

## **Metodología para pronosticar demanda y clasificar inventarios en empresas comercializadoras de productos mayoristas**

A Methodology to Forecast the Demand and Classify Inventories in Wholesale Supplier Companies

MSc. Carlos Jesús Madariaga Fernández<sup>1\*</sup> <http://orcid.org/0000-0001-8194-2216>

Dr. C. Yosvani Orlando Lao León<sup>2</sup> <http://orcid.org/0000-0001-7491-3548>

MSc. Dagnier Antonio Curra Sosa<sup>3</sup> <http://orcid.org/0000-0001-5361-6536>

Dr. C. Rafael Lorenzo Martín<sup>4</sup> <http://orcid.org/0000-0001-6852-5725>

<sup>1</sup>Departamento de Desarrollo de Sistemas, Universidad de Holguín, Cuba

<sup>2</sup>Facultad de Ciencias Empresariales y Administración, Universidad de Holguín, Cuba

<sup>3</sup>Facultad de Ingeniería, Universidad de Holguín, Cuba

<sup>4</sup>Dirección de Ciencia Tecnología e Innovación, Universidad de Holguín, Cuba

Autor para la correspondencia: [carlosjmadariaga@gmail.com](mailto:carlosjmadariaga@gmail.com)

### **RESUMEN**

**Objetivo:** Proponer una metodología que permita la clasificación de inventarios y el pronóstico de la demanda, en empresas comercializadoras de productos mayoristas, los cuales son factores claves para optimizar su desempeño.

**Métodos y técnicas:** La metodología se sustenta en el uso de una red neuronal artificial tipo perceptrón multicapa creada con el *software* Weka; con el agregado de resolver problemas de clasificación de ítems del inventario, basados en ABC y el proceso de análisis jerárquico AHP. La metodología constó de tres fases, la primera encargada de la clasificación de los inventarios, la segunda del pronóstico, y la tercera del análisis integrado de los resultados.

**Principales resultados:** Se propuso una escala jerárquica de variables para la clasificación de ítems del inventario, así como de los pesos de los criterios y subcriterios que la conforman, y su rango de selección. Se mostró una manera efectiva para pronosticar la demanda de forma individualizada para cada ítem del inventario.

**Conclusiones:** La aplicación de la herramienta metodológica en la empresa ACINOX UEB Holguín comercializadora, de la provincia Holguín, Cuba, validó su efectividad para resolver problemas de clasificación de inventarios y pronóstico de demanda. Como derivado de su aplicación, se proporcionó a sus directivos, un instrumento que permite la toma de decisiones en aras de favorecer aquellos ítems mejor clasificados y sus pronósticos.

**Palabras clave:** pronóstico de la demanda, planeación agregada, redes neuronales artificiales, clasificación de inventarios, clasificación ABC.

## ABSTRACT

**Objective:** To recommend a methodology that allows for inventory classification and demand forecast, by wholesale supplier companies, as critical factors to implement performance optimization.

**Methods and techniques:** The methodology relies on the use of a multilayer artificial neural network developed with Weka software, which adds the solution of inventory item classification problems, based on ABC and Analysis of hierarchical processes (AHP). The methodology was developed in three phases, the first one was in charge of inventory classification, the second was engaged in forecasting, and the third, in integrated result analysis.

**Main results:** A hierarchical scale of variables was suggested for inventory item classification, as well as weighing opinions and sub-opinions in it, and its selection scope. An effective way of forecasting individual demands was presented for every inventory item.

**Conclusions:** The application of this methodological tool by ACINOX sales company in Holguin province corroborated its effectiveness to solve inventory classification problems and demand forecasting. Deriving from the application, all the executives have

access to a tool that contributes to decision-making, in order to favor better classified items and their forecasts.

**Key words:** demand forecasting, aggregate planning, artificial neural networks, inventory classification, ABC classification.

Recibido: 09/03/2020

Aprobado: 30/09/2020

## INTRODUCCIÓN

La búsqueda de mejoras en todos los procesos de las empresas comercializadoras constituye una realidad prioritaria para alcanzar el éxito en nuestros días. En este sentido se requiere el correcto manejo de los procesos críticos de estimación de la demanda, la gestión de inventarios y la planeación agregada.

El hecho de que las empresas comercializadoras puedan predecir la demanda que tendrán sus productos en el mercado, sería la garantía de poder diseñar óptimamente las estrategias del encadenamiento de las tareas que conforman al proceso comercial, lo cual sin lugar a dudas potenciará sus niveles de comercialización y conllevaría al éxito de su gestión.

Según criterios de Jacobs y Chase (2014), existen dos fuentes básicas de demanda: la dependiente y la independiente. La primera es la demanda de un producto o servicio provocada por la demanda de otros productos o servicios; esta es una demanda interna que no necesita pronóstico. La independiente no se deriva directamente de la demanda de otros productos, por lo que sí requiere del estudio de su pronóstico, y es precisamente este tipo de demanda independiente el objeto esencial al cual se dirige este artículo.

Actualmente se han desarrollado varias técnicas de pronóstico que intentan predecir uno o más de los cuatro componentes de la demanda: tendencia, ciclo, estacionalidad y aleatoriedad (Krajewski, Malhotra & Ritzman, 2018; Rivas, 2017; Stevenson, 2018).

