Determinación de parámetros de modelos de previsión de demanda a través de los errores de acierto en horizonte rodante

Parameterisation of demand forecasting models through out-of-sample errors on a rolling horizon

Raúl Poler, Josefa Mula y David Peidro

Centro de Investigación, Gestión e Ingeniería de Producción (CIGIP). Universidad Politécnica de Valencia.

Escuela Politécnica Superior de Alcoy. Pza. Ferrándiz y Carbonell, 2. 03801 Alcoy (Alicante).

rpoler@cigip.upv.es fmula@cigip.upv.es dapeipa@cigip.upv.es

Fecha de recepción: 06-10-08

Fecha de aceptación: 02-12-08

Resumen. La Previsión de la Demanda es un proceso crucial para cualquier empresa sea proveedor, fabricante o minorista. En la literatura existe una gran cantidad de trabajos de investigación sobre técnicas de previsión de series temporales. Sin embargo, en muchos casos, la selección del mejor modelo de previsión de series temporales para cada histórico a tratar sigue siendo un problema complejo. En este artículo se propone un nuevo procedimiento de determinación automática de parámetros de métodos de previsión de series temporales, basado en la determinación de los errores de acierto según un método de simulación de predicción ex-ante de horizonte rodante.

Palabras clave: previsión de demanda, selección de modelos.

Abstract. Demand Forecasting is an essential process for any firm whether it is a supplier, manufacturer or retailer. A large number of research works about time series forecast techniques exists in the literature. In many cases, however, selecting the best time series forecasting model for each time series to be dealt with is still a complex problem. In this paper, we propose a new automatic procedure for the parameterisation of time series forecasting methods, based on out-of-sample errors calculation through ex-ante simulation in a rolling horizon.

Key words: demand forecasting, model selection.

1. Introducción

El acierto en las previsiones de demanda es un factor crítico para que, en las empresas, los procesos de Planificación y Programación de la Producción consigan sus objetivos de reducción de costes y de un mejor servicio al cliente (Spedding y Chan, 2000). Una reducción del error cometido en los pronósticos supone minimizar el riesgo que asume la empresa para hacer frente a la demanda de sus clientes (Nikolopoulos y Assimakopoulos, 2003).

Las herramientas de software para la Previsión de la Demanda suelen ofrecer una variedad de técnicas a utilizar. No obstante, en entornos empresariales reales, en los que puede requerirse la realización de previsiones sobre miles de series temporales, es necesario proporcionar al decisor herramientas que se

encarguen de la parametrización automática de los modelos de previsión.

En la mayoría de los casos, los criterios utilizados para la parametrización automática están relacionados con los errores de los pronósticos. La medición de los errores cometidos en el pronóstico se realiza con variados objetivos: para determinar el grado de acierto de un pronóstico concreto, para analizar la evolución de la bondad del pronóstico con el tiempo, para comparar diferentes modelos de previsión frente a una serie temporal, para comparar el comportamiento de un modelo de previsión frente a varias series temporales, etc. En función del objetivo perseguido, la medición del error puede realizarse de varias formas: errores de acierto (*out-of-sample*) o de ajuste (*in-sample*), con signo o en valor absoluto, lineales o cuadráticos, con unidades o adimensiona-

les, etc. Además, dependiendo del impacto que en las decisiones empresariales tenga el error cometido en los pronósticos inmediatos, a corto, medio o largo plazo, los modelos de previsión seleccionados y su parametrización diferirán.

2. Los errores en los pronósticos

Existe una gran variedad de fórmulas para la medición de los errores en los pronósticos. Desde las fórmulas básicas hasta las que relativizan el error, bien sea tomando como referencia los valores del histórico o las previsiones obtenidas por un modelo de previsión tomado como referencia. El modelo de referencia habitualmente utilizado es el Naïve (el pronóstico es igual al último valor observado). En De Gooijer y Hyndman (2005) se relacionan las medidas de error de pronóstico comúnmente utilizadas.

La diferencia entre los errores absolutos y los cuadráticos es que estos últimos penalizan en mayor medida los errores grandes. La elección entre ambos tipos dependerá de la importancia que se le dé a los errores de pronóstico de gran magnitud. El coeficiente de desigualdad de Theil representa un compromiso entre los errores absolutos y cuadráticos (Makridakis et al., 1998).

