

## INFLUENCIA DE LOS MÉTODOS DE PREVISIÓN EN LA GESTIÓN DE INVENTARIOS

### Resumen / Abstract

Se comparan los costes de la gestión de stocks en un almacén, en función de la exactitud de previsión de la demanda. Para la comparación, se han empleado tres técnicas de previsión: una sencilla (la mejor entre alisado exponencial y medias móviles) y dos avanzadas (Box-Jenkins y redes neuronales artificiales). La demanda se ha obtenido utilizando doce series temporales, con distintas características entre sí en lo referente a estacionariedad y estacionalidad. Los datos de cada una de estas doce series temporales se dividen en dos grupos: el primero sirve para la obtención del modelo de previsión correspondiente, y el segundo, para comparar los datos reales con las previsiones. Ya que se dispone de las series reales, se hace una gestión determinística de stocks con demanda variable para las previsiones obtenidas con cada método. Para el cálculo de los tamaños de lote a lo largo del período de gestión, se utiliza el algoritmo de Wagner-Whitin, que proporciona la solución exacta. Los tamaños de lote, así como los períodos de pedido, serán diferentes para cada método de previsión.

*In this job, stocks management costs in a warehouse are compared. This comparison is made in terms of the accuracy of the forecasts obtained with three different techniques: Box-Jenkins, neural networks and the best between moving averages and exponential smoothing. Twelve time series were used to obtain the demand. Among these time series, some of them are stationary and others are non stationary, some are seasonal and others are non seasonal. The observations of each time series are divided in two sets: the first set is used to obtain the model, and the second set is used to compare the actual observations with the forecasts obtained with each technique. These forecasts are used to carry out a deterministic demand study. With the Wagner and Whitin algorithm, lot sizes and order moments are calculated. These results will be different for each forecast method.*

### Palabras clave / Key words

Previsión, series temporales, Box-Jenkins, redes neuronales

*Forecasting, time series, Box-Jenkins, neural networks*

**José Parreño Fernández**, Ingeniero Industrial, Universidad de Oviedo, España

e-mail: parreno@etsiig.uniovi.es

**David de la Fuente García**, Doctor Ingeniero Industrial, Universidad de Oviedo, España

e-mail: david@etsiig.uniovi.es

**Raúl Pino Díez**, Doctor Ingeniero Industrial, Universidad de Oviedo, España

e-mail: david@etsiig.uniovi.es

## INTRODUCCIÓN

Existe una gran controversia sobre si las herramientas más sofisticadas y complejas de previsión como Box-Jenkins (BJ) y redes neuronales (NN), ofrecen en la práctica unos mejores resultados en sus previsiones que las técnicas más elementales y sencillas, como las medias móviles (MM) o el alisado exponencial (AE).<sup>1,3</sup>

En este artículo se comparan todas estas técnicas, tratando de llegar a una conclusión sobre si las primeras ayudan a reducir de forma significativa los costes resultantes de la gestión de stocks en un almacén, justificando así su mayor complejidad de aplicación. Para llevar a cabo el estudio se han utilizado doce series temporales que simulan la demanda de un almacén y para las que se harán previsiones con todas las herramientas anteriormente indicadas.

## PLANTEAMIENTO DEL PROBLEMA

Para tratar de llegar a unas conclusiones fiables, se realiza el estudio con doce series temporales que representen la demanda. Estas series, en general, tienen características muy distintas entre sí, ya que se han incorporado series tanto estacionales como no estacionales, cada una de las cuales puede ser, a su vez, estacionaria o no estacionaria. Concretamente las doce series, con sus características y su procedencia se muestran en la tabla 1. En las figuras 1 - 12 se muestran los gráficos temporales de todas estas series.

Cada una de estas series, en lo que a sus datos se refiere, se divide en dos partes: un primer conjunto de datos que se utiliza para obtener el modelo de previsión, y un segundo conjunto (de menor tamaño) que sirve para comparar los datos reales con las previsiones obtenidas con cada uno de los tres métodos de previsión utilizados. Además, los valores de todas las series y de las previsiones se normalizan entre los valores 1,200 y 1,500 para que los resultados de los doce casos sean comparables entre sí.

Para calcular previsiones para cada serie, se utilizan tres métodos de previsión:

1. BJ
2. NN
3. El mejor entre MM y AE

Los modelos y las previsiones BJ se ha obtenido con la ayuda del programa SCA (Scientific Computing Associates), las previsiones NN con el SNNS (Stuttgart Neural Network Simulator), y las de MM y AE con el programa HOM.


Para hacer la gestión de stocks de este almacén se utiliza el algoritmo de Wagner y Whitin de demanda variable, ya que se conoce la demanda (series temporales anteriores) y esta es variable de unos períodos a otros. Para obtener los tamaños de lote a partir de este algoritmo se utiliza el programa WINQSB (Quantitative System Bussines for Windows).