- La tendencia, considera el cambio gradual en la serie de tiempo sobre un largo período de tiempo.
- El ciclo, analiza cualquier patrón de secuencias de valores por arriba o debajo de la línea de tendencia.
- La estacionalidad, considera patrones regulares de variabilidad dentro de ciertos periodos de tiempo.
- La aleatoriedad, es causada en corto tiempo, no es posible anticiparla y no presenta factores recurrentes.

A su vez, un pronóstico usualmente se clasifica por el horizonte de tiempo que abarca, y se clasifica en tres categorías: corto, mediano y largo plazo. Los pronósticos a mediano y largo plazo se distinguen de los pronósticos a corto plazo, entre otros elementos, porque este último tiende a ser más preciso, ya que en la medida que el horizonte temporal se alarga es más probable que la precisión del pronóstico disminuya (Heizer, Render & Munson, 2017).

Para llevar a cabo la planeación agregada son empleados los pronósticos a corto plazo. En tanto las técnicas de pronósticos utilizadas pueden ser cualitativas como cuantitativas. Las cualitativas se caracterizan por tener un sustento subjetivo, ya que son basadas en estimados y opiniones. Por su parte las cuantitativas pueden dividirse en series de tiempo, relaciones causales y simulación:

- las series de tiempo se caracterizan en el análisis histórico de los eventos a través del tiempo para proyectar el futuro,
- las relaciones causales tratan de entender el sistema subyacente y que rodea al elemento que se va a pronosticar,
- mientras las simulaciones se sustentan en modelos dinámicos, casi siempre por computadora, que permiten al encargado de las proyecciones, suponer acerca de las variables internas y el ambiente externo en el modelo.

La clasificación del inventario es un agregado necesario para pronosticar la demanda y para planificar las operaciones en las empresas comercializadoras de productos mayoristas.

Una de las técnicas estadísticas más usadas para la toma de decisiones es el análisis de Pareto, el cual se emplea para delimitar un número de tareas que prevean un efecto

significativo. Se basa en el principio de considerar el análisis de todos los datos desde la mayor hasta la menor frecuencia de ocurrencia, lo cual facilita identificar los pocos factores vitales que serán considerados y los muchos factores triviales que serán ignorados.

El análisis ABC usa el principio de Pareto, aunque considera por lo general un solo criterio para la selección de ítems. Estos pocos ítems en los cuales estadísticamente recae la mayor contribución a las ventas son llamados ítems de clase A, los cuales son claves para el negocio, ya que su existencia constituye la mayoría de inversión en recursos de inventario. Los otros ítems conocidos como B y C son numerosos en cantidad pero su contribución es menos significativa.

Como parte de la planeación agregada es vital destinar la mayoría de los recursos a los ítems tipo A (mayor rendimiento), mientras que los gastos en los otros que tienen mucho menos efecto sobre las ganancias de la empresa son mantenidos en un mínimo. De esta forma, el esfuerzo y los recursos ahorrados en ítems de bajo valor (ítems B y C) serán destinados a potenciar la comercialización de los productos considerados como ítems tipo A. El análisis ABC es el método más tradicionalmente usado para la clasificación de inventarios. En tal sentido para la clasificación multicriterio se requiere de un análisis jerárquico de las variables en cuestión.

A partir de las variables definidas, el valor anual de la demanda de un producto y la naturaleza crítica del producto se clasificó en los ítems del inventario (Flores & Whybark, 1989). En tanto Flores, Olson & Dorai (1992) muestran el mismo proceder, sin embargo consideran válida la adición de la variable “mejor tiempo”. En la industria farmacéutica, por ejemplo, se empleó una red neuronal artificial para clasificar ítems aleatorios basados en el precio de la unidad, el costo, la demanda y el tiempo de entrega (Partovi & Anandarajan, 2002). Otros criterios como costo de unidad y tiempo fueron propuestos por Hadi (2010), pero empleando un modelo no-lineal programado. Rezaei & Dowlatshahi (2010) proponen un sistema basado en reglas difusas basado en los criterios precio, demanda anual, tiempo y durabilidad. Por su parte Balaji & Senthil (2014) muestran una solución para la empresa automotriz basada en una jerarquización de la clasificación, técnica esta que sustenta parte del procedimiento propuesto en el

presente artículo. Por su parte en Zowid, Babai, Douissa, & Ducq (2019) se emplea el ABC usando un modelo gaussiano pero aplicado solo en un conjunto de datos teóricos. El proceso de análisis jerárquico (AHP, por las siglas de *Analytic Hierarchy Process*) data de 1980. Fue desarrollado por Saaty con el propósito de resolver problemas complejos de clasificación multicriterio; dicho autor le definió una escala, la cual se muestra en la Tabla 1.

**Tabla 1.** Escala fundamental para el proceso de análisis jerárquico

Valor de ij	Descripción
1	Criterio donde i y j tienen igual importancia
3	Criterio donde i tienen ligera importancia más que j
5	Criterio donde i tienen más importancia que j
7	Criterio donde i tienen mucha más importancia que j
9	Criterio donde i es absolutamente más importante que j
2,4,6,8	Valores medios

Fuente: Elaboración basada en Saaty (1980)

Este proceso consiste en la desintegración de problemas complejos, en subproblemas, y estos a su vez, constituyendo una estructura jerárquica, la cual es evaluada según la escala anterior por pares de criterios sobre el impacto del ítem. Este proceder es a criterio de expertos un paso de vital importancia en el proceso de toma de decisiones. El AHP consiste en cuatro pasos (Balaji & Senthil, 2014), los cuales son:

- (1) El problema es desintegrado en una estructura jerárquica basada en objetivos, criterios, subcriterios y alternativas.
- (2) Los criterios y alternativas son comparados en pares con respecto a la importancia del objetivo que se tiene.
- (3) Los resultados de la comparación por pares de n criterios pueden ser añadidos en una matriz (A) de comparación n \* n usando la fórmula 1.

$$A = (a_{ij}), \text{ donde } i, j = 1, 2, 3, \dots, n. \quad (1)$$

Usando la fórmula 2 se calcula el peso de la prioridad de la matriz de comparación

$$Aw = h_{max} W \quad (2)$$

Donde  $A$  es el elemento  $n$  de la matriz de comparación,  $h_{max}$  es el máximo de cada valor de  $A$  y  $w$  es cada vector correspondiente a  $h_{max}$ .

