones, destinada a poner a disposición de la empresa todos los productos, bienes y servicios del exterior que son necesarios para su funcionamiento (Aguilar, 2009; Jia, et al., 2011; Parada Gutiérrez, 2009; Park & Seo, 2013; Servera-Francés, 2010; Torres Navarro & Córdova Neira, 2014).

La función de aprovisionamiento se ha convertido en tema central de mejoramiento en múltiples empresas por su contribución a la satisfacción de los clientes (Prida Romero, 1992). La contribución a esta satisfacción se logra al hacer eficiente y eficaz el proceso de aprovisionamiento, a partir de una adecuada determinación de la demanda, una buena negociación y una cuidadosa selección y evaluación sistemática de proveedores.

Aunque la compra, como función empresarial, presenta un carácter más restringido que el aprovisionamiento, la misma tienen una importancia estratégica en mantener una continuidad en los

suministros de acuerdo con las especificaciones que la organización necesita, en coordinación permanente con el resto de las funciones de la organización (Jia, et al., 2011; Park & Seo, 2013; Singh, 2014). La gran cantidad de variables involucradas (demandas de los clientes, capacidades y costos de producción, capacidades y costos de almacenamientos, capacidades, costos de transportación, costos de compra, cantidad de oferta existentes y calidad de los proveedores que la presentan) y la variabilidad de estas en el tiempo, han provocado el desarrollo de aplicaciones estadístico – matemáticas para estudio de la oferta y la demanda de insumos necesarios para una organización que favorezcan la búsqueda de la mejor alternativa en su encuentro (Chen, Kucukyazici, Verter, & Sáenz, 2015; Dotoli, Epicoco, & Falagario, 2016; Feitó Cespón, et al., 2016; Matinrad, Roghaniana, & Rasi, 2013; Samaranayake & Laosirihongthong, 2016).

Dentro de los mencionados métodos estadístico – matemáticos las redes neuronales han sido utilizadas para satisfacer la necesidad de hacer combinar de una manera precisa las variables oferta y demanda (Çelebi & Bayraktar, 2008; Herbrich, Keilbach, Graepel, Bollmann-Sdorra, & Obermayer, 1999; Heylighen, 2017; Rodger, 2014). Este tema está recibiendo una creciente atención en la literatura actual con el objetivo de pronosticar la demanda (Huber, Gossmann, & Stuckenschmidt, 2017; Lau, Ho, & Zhao, 2013), evaluar proveedores para maximizar el valor de compra total de los artículos teniendo en cuenta restricción presupuestaria, condición de demanda, plazo de entrega y capacidad del proveedor (Singh, 2014), predecir el precio de reserva, el precio objetivo, la oferta inicial del vendedor y su impacto en el resultados de la negociación entre los vendedores y los compradores (Moosmayer, Chong, Liu, & Schuppar, 2013) e identificar oportunidades de hacer corresponder las ofertas de bienes o servicios (Heylighen, 2017).

La no-linealidad inherente en los datos de las organizaciones ha sido observada por mucho tiempo e investigadores han reconocido las limitaciones de las técnicas econométricas que asumen una relación lineal (Evans, 1997; Hornik, Stinchcombe, & White, 1989; Wu & Wang, 2000; Xiao et al., 2014). La asunción de linealidad se usó convenientemente, en parte, porque el coeficiente estimado de estos modelos es de fácil interpretación y, por otro lado, porque la aplicación numérica de otro tipo de análisis era complicada en su momento.

Los avances en materia de tecnológica computacional han relajado las restricciones o complejidades en calcular modelos complejos y han llevado al desarrollo de investigaciones en el contexto organizacional adoptando otras aproximaciones y técnicas de estimación no-lineales basadas

en las ciencias físicas y biológicas como son las redes neuronales. La popularidad de las redes para manejar datos e información compleja ha contribuido considerablemente a la difusión e implementación de modelos de redes neuronales en la economía y la econometría (Herbrich, et al., 1999; Heylighen, 2017).

Algunos autores atribuyen la creciente boga de estos modelos y su aplicación a la capacidad que poseen para permitir relaciones no lineales muy generales entre las variables (Ávila Rondon, da Silva Carvalho, & Infante Hernández, 2008; Chuang & Chao, 2013; Herbrich, et al., 1999; Heylighen, 2017; Wu & Wang, 2000). Esto quiere decir que, bajo ciertas condiciones, una red neuronal puede aproximar cualquier relación, aun no lineal, no importando cuan extraño ni qué tipo de no linealidad se presente (Hornik, et al., 1989). Asimismo, las redes neuronales son una herramienta importante en la modelación de variables en las cuales la existencia de un modelo estructural no es clara, pues no parten de supuestos *a priori* sobre los datos para el pronóstico y todo lo que de ellas puede decirse es inherente a las observaciones (Evans, 1997).