Al aplicar cada una de las distintas técnicas, se obtienen diferentes previsiones, por lo que los resultados de aplicar Wagner y Whitin a estas previsiones de la demanda, serán diferentes para cada método de previsión.


Los errores de cada una de las técnicas de previsión dan como resultado un exceso o un defecto (rotura) de stocks al final de cada período, ya que si la previsión fuese exacta el stock final en cada período debería ser igual a cero. Se supone que la rotura de stocks es algo no deseable en el almacén, por lo que se utiliza como stock de seguridad, para cada método de previsión y para cada serie, una cantidad igual al valor máximo de la rotura en los períodos de gestión correspondientes a dicha serie.

Para poder cuantificar los costes en que se incurre con cada uno de los métodos de previsión, se suponen unos costes de lanzamiento de pedido ( $C_c$ ) de 10, 000 unidades monetarias (um). y unos costes unitarios de posesión por período ( $C_p$ ) de 3,75 unidades monetarias. Los resultados de los tres métodos de previsión se comparan sobre la base de los costes totales (posesión + lanzamiento).


<b>TABLA 1</b>				
<b>Características de las series temporales utilizadas</b>				
Nombre de la serie	Fuente	No. de datos	Estacionalidad	Estacionariedad
BJ02	Box y Jenkins (1976) <sup>5</sup>	369=360+9	NO	NO
PR	Pindick (1980) <sup>6</sup>	75=70+5	NO	NO
AL03	Abraham (1983) <sup>7</sup>	106=95+11	SÍ	SÍ
AL04	Abraham (1983) <sup>7</sup>	108=95+13	SÍ	SI
AL09	Abraham(1983) <sup>7</sup>	159=150+9	NO	NO
AL11	Abraham (1983) <sup>7</sup>	106=95+11	SÍ	SÍ
AL12	Abraham (1983) <sup>7</sup>	192=180+12	SÍ	NO
UN14	Reilly (1980) <sup>8</sup>	147=137+10	NO	NO
UN16	Reilly (1980) <sup>8</sup>	155=145+10	NO	NO
UN17	Reilly (1980) <sup>8</sup>	178=168+10	NO	NO
UN19	Reilly (1980) <sup>8</sup>	148=138+10	NO	NO
UN21	Reilly (1980) <sup>8</sup>	146=136+10	NO	NO




**Fig. 1** Serie BJ02.




**Fig. 2** Serie PR.




**Fig.3** Serie AL03.




**Fig.4** Serie AL04.




**Fig.5** Serie AL09.






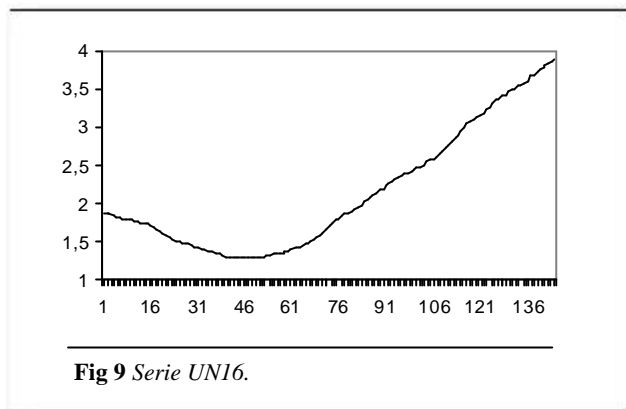
**Fig 6** Serie AL11.



**Fig.7** Serie AL12.



**Fig. 8** Serie UN14.



## METODOLOGÍAS DE BOX-JENKINS Y REDES NEURONALES ARTIFICIALES

En este apartado se van a comentar brevemente las metodologías de Box-Jenkins y de redes neuronales para previsión. Los métodos de las medias móviles y del alisado exponencial se suponen conocidos, dada su popularidad y sencillez.

### Box-Jenkins

La metodología de Box-Jenkins de previsión (1970) consiste en encontrar un modelo matemático que represente el comportamiento de una serie temporal de datos, de modo que para hacer previsiones no haya más que introducir en dicho modelo el período de tiempo para el cual se quiere hacer la previsión. Como ya se indicó anteriormente, los modelos que se utilizan en este trabajo son los modelos ARIMA univariantes, en los cuales se explica el comportamiento de una serie temporal a partir de las observaciones pasadas de la propia serie y a partir de los errores pasados de previsión (o diferencias entre valores reales del pasado y las correspondientes previsiones utilizando el modelo). Un modelo ARIMA tiene la siguiente estructura general.<sup>9</sup>

$$f_p(B)(1-B)^d x_t = k + q_q(B)a_t$$

donde:

$x_t$ : Observación en el período  $t$  de la serie objeto de estudio.  
 $f_p(B)$  y  $q_q(B)$ : Dos polinomios de órdenes  $p$  y  $q$ , en el operador de retardos  $B$  ( $Bx_t = x_{t-1}$ ),

$d$ : Orden de las diferencias de primer orden que hay que tomar para hacer que la serie sea estacionaria en media.