- (4) El índice de consistencia ( $CI$ ) puede ser calculado para evaluar la consistencia de la matriz usando la ecuación 3.

$$CI = \frac{h_{max}-n}{n-1} \quad (3)$$

Para medir el grado de consistencia de  $CI$  del radio de consistencia  $CR$  se calcula empleando la ecuación 4.

$$CR = \frac{CI}{RI} \quad (4)$$

Donde  $RI$  es el índice aleatorio.

El valor de  $CR$  debe ser menor que 0,10; de no serlo el procedimiento debe ser repetido para mejorar la consistencia.

La integración del pronóstico de la demanda y la clasificación de inventarios ha sido considerada por numerosos investigadores, dado su alto impacto en la planeación agregada de las organizaciones. En investigaciones recientes en esta área se evidenció que existen autores que integran simultáneamente los dos temas, proponiendo, muchas veces, mejoras o alternativas a los algoritmos clásicos. Snyder, Koehler & Ord (2002) desarrollaron un modelo de inventarios que parte de pronósticos por suavización exponencial. Little & Coughlan (2008) estudiaron la optimización de los *stocks* de seguridad a partir de restricciones en instituciones hospitalarias. Ferbar (2010) propuso integrar el modelo de inventarios y el de pronósticos optimizando tanto los parámetros como los valores iniciales. Teunter, Syntetos, Babai & Stephenson (2011) estudiaron el efecto de los modelos de pronósticos en los costos y en los niveles de servicio; ellos propusieron que se tengan en cuenta esos factores, además de la minimización del error para evaluar el modelo a aplicar. Mientras que la técnica de pronósticos Holt-Winters con el añadido de la diferenciación de nivel de servicio por clasificación ABC, fue empleada por Arango, Giraldo y Castrillón (2013) en empresas comercializadoras y de servicios.

## DESARROLLO

Los métodos de *machine learning* han demostrado mejor rendimiento que todas las técnicas estadísticas utilizadas para el análisis de serie de tiempo (Fry & Brundage, 2020; Makridakis, Spiliotis & Assimakopoulos, 2018). La capacidad de aproximación universal de las redes neuronales (NN, de las siglas de *Neuronal Networks*) para funciones continuas que tienen primera y segunda derivada en todo su dominio ha sido verificada matemáticamente. Adicionalmente, varios estudios demuestran que las NN pueden aproximar con exactitud diversos tipos de relaciones funcionales complejas.