Dependiendo del objetivo perseguido será conveniente utilizar diferentes mediciones del error de pronóstico. Por ejemplo, para comparar el comportamiento de un modelo de previsión sobre series temporales diferentes es conveniente utilizar errores adimensionales. Esto puede conseguirse, simplemente, dividiendo por el valor del histórico (MAPE). No obstante, dividir únicamente por el valor de histórico produce que el error no sea simétrico (para idénticos errores en valor absoluto, el relativo es diferente en función del signo del error). Para evitar este problema, puede utilizarse el sMAPE (MAPE simétrico). Pero hay que tener en cuenta que sMAPE tiene un comportamiento no deseado cuando el valor real o la previsión se aproximan a cero. Si se utiliza un modelo de referencia (como Naïve) para relativizar el error obtenido se obtiene, al mismo tiempo, un indicador de la bondad del modelo analizado respecto al de referencia (que suele ser el más simple).

En un sentido estricto, los errores en los pronósticos son los observados como la diferencia entre el pronóstico y el valor real cuando la previsión se ha realizado con anterioridad al conocimiento de dicho valor. Sin embargo, ciertos modelos de previsión de series temporales se basan en la determinación de

sus parámetros persiguiendo un ajuste al histórico. En este caso, se realiza un «pronóstico» de los valores reales ya conocidos. De este modo, puede distinguirse entre previsión *ex-post* (*in-sample*) cuando se trata del pronóstico de valores ya conocidos, y previsión *ex-ante* (*out-of-sample*) cuando se trata del pronóstico de valores desconocidos. Los errores así obtenidos pueden denominarse de ajuste y de acierto respectivamente.

En general, los investigadores están de acuerdo en que el acierto en los pronósticos debe ser perseguido a través de procedimientos basados en cálculos *ex-ante* (Fildes y Makridakis, 1995). La *M-Competition* (Makridakis et al., 1982) y otros estudios empíricos muestran que los errores de acierto generalmente exceden a los errores de ajuste. Además, el sobreajuste producido por ciertos métodos de previsión pueden agravar las diferencias entre los errores *in-sample* y los *out-of-sample* (Tashman, 2000).

El cálculo de los errores de los pronósticos *ex-ante* se realiza a medida que se conoce el valor real. No obstante, puede realizarse lo que algunos autores denominan simulación *ex-ante* (Coccari y Galucci, 1984). Para ello, se simula que no se conocen los últimos valores reales del histórico y se aplica el modelo de previsión calculando el error de acierto obtenido. Makridakis (1990) utilizó la simulación *ex-ante* con un horizonte rodante como método para la selección de modelos y estimación de parámetros. Makridakis aplicó este procedimiento sobre series temporales de la *M-Competition* (Makridakis et al., 1982) y demostró que la precisión en los pronósticos mejoraba cuando los parámetros del método de previsión se definían minimizando los errores de acierto en lugar de los errores de ajuste. Fildes (1989) también utilizó un procedimiento de horizonte rodante para comparar la eficacia de varias reglas de selección de modelos. Weiss y Anderson (1984) propusieron un procedimiento para la calibración de modelos de previsión basado en la minimización de los errores de acierto acumulados.

3. Criterios para la selección de modelos de pronósticos

Las primeras propuestas para la selección de modelos de previsión y su parametrización datan de la década de los 60 y se focalizaban en la bondad del ajuste del modelo a los valores ya observados. Sin embargo, este enfoque de selección prioriza los modelos con más variables ya que consiguen un mejor ajuste, pero un buen pronóstico *ex-post* no garanti-

za una buena previsión de valores futuros. Miller (1990) realizó un estudio detallado de los métodos de selección de modelos propuestos hasta esa fecha.

El problema de hallar el equilibrio entre la bondad del ajuste y la complejidad del modelo se elimina si se cambia el enfoque y se opta por indicadores relacionados con los errores de los pronósticos *ex-ante*. Puede darse el caso que un modelo complejo con muy buenos ajustes produzca errores de acierto mayores que un modelo más sencillo y con un peor ajuste.

En general, los dos criterios de selección de modelos más utilizados son el de Akaike (*Akaike Information Criterion* ó AIC) (Akaike, 1973) y el de Schwarz (*Bayesian Information Criterion* ó BIC) (Schwarz, 1978). Ambos consideran la complejidad del modelo al tener en cuenta los grados de libertad (el número de parámetros estimados). El criterio de Schwarz penaliza con mayor intensidad la utilización de grados de libertad (modelos más complejos), por lo que es más consistente. Por el contrario, el criterio de Akaike es asintóticamente eficiente, mientras que el de Schwarz no lo es. La eficiencia asintótica tiene que ver con la hipótesis de que la realidad es mucho más compleja que cualquier modelo considerado, por lo que al aumentar el número de observaciones también debiera aumentarse el número de modelos en el conjunto considerado. Los criterios que sean más lentos a medida que aumente el número de modelos no serán asintóticamente eficientes.