$a_t$ : Serie de ruido blanco.

Hay que destacar que los modelos ARIMA fueron introducidos por Wold,<sup>10</sup> combinando los modelos autorregresivos (AR) que ya había introducido con anterioridad Yule<sup>11</sup> y los modelos de medias móviles (MA), presentados por Slutsky.<sup>12</sup>

Una ventaja de los modelos de Box-Jenkins de previsión es que una vez adquirida experiencia en su metodología resulta más o menos rápido el mecanismo de búsqueda de los modelos, gracias al uso del ordenador. Además, una vez encontrado el modelo resulta inmediato hacer previsiones y comparaciones entre datos reales y previsiones para observaciones pertenecientes al pasado, de modo que resulta fácil ver gráficamente la bondad del modelo elegido.

Otra característica de estos modelos es que se obtienen mejores previsiones a corto plazo que a largo, debido fundamentalmente a la propia estructura de los modelos ARIMA. De todos modos, esta conclusión es una generalización ya que cada serie tiene sus propias particularidades.

Hay que tener en cuenta que, para modelar una serie temporal con la metodología de Box-Jenkins, es necesario el empleo de alguna aplicación informática que facilite la tarea, ya que debido a la complejidad y gran cantidad de operaciones resulta imposible de llevar a cabo sin la ayuda de un ordenador. Uno de los paquetes más reconocidos internacionalmente es el SCA (Scientific Computing Associates), de origen norteamericano, y del que el mismo Box es asesor.

Para la realización de este trabajo se utilizó este paquete.

La metodología Box-Jenkins divide en cuatro etapas el proceso de modelización<sup>13</sup> 1. Identificación; 2. Estimación; 3. Validación y 4. Previsión. A continuación se explicarán brevemente cada una de estas cuatro etapas desde un punto de vista práctico, sin entrar en demasiadas explicaciones teóricas que están fuera del alcance de este trabajo.

**Identificación**

En esta etapa se identifica el orden  $d$  de la diferenciación, en caso de que esta sea necesaria, y los órdenes  $p$  y  $q$  de los polinomios autorregresivo  $f_p(B)$  y de medias móviles  $q_q(B)$  del modelo ARIMA. Para llevar a cabo esta tarea se suelen utilizar varias herramientas como ayuda, entre las que destacan el gráfico temporal de la serie, y las funciones de autocorrelación (ACF), autocorrelación parcial (PACF), y autocorrelación extendida (EACF).

**Estimación**

En esta etapa se calculan los valores de los parámetros del modelo ARIMA identificado. En general se calcularán los valores de  $k, f_1, \dots, f_p, q_1, \dots, q_q$ . Para el cálculo de estos valores se hace indispensable la ayuda del ordenador, debido a la complejidad de los cálculos necesarios. Hay que indicar que es importante estimar todos los modelos alternativos obtenidos en la etapa de identificación.

**Validación**

Una vez estimados los modelos ARIMA identificados en la primera fase, se pasa a realizar un diagnóstico sobre su validez, desde el punto de vista teórico. Existen multitud de tests de diagnóstico, aunque para la elaboración de este trabajo se han utilizado los más reconocidos universalmente, que se indican a continuación. En primer lugar, hay que comprobar que todos los parámetros estimados sean estadísticamente significativos. A continuación, se pasa a comprobar que la serie temporal formada por los residuos del modelo, es decir, las diferencias entre los valores reales pasados de la serie y los valores obtenidos por el modelo, es un ruido blanco, para lo cual se analiza su ACF. Es posible que varios de los modelos alternativos estimados pasen los tests de diagnóstico, lo que quiere decir que todos ellos son válidos para realizar previsiones. Sin embargo, lo más lógico es quedarse en este momento nada más que con uno de ellos; para esto se comparan los errores estándar de los residuos (RSE) de todos, quedándose con el que presente el menor.

**Previsión**

En esta última fase, se realizan previsiones con el modelo seleccionado al final de la etapa anterior. Para ello, vuelve a ser necesario el uso del ordenador.

**Redes neuronales**

Las redes neuronales (o redes de neuronas artificiales), son modelos matemáticos simplificados de las redes de neuronas que constituyen el cerebro humano. Estos modelos están compuestos por un conjunto de "neuronas artificiales" o conjunto de unidades que procesan e intercambian información. Las neuronas de una red, están estructuradas en distintas capas, de forma que una neurona de una capa está conectada con las de la capa siguiente, a las que puede enviar información.