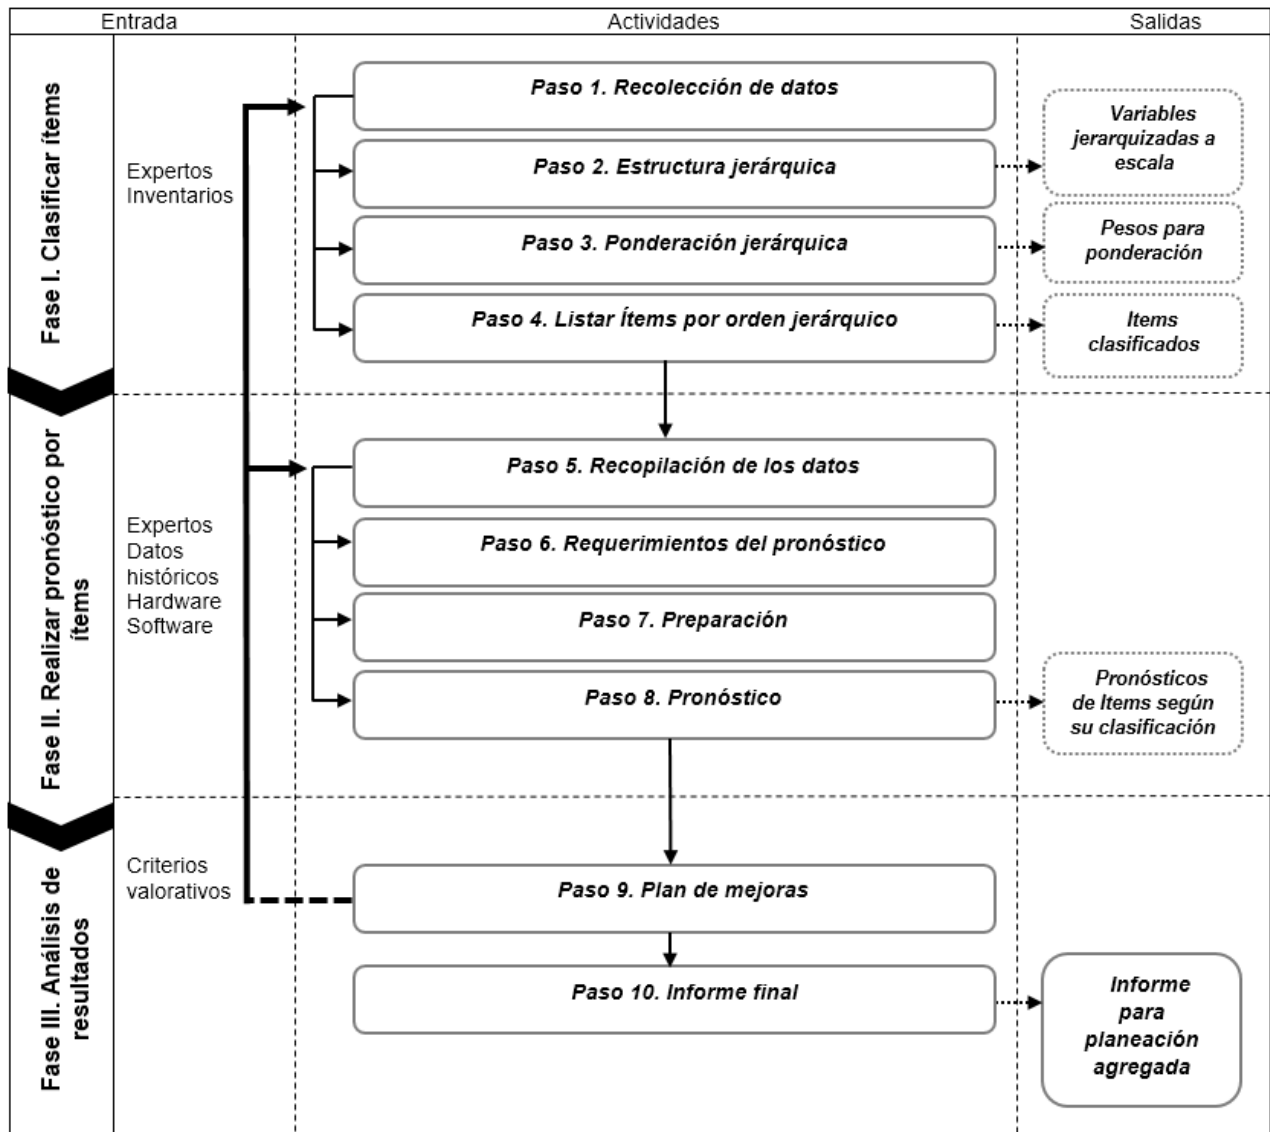
En tal sentido muchos son los estudios que versan sobre las distintas formas de conformar NN para realizar el pronóstico de la demanda. Medeiro, Tersvirta & Rech (2006) proponen un modelo híbrido entre un modelo autorregresivo (AR) y una red neuronal con una sola capa oculta. Tiene como principal ventaja el bajo costo computacional de su solución. Otros como Li, Luo, Zhu, Liu & Le (2008) consideran la combinación de modelos AR y una NN con regresión generalizada (GRNN). El resultado indica que es un método efectivo para obtener lo mejor de los dos en un solo modelo.

Para producir pronósticos más precisos con datos incompletos proponen Khashei, Reza & Bijari (2008) un modelo híbrido basado en el concepto básico de una NN con un modelo de regresión difuso. Posteriormente en 2010, dos de estos mismos autores, Khashei y Bijari presentan un nuevo híbrido basado en un modelo de NN con el uso de la metodología ARIMA (modelo autorregresivo integrado de media móvil) para obtener un pronóstico más exacto (Khashei & Bijari, 2010). Esta misma combinación de ARIMA con NN fue la solución dada por Wang, Zou, Su, li & Chaudhry (2013), en la cual se usaron tres *datasets* (conjunto de datos) con similares resultados.

Wang, Fang & Niu (2016) proponen un modelo híbrido basado en redes neuronales recurrentes de Elman (ERNN) con series de tiempo estocásticas, en el cual demostraron que las redes neuronales presentan mejor rendimiento que la regresión lineal, la distancia invariante compleja (CID), multiescala (MCID). Las redes neuronales con perceptrón multicapa fueron empleadas por Rivas (2017) con mejores resultados de error medio de estimación para el pronóstico. Esta misma tipología de NN fue empleada en Xu & Chan (2019) para el pronóstico de la demanda de materiales médicos. Por otra



parte el aprendizaje de máquina para la demanda de energía, fue empleada con el algoritmo de clasificación KNN (*K-Nearest Neighbour*), por Grimaldo & Novak (2020). En tal sentido en este artículo se propone como parte de la metodología, emplear esta técnica para realizar el pronóstico (NN-PMC) habiéndose demostrado la eficiencia de esta con anterioridad. La metodología propuesta consta de tres fases y diez pasos. Para su mejor comprensión, se graficó su lógica en la Fig. 1.



**Fig. 1.** Metodología para pronosticar la demanda considerando clasificación ABC multicriterio y redes neuronales

Fuente: Elaboración de los autores.

### Fase I. Clasificar ítems

Descripción: Se recopilan los datos de los ítems a clasificar, se determinan sus relaciones jerárquicas y sus ponderaciones incidiendo en las características de la organización y en la estrategia que persigue.

*Paso 1. Recolección de datos*

Los datos de la empresa son recopilados atendiendo a un período mínimo de un año; para la selección de las variables inicialmente se confeccionará un listado de las que se manejan en la entidad. Posteriormente se consultará a los expertos con el objetivo de que estos indiquen las variables que potencialmente se encuentren correlacionadas con los productos objeto de pronóstico y que no se contemplen en el listado previamente confeccionado.