Un método de selección alternativo es el denominado validación cruzada (Stone, 1974). Los datos se dividen en dos subconjuntos, uno de ellos se utiliza para la determinación de los parámetros del modelo y el otro para la comprobación de la bondad de la parametrización realizada.

La relación entre la bondad del modelo y ciertas características de las series temporales ha sido un tema de investigación para varios autores (Makridakis *et al.*, 1982). Las series temporales pueden ser clasificadas por subcategorías (anual, trimestral, mensual, micro, macro, industrial, demográfica, estacional, etc.), pero los patrones de las series también deben tenerse en cuenta para explicar las diferencias entre los modelos seleccionados y los desechados.

Hay dos fuentes básicas de conocimiento sobre la selección de métodos de previsión: los estudios empíricos y los expertos en pronósticos (Collopy y Armstrong, 1989). La literatura empírica proporciona numerosas pautas para la selección entre méto-

dos de pronóstico. La previsión basada en reglas (*Rule Based Forecasting* ó RBF) es un tipo de sistema experto aplicado a la extrapolación de series temporales. RBF se compone de 99 reglas y la previsión se obtiene mediante la combinación de las previsiones de cuatro métodos de extrapolación: *random walk*, regresión, lisaje exponencial con tendencia (Brown, 1959) y lisaje de Holt (Holt *et al.*, 1960) usando 18 características de las series temporales (Collopy y Armstrong, 1992) (Armstrong *et al.*, 2001).

Franses y Koehler (1998) propusieron una estrategia de selección de modelos para series temporales con una creciente variación estacional. Esta estrategia proporciona un acercamiento global sistemático sin usar las transformaciones Box-Cox para la comparación de modelos con componentes deterministas y estocásticos. Sus resultados empíricos indican, sin embargo, que los modelos seleccionados usando observaciones *in-sample* funcionan adecuadamente en los pronósticos *out-of-sample*.

También pueden aplicarse algoritmos de aprendizaje (*machine learning*) para la selección de métodos de previsión (Arinze, 1994) como un problema de la clasificación donde el mejor modelo de previsión es el atributo de la clase y los patrones de la serie temporal son los predictores. Estos algoritmos aprenden a relacionar los patrones de las series temporales con los mejores modelos. Utilizando este enfoque, Prudencio *et al.* (2004) proponen un método de clasificación dirigido relacionado con el análisis simbólico de datos.

Flores y Pearce (2000) describen un sistema experto originalmente diseñado para prever la demanda mensual de productos industriales que fue modificado para participar en la *M3-Competition*. Las reglas están implementadas en sentencias *IF-THEN*. El sistema describe y ajusta datos tempranos irrelevantes, detecta y ajusta *outliers*, verifica la existencia de tendencia, detecta la estacionalidad y selecciona el método de previsión preferido según los patrones de la serie temporal procesada. Los métodos de previsión usados fueron: el lisaje exponencial simple, el alisado de Gardner, la descomposición clásica (todos ellos con y sin estacionalidad) y las medias móviles de seis períodos.

Del análisis de las diferentes propuestas encontradas en la literatura puede concluirse que la mayoría de los criterios de selección de modelos de previsión basados en errores de acierto utilizan el error de pronóstico a «un paso», es decir, los errores obtenidos en la previsión del siguiente punto del histórico.

No obstante, dependiendo del uso que se realice en la empresa de las previsiones inmediatas, a corto, a medio y a largo plazo, es posible que sea más adecuado un modelo de previsión con, por ejemplo, un contenido error de acierto a medio plazo que otro con un muy buen acierto a «un paso», pero con peor comportamiento a medio plazo. En definitiva, la importancia del horizonte de previsión debe ser tenida en cuenta a la hora de definir un criterio de selección de modelos.

4. Criterio de selección propuesto

La elección de un criterio para la selección de modelos de previsión de series temporales dependerá del ámbito al que deba ser aplicado y a las diversas consideraciones a tener en cuenta. Las características del tipo de problema que interesa resolver son:

- El conjunto de históricos sobre los que proceder y, por tanto, para los cuales debe seleccionarse el modelo de previsión más adecuado, es muy grande (más de 10.000).
- El conjunto de modelos de previsión de series temporales considerados es amplio y contiene modelos de muy diversa índole.
- Las previsiones a obtener no son únicamente a «un paso» sino en un horizonte amplio (por ejemplo 18 períodos).
- Al decisor le interesa tener en cuenta los errores cometidos en todo el horizonte de previsión y en diferentes instantes de la realización del pronóstico. También le interesa decidir sobre el nivel de magnificación de los errores grandes.
- El método debe poder ser aplicado automáticamente sin necesidad de intervención del decisor.