Tal como se refleja en la figura 13, la arquitectura más habitual consiste en una capa de neuronas de entrada que recibe la información **del exterior**, una serie de capas intermedias **uocultas** y una capa de salidas, que proporciona **al exterior** el resultado del trabajo de la red.

Cada neurona, tal como se muestra en la figura 14a), constituye una **unidad de procesamiento** de información, convierte un conjunto de señales de entrada en una salida que es difundida a las neuronas de la capa siguiente. Esta conversión se realiza en dos etapas: primero, cada una de las señales de entrada es multiplicada por un coeficiente de ponderación **peso sináptico** atribuido a la conexión; todos los productos son sumados para obtener una cantidad denominada **entrada ponderada total**. En una segunda fase, cada unidad utiliza una función de transferencia entrada-salida, o función de activación, que transforma la entrada ponderada total en una señal de salida que es la que se difunde a las neuronas de la capa siguiente. La función de transferencia (figura 14 b.) puede ser de tres tipos.<sup>14</sup>

1. **Lineal**. La actividad de salida es proporcional a la entrada ponderada total.

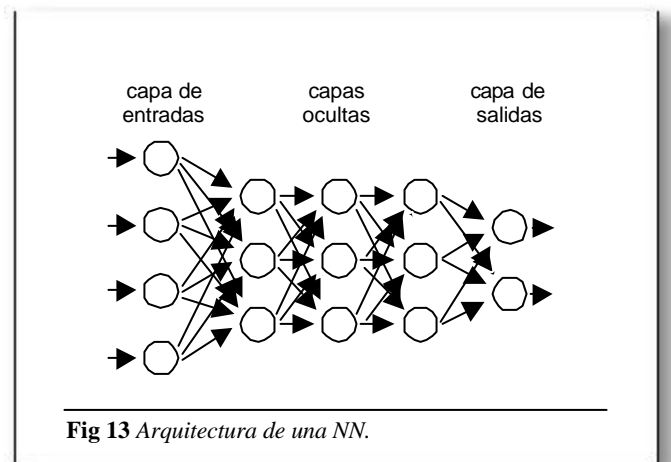
2. **De umbral**. La salida queda fija a uno de dos niveles dependiendo si la entrada ponderada total es mayor o menor que cierto valor crítico denominado **umbral**.

3. **Sigmoide**. La salida varía de forma continua dependiendo de la entrada ponderada total, pero esta dependencia no es lineal.

Habitualmente, se suele utilizar la sigmoide como función de transferencia cuando se trata de aplicar la tecnología de redes neuronales al procesado de señales no lineales,<sup>15</sup> aunque es necesario tener presente que las tres son aproximaciones bastante burdas de la actividad de las neuronas reales.

El proceso de aplicación de la tecnología de redes neuronales artificiales a un problema concreto, consta de tres etapas fundamentales:

1. **Diseño de la red**. Es necesario decidir la arquitectura que va a tener la red, lo cual implica determinar el número de neuronas de la capa de entradas, el número de capas ocultas y las neuronas que contendrá cada una de ellas y, por último, el número de neuronas de la capa de salidas. La arquitectura de la red dependerá como es lógico, del problema concreto que se quiera resolver.



**Fig 13** Arquitectura de una NN.

En este caso se quiere aplicar la tecnología de redes neuronales artificiales a la previsión de series temporales, basándose en los datos históricos de la serie, por lo tanto, el número de neuronas de la capa de entrada coincidirá con el número de datos anteriores de la serie que son necesarios para calcular un valor concreto. La capa de salida estará compuesta por una sola neurona cuya salida será el valor de la previsión que se quiere calcular.

En cuanto al número de capas ocultas y las neuronas de estas capas, no existen reglas fijas que determinen los valores óptimos. Un número muy pequeño de capas ocultas puede hacer que el proceso de entrenamiento se alargue excesivamente, mientras que demasiadas capas ocultas llevan a que se produzca una memorización de los datos, en lugar de la deducción de los patrones que se derivan de los datos, con lo que se falsea la predicción.<sup>16</sup>

Por otra parte, el número de neuronas en cada capa oculta, dependerá de la complejidad del problema a estudiar, aunque algunos autores dan ciertas recomendaciones que van desde la utilización de complicadísimas fórmulas para su cálculo,<sup>17</sup> o indicar que el número de neuronas de la capa oculta debe ser como mínimo el 75 % del número de neuronas de entrada,<sup>18</sup> hasta aplicar a teoría matemática clásica de Kolmogorov para calcular el número de neuronas como  $2k+1$ , siendo  $k$  el número de neuronas de la capa de entrada.