*Paso 2. Estructura jerárquica*

Considerando como criterios para el control de inventarios las variables: demanda (en este caso estará determinada por la cantidad de movimientos de ese ítem), precio de la unidad, peso y volumen que ocupa en almacenamiento.

*Paso 3. Ponderación jerárquica*

Una vez recopilados todos los ítems y analizados mediante el Microsoft Excel, el total de los datos serán interpretados por un especialista designado por la empresa. Este analiza los pesos de los criterios y subcriterios (sobre la base de la escala de Saaty) y los compara con alternativas. Una vez realizado este proceso, se obtiene el resultado final de los pesos. Esto permite establecer el ranking de los ítems atendiendo a la clasificación ABC.

*Paso 4. Listar Ítems por orden jerárquico*

En este paso se procederá a ordenar cada ítem por categoría ABC, según el orden correspondiente a la ponderación que le corresponde.

## **Fase II. Realizar pronóstico por ítems**

Descripción: Se considerará realizar el pronóstico según el orden de prioridad definido por el ranking ABC de la Fase 1, en concordancia con el proceder de Lao, Rivas, Pérez y Marrero (2017).

*Paso 5. Recopilación de los datos*

Se recopilará la información referente a cada ítem, necesaria para aplicar el instrumento, en este caso en el período que se va a pronosticar. Con el objetivo de obtener los datos de cada producto, se creará una tabla en la que las columnas serán las variables seleccionadas y las filas, los registros históricos (instancias) en relación a las variables. La información de cada fila de la tabla podrá ser diaria, mensual, trimestral o anual. Siempre se tendrá presente que la variable dependiente deberá ir al final de la tabla, esto se debe a que el *software Weka* (propuesto para la realización del pronóstico en esta investigación) por defecto toma la última columna como la variable dependiente (variable a pronosticar).

Estas variables serán clasificadas como se muestra a continuación:

- nominal: sus valores representan categorías que no obedecen a una ordenación intrínseca;
- ordinal: sus valores representan categorías con alguna ordenación; o
- escala: sus valores representan categorías ordenadas con una métrica con significado.

#### *Paso 6. Requerimientos del pronóstico*

Primeramente se definirán los requerimientos mínimos para prueba y funcionamiento, teniendo en cuenta el hardware (ordenador de 2 GB de memoria RAM, 3,7 GHz de procesador y 100 GB de disco duro), *software Weka* y sistema operativo Linux. Se seleccionarán las variables a emplear en el pronóstico de la demanda del (los) bien(es); para ello se deberán estudiar las variables que estén correlacionadas con esta.

#### *Paso 7. Preparación*

La información que se maneja en las tablas creadas se convertirá al formato de la herramienta de minería de datos *Weka*. Con este fin se podrá utilizar el *software Excel-ArffConverter* o realizar el proceso de forma manual. La extensión de este formato será \*.arff.

#### *Paso 8. Pronóstico*

Para la representación de los resultados del pronóstico con el empleo de *Weka* se seguirán los pasos siguientes:

1. Abrir el explorador de *Weka*.
2. Seleccionar el conjunto de datos a trabajar: *Open file*.

3. Ir a la pestaña *classify*, luego en el botón *choose* seleccionar el algoritmo de regresión *Multilayer Perceptron*.
4. Clic en el botón *Start* para comenzar a construir el modelo y evaluarlo.

### **Fase III. Análisis de resultados**

Descripción: Se muestran los resultados de los pronósticos de cada ítem y la posibilidad de mejora de la metodología.

#### *Paso 9. Plan de mejoras*

En este paso se propondrán un conjunto de medidas correctoras en función del desempeño de la aplicación de la metodología, con el objetivo de reorientar y reajustar acciones que en su implementación demuestren capacidad de mejora. Para esto se aplica a los actores de la metodología un instrumento capaz de recopilar información que permita identificar los problemas sobre los cuales se va a actuar y definir actividades para la mejora del procedimiento. A cada medida se le asignarán: responsables, recursos y fechas de control y cumplimiento.

#### *Paso 10. Informe final*

Se muestra en una tabla el listado de ítems de la organización comercializadora ordenados por la relevancia determinada en la Fase 1, con el pronóstico individual correspondiente al periodo analizado resultante de la Fase 2.

## **Resultados**

Como resultado de la aplicación de esta metodología en la empresa ACINOX UEB Holguín comercializadora, se constituyó la siguiente escala jerárquica de variables para la clasificación de ítems del inventario.

Nivel 1: Escala de demanda por movimientos del ítem

- Clase 1: ítems con 25 o más movimientos.
- Clase 2: ítems en el rango de 15 hasta 24 datos de movimiento.
- Clase 3: ítems en el rango de 5 hasta 14 datos de movimiento.
- Clase 4: ítems en el rango de 1 hasta 4 datos de movimiento.

- Clase 5: ítems que no han tenido movimiento en el último año.

Nivel 1: Escala de precios

- Alto: ítems con precio superior a 100 pesos.
- Medio: ítems con precio en el rango de entre los 10 pesos a 100 pesos.
- Bajo: ítems con precio inferior a 10 pesos.

Nivel 1: Escala de peso

- Alto: Ítems con peso superior a 20 kg .
- Medio: Ítems con peso en el rango de entre uno hasta 20 kg .
- Bajo: Ítems con peso inferior a 1 kg .