Las ventajas que ofertan las redes neuronales permitirán modelar el comportamiento de la oferta en función de la demanda de los insumos necesarios en una organización, cumpliendo así con el objetivo planteado para este estudio.

MÉTODO

Se consideran los datos reales del año 2016 de la oferta y el pronóstico de la demanda de 35 productos agropecuarios en una instalación turística en Santo Domingo de los Tsáchilas, Ecuador. La selección de los productos responde a que los mismos representan el 80% del valor total de las compras que se realizan en la instalación (ver Tabla 1).

Los datos se volcaron en un fichero de formato *worksheet* con un arreglo en una matriz de 35 x 2 (productos, oferta, demanda) correspondiente al año 2016. Por conveniencia la matriz es dividida en dos paquetes de datos. Las primeras 25 filas como paquete de entrenamiento y el resto como paquete de prueba. Las instrucciones que siguen especifican *P* input como “entrada” (oferta) y *T* targets como “objetivo” (demanda) definiendo una función que puede ser ploteada:

Tabla 1

Productos estudiados

1. Mango	2. Maíz	3. Naranja Agria	4. Cebolla
5. Piña	6. Fresa	7. Manzana	8. Col
9. Plátano Fruta	10. Malanga	11. Limón	12. Zanahoria
13. Papaya	14. Carne de Res	15. Papa	16. Lechuga
17. Sandía	18. Carne de ave	19. Plátano Verde	20. Pepino
21. Aguacate	22. Carne de cordero	23. Yuca	24. Calabaza
25. Guayaba	26. Carne de cui	27. Remolacha	28. Acelga
29. Melón	30. Tomate	31. Ajo	32. Rábano
33. Naranja Dulce	34. Pimiento	35. Huevos de gallina	

```
P = data (1:25, 1:1);
```

```
T = data (1:25, 2:2);
```

```
a = data (26:35, 1:1);
```

```
s = data (26:35, 2:2);
```

```
plot(P, T, 'o')
```


```
[pn, minp, maxp, tn, mint, maxt] = premnmx(P', T')
```

```
[an, mina, maxa, sn, mins, maxs] = premnmx(a', s')
```

La función *newff* se utiliza para crear una red *feed forward* de 2 *layers* o capas. La red tendrá una entrada (en el rango de los mínimos y máximos), seguida de un *layer* de 5 neuronas *tansig*, seguido de un *layer* con 1 neurona *tansig*. Se utiliza la propagación hacia atrás la cual es la más utilizada para problemas de regresión. La red tiene una neurona de salida ya que existe un sólo valor objetivo (demanda) asociado con cada vector de entrada (oferta). Con esta sentencia se crea una variable llamada *net* que contendrá la red neuronal. Dentro de la sentencia se han escrito todas las características de la red (Ver figura 1).

Figura 1:

Sentencia de la Red



RESULTADOS

Una vez concebida la red neuronal y cargados los datos en el MatLab R2007b, se entrena la red a través de la utilización de tres sentencias que configuran dicho entrenamiento:

```
net.trainParam.epochs = 5000  
net.trainParam.lr = 0.001  
net.trainParam.mc = 0.05
```

La sentencia que sigue permite iniciar el entrenamiento de la red:

```
net = train(net, pn, tn)
```

La variable *net* se entrena, con las matrices de datos de entrada *p* y con la matriz de resultados deseados *t*. La red comienza a realizar ciclos y a modificar pesos sinápticos y muestra cada 50 ciclos el resultado. El entrenamiento parará cuando se llegue al final de los ciclos, o cuando se consiga que el error entre los datos obtenidos por la red llegue al objetivo conseguido. La red se simulada a través de la declaración que sigue:

```
y = sim(net, an)
```

En la variable `y` se recogen los resultados de la red.

```
t = postmnmx(y', mins, maxs)
[t s]
plot(t, s, '*')
hold on
title('Comparación entre el Targets actual y las predicciones')
```

Se calcula el MSE (*mean square prediction errors*) entre los valores actuales y pronosticados.

```
d = [t - s].^2
mse = mean(d)
```

Para saber si los resultados obtenidos son los deseados, se calcula el coeficiente de correlación entre los resultados de la red y los deseados.

```
[m, b, r] = postreg(t', s')
```