Se ha comprobado que el número de neuronas de la capa oculta, siempre que esté entre unos valores mínimo (por ejemplo el 75% de las neuronas de entrada) y máximo (5 veces ese mismo número), solo influye en la velocidad de entrenamiento de la red, por lo que en este caso se ha partido de un valor inicial ( $2k+1$ ), que posteriormente se ha ajustado, si durante el proceso de entrenamiento de la red se comprueba que mejora los resultados.

**2. Entrenamiento de la red neuronal artificial.** El entrenamiento de una red neuronal consiste en la utilización de un algoritmo (generalmente se usa el algoritmo *Back Propagation*) para ajustar los pesos sinápticos de las conexiones entre las neuronas.

El proceso, que aparece esquematizado en la figura 15, consiste en presentar a la red inicial una batería de casos de entrenamiento, que se construyen utilizando los datos reales disponibles (el basado de la serie temporal), tal como se comenta en el apartado siguiente. Cada uno de estos casos está compuesto por una serie de valores de entrada y el valor de salida correspondiente. Se asignan los valores de entrada a las neuronas de la capa de entradas, y se obtiene al final un valor de salida de la red neuronal. Esta respuesta se compara con la deseada u objetivo, mediante una función de error que da una medida de la eficacia de la configuración actual de pesos sinápticos de la red. El objetivo del aprendizaje es minimizar esta función de error.

Una vez calculado este error, se procede a realizar la fase **hacia atrás** o **backward** variando los pesos sinápticos de los enlaces en función de la magnitud del error cometido y de una constante llamada **coeficiente, tasa o ritmo de aprendizaje** que varía entre 0 y 1. La elección de  $e$  es importante, ya que un valor bajo, da como resultado una lenta convergencia pues implicará variar los pesos muy poco, mientras que un valor excesivamente alto, puede conducir a oscilaciones en los pesos de la red, con lo que nunca se alcanzarían los pesos óptimos. Un valor usual de partida para  $e$  es 0,3 aunque puede ser ajustado ligeramente durante el proceso de aprendizaje de la red.

Después de ajustados los pesos sinápticos, se vuelven a presentar los casos a la red y se vuelve a calcular el error, de acuerdo con él, se reajustan los pesos. Este proceso continuará hasta que el error obtenido esté dentro de unos límites previamente fijados como aceptables, en este momento, el entrenamiento de la red habría finalizado.

Una forma sencilla de acelerar el entrenamiento de la red, es añadir un término de momento  $m$  a la hora de ajustar los pesos, que recoja información sobre el último ajuste realizado.<sup>19</sup> Un valor habitual de partida suele ser  $m = 0,7$ ; aunque también puede ser ajustado a cualquier valor entre 0 y 1 durante el proceso de entrenamiento de la red.

**3.Utilización de la red neuronal en "modo recuerdo".** Una vez entrenada, la red neuronal está en condiciones de ser utilizada. Para ello, no hay más que presentar a la red un caso determinado (por ejemplo, los últimos datos disponibles de una serie temporal) para que, utilizando los pesos sinápticos encontrados durante el proceso de entrenamiento, calcule la salida (la previsión del dato siguiente de la serie temporal).

La mayor parte de las aplicaciones de redes neuronales, se realizaron en lenguajes de programación convencionales como FORTRAN o C. Sin embargo, de forma análoga a lo sucedido con los sistemas expertos, ante la expansión de la tecnología y las dificultades que presentan algunas de la etapas de diseño y entrenamiento de las redes, diversas instituciones y compañías, han empezado a comercializar entornos de desarrollo o *shells* que facilitan diversos tipos de arquitecturas y algoritmos de entrenamiento.

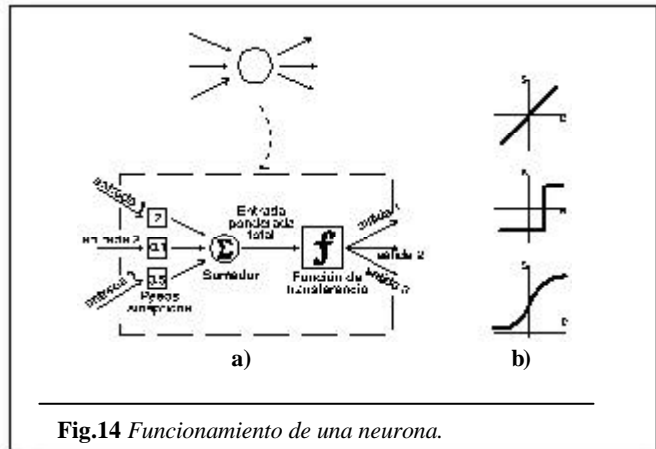


Fig.14 Funcionamiento de una neurona.