Nivel 1: Escala de almacenamiento

- Alto: Ítem que ocupa un volumen superior a 1 m<sup>3</sup> .
- Medio: Ítem que ocupa un volumen en el rango de entre 0,5 hasta 1 m<sup>3</sup> .
- Bajo: Ítem que ocupa un volumen inferior a 0,5 m<sup>3</sup> .

Posteriormente, como se muestra en la Tabla 2, se establecieron los pesos de cada variable.

**Tabla 2.** Escala jerárquica de criterios y subcriterios

Nivel 1	W	Nivel 2	W	I <sub>ij</sub>
Escala de demanda por movimientos del ítem	0,0781	Clase 1	0,5616	0,04386
		Clase 2	0,2521	0,01969
		Clase 3	0,1129	0,00881
		Clase 4	0,0505	0,00394
		Clase 5	0,0228	0,00178
Escala de precios	0,2413	Alto	0,7403	0,17863
		Medio	0,2037	0,04915
		Bajo	0,0560	0,01351
Escala de peso	0,0309	Alto	0,0604	0,00186
		Medio	0,2099	0,00648
		Bajo	0,7297	0,02254
Escala de almacenamiento	0,6497	Alto	0,0484	0,03144
		Medio	0,1599	0,10388
		Bajo	0,7917	0,51436

Fuente: Elaboración de los autores

CR: 0,007 157 28

$$I_{max} = 9,090\ 097\ 084\ 995\ 08 * 10^{-5}$$

$$I_{min} = 0,000\ 142\ 328\ 534\ 92 * 10^{-5}$$

A continuación, como se muestra en la Tabla 3, se establece la clasificación ABC atendiendo a una escala de intervalo.

**Tabla 3.** Escala para los intervalos de clasificación

Intervalo del ítem		Clasificación ABC basado en AHP
Min	Max	
$2,0 * 10^{-5}$	$9,0 * 10^{-5}$	A
$0,1 * 10^{-5}$	$2,0 * 10^{-5}$	B
$0,000\ 14 * 10^{-5}$	$0,1 * 10^{-5}$	C

Fuente: Elaboración de los autores

En la Tabla 4 se muestra la lista ordenada de ítems obtenidos como salida de la Fase 1.

**Tabla 4.** Clasificación de ítems

Datos ítem		Datos de clasificación en el período					ABC
Nombre del ítem	Clasificador	Cantidad de movimientos	Precio	Peso en kg	Volumen en m <sup>3</sup>	I <sub>ij</sub>	
Barra corrugada 12,7 mm	002BD0129G40M	78	498	4	0,2	$2,61 * 10^{-5}$	A
Barra corrugada 3/8	274ACCSA3/8A9FC0311	42	498	3	0,2	$2,61 * 10^{-5}$	A
Barra corrugada 5/8	004PLT901114049M	29	498	4	0,2	$2,61 * 10^{-5}$	A
Andamio para la construcción	400590	2	293	25	3	$0,00188 * 10^{-5}$	C
Barrenas p/madera 6 mm x 152 mm	C06-10040001	18	1	0,05	0,01	$0,0256 * 10^{-5}$	C
Cubos de impacto estándar 1/2 9 mm	C06-A4558F	10	2	0,1	0,02	$0,138 * 10^{-5}$	B
Torcho de bronce fosfórico 80 mm	2215TOR0BRO-40	4	315	1	0,2	$0,37 * 10^{-5}$	B
Cuchillo de mesa modelo 9400	TN0510-1-9400-007A	7	0,60	0,4	0,1	$0,0619 * 10^{-5}$	C

Tubo led 120/18ws	C98-189350421011191	88	5,50	0,03	0,1	0,687* 10 <sup>-5</sup>	B
Llana de acero 30 cm	C09-65950	3	5,34	0,5	0,2	0,0619*10 <sup>-5</sup>	C
Manguera 1/2 x100 m	C48-20-0-8014	1	4,10 <sup>1</sup>	40	0,3	0,0023*10 <sup>-5</sup>	C

<sup>1</sup>En el caso de la manguera el precio es por metro de unidad, en todos los demás productos es por unidad comercial.

Fuente: Elaboración de los autores

Como parte del paso 9 de la metodología se procedió a aplicar una entrevista al personal de la empresa que interactuó en su aplicación, los cuales mostraron conformidad con su diseño y aplicación.

Luego de tener la clasificación del inventario se procedió a la Fase 2 donde se recopilaron estos datos, se construyó una NN-PMC y de sus resultados se obtuvieron los pronósticos mostrados en la Tabla 5, con el orden jerárquico ya determinado en la fase anterior.