Para deducir el algoritmo, primero se obtienen los pesos sinápticos de la red. Donde W es la matriz de los pesos que unen la capa de entrada y la capa oculta. LW es la matriz de los pesos que unen la capa oculta y la capa de salida. *Umbral* es la matriz de los umbrales de la capa oculta y *Lumbral* es la matriz de los umbrales de la capa de salida. En la matriz W se sitúan los pesos sinápticos que unen la capa de entrada con la capa oculta de la red.

```
W = net.IW{1,1}
```

En la matriz umbral se sitúa el valor de los umbrales de cada una de las neuronas de la capa oculta.

```
umbral = net.b{1}
```

En la matriz *LW* se sitúa a los pesos sinápticos que unen la capa oculta con la capa de salida:

```
LW = net.LW{2,1}
```

En la matriz *Lumbral* se establece el valor del único umbral que tiene la neurona situada en la capa de salida:

```
Lumbral=net.b{2}
```

Finalmente se imprimen las cargas:

```
input_layer_weight = net.iw{1,1}  
Hidden_layer_weight = net.lw{2,1}  
Bias_weights = net.b{1}
```

La salida final se expresa de la forma que sigue:

```
mse =  
3.2713e+010
```

Este indicador muestra el valor del MSE de la red entrenada que como se aprecia es lo suficientemente bajo como para decir que la diferencia entre el estimador y lo que se estima es despreciable. Para comprobar el grado de predicción del modelo utilizamos el coeficiente de correlación entre los resultados de la red y los deseados. La red ofrece la siguiente respuesta:

```
m =  
0.8947  
b =  
1.0632e+005  
r =  
0.9997
```

Este coeficiente entre los resultados obtenidos en el test y los resultados reales es del 99.97%, un valor muy aceptable teniendo en cuenta el tamaño pequeño de la muestra utilizada. Los parámetros m y b son, respectivamente el origen y la pendiente de la recta que mejor se ajusta a los resultados obtenidos.

Los pesos, umbrales y detalles generales con que trabaja la red, se muestran en la tabla 2 y 3:

Tabla 2

Pesos y umbrales de la red

W =				umbral =
7.0082				-6.9918
7.0002				-3.4997
-7.0011				0.0143
7.0595				3.3899
7.0887				6.9032
LW =				umbral =
-0.1849	0.0922	-0.3240	0.9356	-0.5426
0.3737				

Tabla 3


Detalles de la red neural entrenada utilizada

input_layer_weight =	Hidden_layer_weight =					Bias_weights =
7.0082						-6.9918
7.0002						-3.4997
-7.0011	-0.1849	0.0922	-0.3240	0.9356	0.3737	0.0143
7.0595						3.3899
7.0887						6.9032

El ploteo del comportamiento de la oferta y la demanda se aprecia en la Figura 2:

Figura 2


Ploteo oferta vs demanda



Con los datos detallados de cada producto agropecuario analizado se calculó la precisión de la red neuronal construida, la cual fue verificada usando el análisis de regresión y el coeficiente de correlación. El coeficiente de correlación entre la oferta y la demanda determinado por la red neuronal fue de 0.9997 con un *slope* igual a 0.89. La alta correlación confirma que la nueva red construida es altamente precisa en predecir el comportamiento de la oferta y demanda (ver Figura 3).

Figura 3:

Gráfico de regresión para juzgar la red neuronal artificial de oferta y demanda



Es posible observar que la nueva red construida es precisa en predecir la oferta requerida en relación con la demanda de productos que se pueda presentar por parte de la instalación turística estudiada, con un alto coeficiente de correlación 0.9997. O sea, la red ha sido capaz de calcular la oferta de 35 productos diferentes puestos al azar con una precisión del 99.97%.

CONCLUSIONES

El presente estudio sirve para comprobar el potencial de las redes neuronales supervisadas para modelar el comportamiento de las relaciones entre la oferta y la demanda en las organizaciones. El modelo de red neuronal desarrollado resultó ser muy adecuado para estimar dicha relación, siendo congruente con resultados obtenidos por estudios de similar factura (Ávila Rondon, et al., 2008; Çelebi & Bayraktar, 2008; Lau, et al., 2013; Moosmayer, et al., 2013; Rodger, 2014).