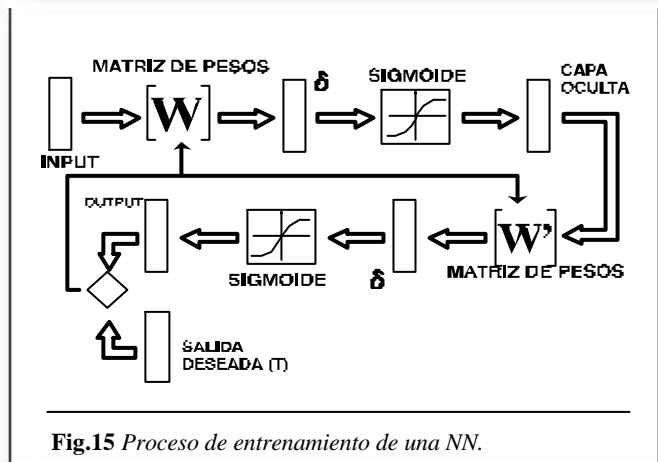


Fig.15 Proceso de entrenamiento de una NN.

Los autores han utilizado también el paquete comercial denominado NEUROSHELL en aplicaciones sobre previsión, aunque existen otros como ANSIM, BACK PROPAGATION, etc, para ordenadores personales.

### EXPOSICIÓN DE RESULTADOS

Después de realizado el estudio se debe hacer una elección, para cada serie, entre las tres técnicas de previsión empleadas. Como criterio se utilizará el hecho de tener un menor coste total de la gestión de stocks. A modo de ejemplo, se detallan a continuación los cálculos efectuados para la serie BJ02.

Esta serie consta de 369 datos, de los cuales se utilizan 360 para la construcción del modelo. Una vez obtenido el modelo, se calculan nueve previsiones que se comparan con los nueve datos restantes de la serie real. Los modelos BJ y NN encontrados para esta, y para todas las series, se muestran en las tablas 2 y 3, respectivamente.

Por otra parte, el paquete HOM indica, para esta serie, que el alisado exponencial ofrece mejores previsiones que las medias móviles.

En la tabla 4 se muestran, en la columna "serie BJ02", los valores reales de la serie para los próximos nueve períodos de gestión; en la columna **Pedido**, se presentan los pedidos que habría que hacer utilizando el algoritmo de Wagner y Whitin, pedidos que dan lugar a los inventarios finales que se muestran en la columna **Inv.final**. Los costes por período (CTi) que resultan de esta gestión de stocks se muestran en la columna **Coste** y son el resultado de la suma de los costes de posesión del inventario final de cada período (con un coste unitario de posesión por período de 3,75 u.m.) más los costes de lanzamiento, en caso de que sean necesarios (con un coste unitario de lanzamiento de 10.000 u.m.).

La fórmula utilizada para calcular los costes en cada período es la siguiente:

$$C_{Ti} = 3,75 I_{Fi} + 10,000 \text{ para los períodos con lanzamiento de pedido.}$$

$$C_{Ti} = 3,75 I_{Fi} \text{ para los períodos sin lanzamiento de pedido.}$$

En la tabla 5, se indica el resultado de la gestión considerando para los próximos 9 períodos, en lugar de la serie real, las previsiones obtenidas con NN. Los costes totales, evidentemente, serán mayores que los obtenidos en la tabla 4. Se observa que no se producen roturas de stocks empleando estas previsiones.

En la tabla 6 se muestran los resultados obtenidos con la metodología BJ, que tienen la particularidad de provocar la rotura de stocks en tres períodos (quinto, séptimo y noveno). Como se está considerando que no se admiten roturas de stocks, se penalizará esta situación obligando a mantener un stock de seguridad igual a la rotura máxima (en este caso 148 unidades en

el período 9), lo que incrementará el inventario final en cada período y, consiguientemente, los costes de posesión. A pesar de todo se ve que los costes totales resultantes son menores que en el caso de NN.

En la tabla 7 se observa el resultado de la gestión para las previsiones con alisado exponencial, para el que se obtiene un coste total mayor. En la tabla 8 se muestran los costes totales (en unidades monetarias) obtenidos con cada una de las tres técnicas de previsión para cada una de las series estudiadas. Para cada serie, se muestra en negrita el menor coste obtenido.