**Tabla 5.** Pronóstico de los ítems clasificados

Datos ítem	Datos de clasificación en el período	Pronóstico primer trimestre 2020 en unidades				
		ene	feb	mar		
Nombre del ítem	Clasificador	$I_{ij}$	ABC	ene	feb	mar
Barra corrugada 12,7 mm	002BD0129G40M	$2,61 * 10^{-5}$	A	75	60	74
Barra corrugada 3/8	274ACCSA3/8A9FC0311	$2,61 * 10^{-5}$	A	54	62	15
Barra corrugada 5/8	004PLT901114049M	$2,61 * 10^{-5}$	A	23	18	42
Cubos de impacto estándar 1/2 9 mm	C06-A4558F	$0,138 * 10^{-5}$	B	5	3	9
Torcho de bronce fosfórico 80 mm	2215TOR0BRO-40	$0,37 * 10^{-5}$	B	0	2	0
Tubo led 120/18ws	C98-189350421011191	$0,687 * 10^{-5}$	B	24	13	26
Andamio para la construcción	400590	$0,00188 * 10^{-5}$	C	0	0	1
Barrenas p/madera 6 x 152 mm	C06-10040001	$0,0256 * 10^{-5}$	C	1	7	4
Cuchillo de mesa modelo 9400	TN0510-1-9400-007A	$0,0619 * 10^{-5}$	C	1	2	0
Llana de acero 30 cm	C09-65950	$0,0619 * 10^{-5}$	C	0	0	1
Manguera 1/2 x100 m	C48-20-0-8014	$0,0023 * 10^{-5}$	C	0	0	0

Fuente: Elaboración de los autores

## CONCLUSIONES

El presente trabajo brinda un instrumento metodológico que sustenta una manera efectiva de pronosticar la demanda con una clasificación de ítems del inventario. De este se puede afirmar que:

La clasificación multicriterio de ítems de inventario constituye no solo un mecanismo para el control de inventarios, sino un instrumento capaz de establecer un orden de prioridades sobre las características propias de la empresa y su propósito estratégico.

El pronóstico de la demanda constituye un proceso indispensable para la planeación agregada, por lo tanto, no solo ha de hacerse con el simple fin de pronosticar futuras ventas, sino que es factible y necesaria su integración con mecanismos de clasificación de inventarios en aras de brindar un agregado crucial a la toma de decisiones.

Se comprobó la validez y factibilidad de la herramienta metodológica a través de su aplicación en la empresa comercializadora seleccionada como caso estudio: Empresa ACINOX UEB Holguín, al mostrar su efectividad para resolver problemas de clasificación de inventarios y pronóstico de demanda.

Constituyen importantes aportes en el artículo, además de la metodología en sí, la escala jerárquica de variables para la clasificación de ítems del inventario, los pesos de los criterios y subcriterios que la conforman, a la par que se proporcionó a los directivos de dicha institución, un instrumento que permite obtener el pronóstico de la demanda de los Ítems clasificados en un periodo trimestral, todos resultados derivados de su aplicación.

Dada la complejidad con que evoluciona el entorno, sería recomendable para futuras investigaciones en este campo considerar variables difusas en la determinación de los pesos en la clasificación de inventarios, lo cual favorecerá el proceso de toma de decisiones.

## REFERENCIAS



- Arango, J., Giraldo, J. y Castrillón, O. (2013). Gestión de compras e inventarios a partir de pronósticos Holt-Winters y diferenciación de nivel de servicio por clasificación ABC. *Scientia et Technica*, 18(4), 743-747. Recuperado de <http://www.revistas.utp.edu.co>
- Balaji, K. & Senthil, V. (2014). Multicriteria Inventory ABC Classification in an Automobile Rubber Components Manufacturing Industry. *Procedia CIRP*, 17, 463-468. Recuperado de <http://doi.org/10.1016/j.procir.2014.02.044>
- Ferbar, L. (2010). Joint optimisation of demand forecasting and stock control parameter. *International Journal of Production Economics*, 127(1), 173-179. Recuperado de <http://doi.org/10.1016/j.ijpe.2010.05.009>.
- Flores, B., Olson, D. & Dorai, V. (1992). Management of multicriteria inventory classification. *Mathematical Computer Modeling*, 16(12), 71-82. Recuperado de [https://www.sciencedirect.com/journal/mathematical\\_and\\_computer\\_modelling/](https://www.sciencedirect.com/journal/mathematical_and_computer_modelling/)
- Flores, B. & Whybark, D. (1989). Implementing multiple criteria ABC analysis. *Engineering costs of production economics*, 15, 191-195. Recuperado de [http://doi.org/10.1016/0167\\_188x\(89\)90124\\_9](http://doi.org/10.1016/0167_188x(89)90124_9)
- Fry, C. & Brundage, M. (2020). The M4 forecasting competition. A practitioner's view. *International Journal of Forecasting*, 36(1), 156-160. Recuperado de <http://doi.org/10.1016/j.ijforecast.2019.02.013>
- Grimaldo, A. & Novak, J. (2020). Combining Machine Learning with Visual Analytics for Explainable Forecasting of Energy Demand in Prosumer Scenarios. *Procedia Computer Science*, 175, 525-532. Recuperado de <http://doi.org/10.1016/j.procs.2020.07.074>
- Hadi, A. (2010). An improvement to multiple criteria ABC inventory classification. *European Journal of Operational Research*, 201(3), 962-965. Recuperado de <http://www.sciencedirect.com/science/article/abs/pii/S03772217090002598>
- Heizer, J., Render, B. & Munson, C. (2017). *Principles of Operations Management* (10th ed.). New York, United States of America: Pearson Educación.