La red neuronal construida consigue encontrar la relación no lineal que existe entre los conjuntos de datos de la oferta y la demanda. El análisis de este resultado puede ser utilizado por los encargados de compra del establecimiento turístico que se estudia para encontrar nuevas relaciones no estudiadas y realizar predicciones de la oferta necesaria para satisfacer las demandas de la instalación. Esto es así, ya que la red construida fue entrenada teniendo en cuenta datos reales de oferta y demanda lo que hace que la red neural sea lo suficientemente precisa para predecir el comportamiento de estas variables sin importar su comportamiento futuro. Entonces, desde el punto de vista práctico la red construida y entrenada puede constituir una herramienta para el análisis de la oferta y demanda para el tipo de productos estudiados y, de esta forma, mejorar la toma de decisiones en cuanto a proceso de compra se refiere (Çelebi & Bayraktar, 2008; Chuang & Chao, 2013; Evans, 1997; Herbrich, et al., 1999; Rodger, 2014).

Entre las limitaciones del estudio se encuentra el hecho de la restringida gama de productos incluidos en la modelación y simulación de la red. No obstante, siempre es posible introducir otros productos considerados como nuevos insumos para capacitar a la red. De igual forma, para realizar una generalización superior que la lograda con la red neuronal diseñada y simulada se debería utilizar una cantidad de datos mayor de la demanda y oferta de los productos analizados, a pesar de que la precisión alcanzada por la red con los datos utilizados se considera muy buena.

BIBLIOGRAFIA

- Aguilar, J. G. (2009). Gestión de inventarios como factor de competitividad, en el sector metalmecánico de la región occidental de Venezuela. *Revista de Ciencias Sociales (RCS)*, XV(3), 509 - 518.
- Ávila Rondon, R. L., da Silva Carvalho, A., & Infante Hernández, G. (2008). Innovation in Manufacturing Networks. In A. Azevedo (Ed.), *Neural Network Modelling and Simulation of The Scheduling*. (pp. 231-238). New York: Springer.
- Bosco Gimeno, J. (1999). El aprovisionamiento en la hostelería: un cuidado muy especial. *Distribución y Consumo*(46), 59-60.
- Carter, C. R. (2011). A call for theory: The maturation of the supply chain management discipline. *Journal of Supply Chain Management*, 47(2), 3-7. doi: <http://dx.doi.org/10.1111/j.1745-493X.2011.03218.x>
- Carter, C. R., & Rogers, D. S. (2008). A framework of sustainable supply chain management: moving toward new theory. *International Journal of Physical Distribution & Logistics Management*, 38(5), 360-387. doi: <http://dx.doi.org/10.1108/09600030810882816>
- Çelebi, D., & Bayraktar, D. (2008). An integrated neural network and data envelopment analysis for supplier evaluation under incomplete information. *Expert Systems with Applications*, 35(4), 1698-1710. doi: <https://doi.org/10.1016/j.eswa.2007.08.107>
- Chen, W., Kucukyazici, B., Verter, V., & Sáenz, M. J. (2015). Supply chain design for unlocking the value of remanufacturing under uncertainty. *European Journal of Operational Research*, 247(3), 804-819. doi: <https://doi.org/10.1016/j.ejor.2015.06.062>
- Chuang, L.-M., & Chao, S.-T. (2013). Evolution of National Entrepreneurial Opportunity Recognition: A Neural Network Analysis. *Journal of Advanced Management Science*, 1(1), 66-70. doi: 10.12720/joams.1.1.66-70
- Dotoli, M., Epicoco, N., & Falagario, M. (2015). A Technique for Supply Chain Network Design under Uncertainty using Cross-Efficiency Fuzzy Data Envelopment Analysis. *ScienceDirect*, 48(3), 634-639. doi: <https://doi.org/10.1016/j.ifacol.2015.06.153>
- Dotoli, M., Epicoco, N., & Falagario, M. (2016). A fuzzy technique for supply chain network design with quantity discounts. *International Journal of Production Research*, 55(7), 1862-1884. doi: <http://dx.doi.org/10.1080/00207543.2016.1178408>