Como se puede ver en la tabla 8, de los doce casos estudiados solamente en dos las técnicas sencillas de previsión superan a las más sofisticadas (series AL03 y AL12), con lo que podría afirmarse que merece la pena el esfuerzo extra que supone el hecho de hacer previsiones con técnicas más avanzadas, pero también más complejas. De entre estas (NN y BJ), se hace difícil aseverar cuál es más eficiente, por lo menos en los casos estudiados en este trabajo, ya que de las diez series en que se obtienen menores costes con ellas, seis corresponden a NN y cuatro a BJ, por lo que la diferencia no se supone que sea lo suficientemente significativa como para dar una ganadora entre ellas. Además, de los dos casos en que son superadas por las técnicas sencillas, en la AL03 se obtienen menores costes con BJ, mientras que en la AL12 se obtienen con NN.

TABLA 2 Modelos ARIMA	
Serie	Modelo
BJ02	$(1-B)x = a_t$
PR	$(1-B)x = k + (1-q_1B)a_t$
AL03	$(1-f_1B)(1-f_2B^2)(1-B^2)x = (1-q_2B^2)a_t$
AL04	$(1-f_1B)(1-B^2)x = k + (1-q_2B^2)a_t$
AL09	$(1-f_1B)x = k + a_t$
AL11	$(1-f_1B)(1-B^2)x = k + (1-q_2B^2)a_t$
AL12	$(1-f_2B^2-f_3B^3)(1-B^2)x = k + (1-q_2B^2)a_t$
UN14	$(1-B)x = k + (1-q_1B)a_t$
UN16	$(1-B)^2x = (1-q_1B-q_2B^2)a_t$
UN17	$(1-f_1B-f_2B^2)(1-B)x = k + a_t$
UN19	$(1-f_1B)(1-B)x = k + a_t$
UN21	$(1-B)x = k + (1-q_1B-q_2B^2)a_t$

INFLUENCIA DE LOS MÉTODOS DE PREVISIÓN EN LA GESTIÓN DE INVENTARIOS

<b>TABLA 3 Configuración de las NN</b>		
Serie	Arquitectura	Configuración
BJ02	MLP	7-4-1
PR	MLP	5-1-1
AL03	MLP	6-3-1
AL04	MLP	12-5-1
AL09	MLP	5-3-1
AL11	ELM	6-3-1
AL12	MLP	12-4-1
UN14	ELM	5-4-1
UN16	MLP	5-2-1
UN17	MLP	6-4-1
UN19	MLP	5-2-1
UN21	MLP	5 -2-1

<b>TABLA 5 Gestión con las presiones</b>				
	Prev. NN	Pedidos NN	Inv. final	Coste NN
1	1 368	2 620	1 408	15 280
2	1 252	0	89	333,75
3	1 340	3 954	2 735	20 256,25
4	1 346	0	1 513	5 673,75
5	1 268	0	141	528,75
6	1 384	2 837	1 531	15 741,25
7	1 453	0	148	555
8	1 399	2 843	1 544	15 790
9	1 444	0	44	165
				74 323,75

<b>TABLA 4 Gestión con la serie real NN</b>				
	Serie BJ02	Pedidos	Inv. final	Coste
1	1 212	2 531	1 319	14 946,25
2	1 319	0	0	0
3	1 308	2 530	1 222	14 582,5
4	1 222	0	0	0
5	1 372	1 372	0	10 000
6	1 447	2 830	1 383	15 186,25
7	1 383	0	0	0
8	1 447	2 947	1 500	15 625
9	1 500	0	0	0
				70 340

<b>TABLA 6 Gestión con las previsiones BJ</b>					
	Prev. BJ	Pedidos BJ	Inv. final	Inv. fin. +SS	Costo BJ + SS
1	1 346	2 546	1 334	1 482	15 557,5
2	1 200	0	15	163	611,25
3	1 329	3 850	2 557	2 705	20 143,75
4	1 306	0	1 335	1 483	5 561,25
5	1 215	0	-37	111	416,25
6	1 385	2 837	1 353	1 501	15 628,75
7	1 452	0	-30	118	442,5
8	1 376	2 829	1 352	1 500	15 625
9	1 453	0	-148	0	0
			Rompe 3		73 986,25



**TABLA 7**  
**Gestión con previsiones del alisado**

	Prev. alisado	Pedidos alisado	Inv. final	Inv. final +SS	Coste ali. + NN
1	1 341	2 673	1 461	1 932	17 245
2	1 332	0	142	613	2 298,75
3	1 323	2 637	1 471	1 942	17 282,5
4	1 314	0	249	720	2 700
5	1 304	2 599	1 476	1 947	17 301,25
6	1 295	0	29	500	1 875
7	1 286	3 830	2 476	2 947	21 051,25
8	1 277	0	1 029	1 500	5 625
9	1 267	0	-471	0	0
			Rompe 1		85 378,75