- Jacobs, R. y Chase, R. (2014). *Administración de Operaciones. Producción y cadena de suministros* (13ra. ed.). Ciudad de México, México: McGraw-Hill.
- Khashei, M. & Bijari, M. (2010). An artificial neural network (p,d,q) model for time series forecasting. *Expert Syst Appl*, 37(1), 479-489. doi:10.1016/j.esena.200925f.044
- Khashei, M., Reza, S. & Bijari, M. (2008). A new hybrid artificial neural networks and fuzzy regression model for time series forecasting. *Fuzzy Set Systems*, 139(7), 769-786. doi: 101016/j.fiss.2007.10\_11
- Krajewski, L., Malhotra, M. & Ritzman, L. (2018). *Operations Management Processes and Supply Chains* (12th. ed). Recuperado de <http://www.iberlibro.com>
- Lao, Y. O., Rivas, A., Pérez, M. y Marrero, F. (2017). Procedimiento para el pronóstico de la demanda mediante redes neuronales artificiales. *Ciencias Holguín*, 23(1), 1-17. Recuperado <http://www.ciencias.holguin.cu/index.php/cienciasholguin/article/view/995/109>
- Li, W., Luo, Y., Zhu, Q., Liu, J. & Le, J. (2008). Applications of AR-GRNN model for financial time series forecasting. *Neural Computing Applications*, 17(56), 441-448. doi: 10.1007/500521\_17007\_0131\_9
- Little, J. & Coughlan, B. (2008). Optimal inventory policy within hospital space constraints. *Health Care Management Science*, 11(2), 177-183. doi: 10.1007/510729\_00890666\_7
- Makridakis, S., Spiliotis, E. & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*, 19(3), 1-26. Recuperado de <http://doi.org/10.1371/journal.pone.0194889>
- Medeiro, M., Tersvirta, T. & Rech, G. (2006). Building neural network models for time series: a statistical approach. *International Journal of Forecasting*, 25(1), 49-75.
- Partovi, F. & Anandarajan, M. (2002). Classifying inventory using an artificial neural network approach. *Computers & Industrial Engineering*, 41(4), 389-404. doi: 10.1016/50360\_8352(01)00064\_x

- Rezaei, J. & Dowlatshahi, S. (2010). A rule - based multiple criteria approach to inventory classification. *International Journal of Production Research*, 48(23), 7107-7126. doi: 10.1080/00207540903348361
- Rivas, A. (2017). *Procedimiento para el pronóstico de productos farmacéuticos mediante modelos de regresión* (Tesis de maestría). Universidad de Holguín, Holguín, Cuba.
- Saaty, T. (1980). *The analytic hierarchy process*. New York, USA: Mcgrave-Hill.
- Snyder, R., Koehler, A. & Ord, J. (2002). Forecasting for inventory control with exponential smoothing. *International Journal of Forecasting*, 18(1), 5-18. doi: 10.1016/50169\_2070(01)109\_1
- Stevenson, W. J. (2018). *Operations Management* (13th ed.). Recuperado de [https://www.mheducation.com/highered/product/operations\\_manegement\\_stevenson/](https://www.mheducation.com/highered/product/operations_manegement_stevenson/)
- Teunter, R., Syntetos, A., Babai, M. & Stephenson, D. (2011). Intermittent demand: Linking forecasting to inventory obsolescence. *European Journal of Operational Research*, 214, 606-615.
- Wang, J., Fang, W. & Niu, H. (2016). Financial time series prediction using Elman recurrent random neural networks. *Computational Intelligence and Neuroscience*, 30, 44-59. doi: 10.1155/2016/4742515
- Wang, L., Zou, H., Su, J., li, L. & Chaudhry, S. (2013). An ARIMA-ANN hybrid model for time series forecasting. *Systems Research and Behavioral Science*. 30(3), 244-259. DOI: 10.1002/sres.2179. Recuperado de [https://www.researchgate.net/publication/263454208\\_An\\_ARIMA-ANN\\_hybrid\\_model\\_for\\_time\\_series\\_forecasting/citation/download](https://www.researchgate.net/publication/263454208_An_ARIMA-ANN_hybrid_model_for_time_series_forecasting/citation/download)
- Xu, S. & Chan, H. K. (2019). Forecasting Medical Device Demand with Online Search Queries: A Big Data and Machine Learning Approach. *Procedia Computer Science*, 39, 32-39. Recuperado de <http://doi.org/10.1016/j.promfg.2020.01.225>

Zowid, F., Babai, M., Douissa, M. & Ducq, Y. (2019). Multi-criteria inventory ABC classification using Gaussian Mixture Model. *International Federation of Automatic Control (IFAC)*, 52(13), 1925–1930. Recuperado de <http://doi.org/10.1016/j.ifacol.2019.11.484>

### **Declaración de conflicto de interés y conflictos éticos**

Los autores declaramos que el presente manuscrito es original y no ha sido enviado a otra revista. Los autores somos responsables del contenido recogido en el artículo, y en él no existen: ni plagios, ni conflictos de interés, ni éticos.

### **Declaración de contribuciones de los autores**

Carlos Jesús Madariaga Fernández. Gestión de la información para favorecer la actualización del artículo. Concepción preliminar (idea generadora) y diseño del artículo. Fundamentos teóricos, proyecto y desarrollo de la metodología, generación de fórmulas e índices gráficos. Análisis de los resultados. Elaboración de conclusiones.

Yosvani Orlando Lao León. Revisión teórica general del artículo. Perfeccionamiento del resumen y conclusiones. Profundización de los resultados y sus inferencias lógicas. Revisión de las referencias bibliográficas.

Dagnier Antonio Curra Sosa. Revisión de fórmulas e índices, procesamiento de datos, redacción de las metainferencias.

Rafael Lorenzo Martín. Revisión técnica y uso de términos (tesauro especializado) del artículo. Coherencia y lógica investigativa, redacción y revisión de la estructura y relaciones del artículo. Gestión del colchón editorial a publicar.