- Evans, O. V. D. (1997). Short-Term Currency Forecasting Using Neural Networks. *ICL Systems Journal*, 11(2), 279-302.
- Feitó Cespón, M., Cespón Castro, R., & Rubio Rodríguez, M. A. (2016). Modelos de optimización para el diseño sostenible de cadenas de suministros de reciclaje de múltiples productos. *Ingeniare. Revista chilena de ingeniería*, 24(1), 135-148. doi: <http://dx.doi.org/10.4067/S0718-33052016000100013>
- Herbrich, R., Keilbach, M., Graepel, T., Bollmann-Sdorra, P., & Obermayer, K. (1999). Neural Networks in Economics. Background, Applications and New Developments. In T. Brenner (Ed.), *Computational Techniques for Modelling Learning in Economics* (pp. 169-196). Boston, MA: Springer US.
- Heylighen, F. (2017). Towards an intelligent network for matching offer and demand: From the sharing economy to the global brain. *Technological Forecasting and Social Change*, 114, 74-85. doi: 10.1016/j.techfore.2016.02.004
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer Feedforward Networks are Universal Approximator. *Neural Networks*, 2(5), 359-366. doi: [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
- Huber, J., Gossmann, A., & Stuckenschmidt, H. (2017). Cluster-based hierarchical demand forecasting for perishable goods. *Expert Systems with Applications*, 76, 140-151. doi: <https://doi.org/10.1016/j.eswa.2017.01.022>
- Jia, Z., Lu, X., Jia, D., & Lv, Y. (2011). Research and development of purchase management system for Chinese medium and small manufacturing enterprises. *International Journal of Industrial Engineering: Theory Applications and Practice*, 18(3), 140-150.
- Lau, H. C. W., Ho, G. T. S., & Zhao, Y. (2013). A demand forecast model using a combination of surrogate data analysis and optimal neural network approach. *Decision Support Systems*, 54(3), 1404-1416. doi: <https://doi.org/10.1016/j.dss.2012.12.008>
- Matinrad, N., Roghaniana, E., & Rasi, Z. (2013). Supply chain network optimization: A review of classification, models, solution techniques and future research. *Uncertain Supply Chain Management*, 1, 1-24. doi: <http://dx.doi.org/10.5267/j.uscm.2013.05.003>
- Moosmayer, D. C., Chong, A. Y.-L., Liu, M. J., & Schuppar, B. (2013). A neural network approach to predicting price negotiation outcomes in business-to-business contexts. *Expert Systems with Applications*, 40(8), 3028-3035. doi: <https://doi.org/10.1016/j.eswa.2012.12.018>

- Mota, P. (2012). Los Hoteles se agarran a la Gestión de Compras. *Alimarket: Hoteles y Restauración. Hostelmarket*(148), 60-72.
- Parada Gutiérrez, O. (2009). Un enfoque multicriterio para la toma de decisiones en la gestión de inventarios. *Cuadernos de Administración*, 22(38), 169-187.
- Park, C., & Seo, J. (2013). Consideration of purchase dependence in inventory management. *Computers & Industrial Engineering*, 66(2), 274-285. doi: 10.1016/j.cie.2013.06.015
- Prida Romero, B. (1992). *Mejora de la competitividad de la empresa a través de la gestión de aprovisionamiento, manutención y almacenaje*. Madrid: Impresiones Ligeras.
- Rodger, J. A. (2014). A fuzzy nearest neighbor neural network statistical model for predicting demand for natural gas and energy cost savings in public buildings. *Expert Systems with Applications*, 41(4, Part 2), 1813-1829. doi: <https://doi.org/10.1016/j.eswa.2013.08.080>
- Rodríguez Barroetabeña, M., & Cabrera Expósito, Y. (2008). Estudio de los niveles de satisfacción de la demanda de los productos agrícolas en los hoteles Brisas Guardalavaca y Club Amigo Atlántico-Guardalavaca. (Tesis en opción el título de Licenciado en Economía). Universidad de Holguín "Oscar Lucero Moya", Holguín.
- Samaranayake, P., & Laosirihongthong, T. (2016). Configuration of supply chain integration and delivery performance: Unitary structure model and fuzzy approach. *Journal of Modelling in Management*, 11(1), 43-74. doi: <http://dx.doi.org/10.1108/JM2-01-2014-0005>
- Servera-Francés, D. (2010). Concepto y evolución de la función logística. *Innovar*, 20(38), 217-234.
- Singh, A. (2014). Supplier evaluation and demand allocation among suppliers in a supply chain. *Journal of Purchasing and Supply Management*, 20(3), 167-176. doi: <https://doi.org/10.1016/j.pursup.2014.02.001>
- Torres Navarro, C. A., & Córdova Neira, J. A. (2014). Diseño de sistema experto para toma de decisiones de compra de materiales. *Cuadernos de Administración*, 30(52), 20-30.
- Wu, C., & Wang, X.-M. (2000). A Neural Network Approach for Analyzing Small Business Lending Decisions. *Review of Quantitative Finance and Accounting*, 15(3), 259-276.
- Xiao, Y., Liu, J. J., Hu, Y., Wang, Y., Lai, K. K., & Wang, S. (2014). A neuro-fuzzy combination model based on singular spectrum analysis for air transport demand forecasting. *Journal of Air Transport Management*, 39, 1-11. doi: <https://doi.org/10.1016/j.jairtraman.2014.03.004>