**TABLA 8**  
**Resumen de costes para todas las series**

Serie	Red neuronal	Box-Jenkins	Media móvil-alisado
BJ02	74,324	<b>73,986</b>	85,379
PR	41,769	<b>40,273</b>	40,858
AL03	91,738	89,574	<b>89,525</b>
AL04	107,186	<b>102,743</b>	105,698
AL09	<b>75,414</b>	76,491	77,388
AL11	<b>84,590</b>	85,126	85,539
AL12	93,068	93,795	<b>92,700</b>
UN14	<b>78,845</b>	93,463	93,793
UN16	81,736	<b>80,559</b>	83,454
UN17	<b>89,424</b>	105,699	98,716
UN19	<b>76,899</b>	101,964	99,399
UN21	<b>76,231</b>	77,394	88,914

**CONCLUSIONES**

Se compararon los costes de la gestión de stocks en un almacén, dependiendo del grado de exactitud con que se prevea la demanda, para lo que se han utilizado tres técnicas de previsión diferentes. A partir de los resultados obtenidos, se quiere destacar la influencia que puede tener el hecho de escoger un buen método de previsión, en dichos costes de la gestión de stocks. Como se ha podido comprobar, los autores se adhieren, en este estudio de asegurar si las NN superan en este sentido a la metodología de Box-Jenkins o viceversa. Lo que sí queda probado es que ambas técnicas superan a las más sencillas medias móviles y alisado exponencial, cuyo uso solamente estaría justificado cuando resulte muy caro utilizar las otras dos metodologías. [3]

**REFERENCIAS**

1. **CHATFIELD, C.:** "What is the 'Best' Method of Forecasting?" *Journal of Applied Statistics*, No.15, pp. 19-38,1988.
2. ———: *The Analysis of Time Series*, 5th ed., Chapman and Hall London, 1996.
3. **FILDES, R.:** "The Evaluation of Extrapolative Forecasting Methods" *International Journal of Forecasting*, No.8, pp. 81-98, 1992.
4. **ATIENZA, O.O.; B.W. ANG Y L. C. TANG:** "Statistical Process Control and Forecasting", *International Journal of Quality Science* Vol. 2 No.1 pp. 37-51, 1997.
5. **BOX, G. E. P. AND G. M. JENKINS:** *Time Series Analysis. Forecasting and Control*, 2nd. ed. Holden Day, San Francisco, 1976
6. **PINDICK, R. S. AND D. L. RUBINFELD:** *Modelos econométricos McGraw-Hill*, 1980.
7. **ABRAHAM, B. AND J. LEDOITER:** *Statistical Methods for Forecasting*, Wiley, New York, 1983.
8. **REILLY, D. P.:** "Experience with an Automatic Box-Jenkins Modeling Algorithm in Time Series Analysis", *O.D. Anderson*, pp. 493-508 Amsterdam, North-Holland, 1980.
9. **PULIDO, A. Y A.M. LÓPEZ:** "Predicción y Simulación aplicada a la economía y gestión de empresas", *Pirámide*, 1999.
10. **WOLD, H.:** *A Study in the Analysis of Stationary Time Series*, Almqvist & Wiksell, Estocolmo, 1938.
11. **YULE, G. U.:** "Why do we Sometimes Get Nonsense-Correlations between Time Series? A Study in Sampling and the Nature of Time Series", *Journal of Royal Statistical Society*, No. 89, pp. 1-64,1926.
12. **SLUTSKY, E.** "The Summation of Random Causes as the Source of Cyclic Processes", *Econometrica*, No.5, pp. 105-46,1937.
13. **URIEL, E.:** *Análisis de Series Temporales. Modelos ARIMA* Paraninfo, Madrid, 1985.
14. **LIPPMANN, R. P.:** "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine*, pp. 4-22, April, 1987.
15. **LAPEDES, A. AND R. FARBER:** "NonLinear Signal Processing Using Neural Networks", *IEEE Conference on Neural Information Processing System - Natural and Synthetic*, 1987.
16. **RICHESON, L. AND R. A. ZIMMERMANN:** "Predicting Consumer Credit Performance: Can Neural Networks Outperform Traditional Statistical Methods?", *Int. Journal of Applied Expert Systems*. Vol.2, No.2, February, 1994.
17. **ZURADA, J.:** *Using Nworks: An Extended Tutorial for Neural Work: Professional II/Plus and NeuralWorks Explorer*, Pittsburg, 1991.
18. **SALCHENBERGER, L. M.; E.M. CINAR, AND N.A. LASH** "Neural Networks: a New Tool for Predicting Thrift Failures" *Decision Sciences*, July-August, 1992.
19. **CHAPMAN, A. J.:** "Stock Market Trading Systems Through Neural Networks: Developing a Model", *International. Journal of Applied Expert Systems*, Vol. 12, No. 2, 1994.