Con el objetivo de facilitar el diseño del criterio de selección, se describen varias sentencias que ayudarán a la creación de su fórmula:

- El criterio de selección de modelos operará con errores de acierto, no con errores de ajuste.
- Se registrarán los errores cometidos por todos los modelos de previsión para el horizonte de previsión considerado.
- Se otorgará una importancia diferente a los errores cometidos a lo largo del horizonte de previsión.

- Se otorgará una importancia diferente a los errores que, para un mismo período, haya producido un determinado modelo de previsión aplicado en instantes de tiempo diferentes.
- A los errores se les podrá definir un grado de magnificación que dependa de la cercanía del período considerado.

El criterio de selección propuesto se basa en los errores de acierto observados en un horizonte rodante. Además, se otorga diferente importancia según el instante en el que se realizó el pronóstico. Así mismo, permite definir el nivel de magnificación del error. Se define el criterio RHE (*Rolling Horizon Error*) para la selección de modelos de previsión como:

$$RHE = \sum_t \sum_s \left| e_t^s \right|^{\pi(\alpha)} \cdot \mu(\alpha) \cdot \lambda(\beta) \quad [1]$$

$$\pi(\alpha) \geq 1 \quad [2]$$

$$\sum_{\alpha} \mu(\alpha) = 1 \quad [3]$$

$$\sum_{\beta} \lambda(\beta) = 1 \quad [4]$$

donde:

T = período actual (última observación real)

Y_t = valor real del histórico en el período

F_t^s = pronóstico en el período realizado en el período

$e_t^s = Y_t - F_t^s$ = error del pronóstico en el período realizado en el período

$\alpha = t - s$ = avance en el pronóstico

$\beta = T - s$ = antigüedad del pronóstico

$\pi(\alpha)$ = potencia del error según el avance en el pronóstico

$\mu(\alpha)$ = factor multiplicativo del error según el avance en el pronóstico

$\lambda(\beta)$ = factor multiplicativo del error según la antigüedad del pronóstico

En la Tabla I puede observarse un ejemplo numérico del cálculo de RHE para el modelo de lisaje ex-

Tabla I
Ejemplo de cálculo de RHE para el modelo de lisaje exponencia

α	0,4	s = 10		s = 11		s = 12		s = 13		s = 14		s = 15		s = 16		s = 17		s = 18		s = 19	
t	Y_t	F_t	e_t	F_t	e_t	F_t	e_t	F_t	e_t	F_t	e_t	F_t	e_t	F_t	e_t	F_t	e_t	F_t	e_t	F_t	e_t
1	91	91,0		91,0		91,0		91,0		91,0		91,0		91,0		91,0		91,0		91,0	
2	99	91,0		91,0		91,0		91,0		91,0		91,0		91,0		91,0		91,0		91,0	
3	56	94,2		94,2		94,2		94,2		94,2		94,2		94,2		94,2		94,2		94,2	
4	89	78,9		78,9		78,9		78,9		78,9		78,9		78,9		78,9		78,9		78,9	
5	49	83,0		83,0		83,0		83,0		83,0		83,0		83,0		83,0		83,0		83,0	
6	63	69,4		69,4		69,4		69,4		69,4		69,4		69,4		69,4		69,4		69,4	
7	40	66,8		66,8		66,8		66,8		66,8		66,8		66,8		66,8		66,8		66,8	
8	58	56,1		56,1		56,1		56,1		56,1		56,1		56,1		56,1		56,1		56,1	
9	87	56,9		56,9		56,9		56,9		56,9		56,9		56,9		56,9		56,9		56,9	
10	56	68,9		68,9		68,9		68,9		68,9		68,9		68,9		68,9		68,9		68,9	
11	40	63,7	23,7	63,7		63,7		63,7		63,7		63,7		63,7		63,7		63,7		63,7	
12	92	63,7	-28,3	54,2	-37,8	54,2		54,2		54,2		54,2		54,2		54,2		54,2		54,2	
13	60	63,7	3,7	54,2	-5,8	69,3	9,3	69,3		69,3		69,3		69,3		69,3		69,3		69,3	
14	42	63,7	21,7	54,2	12,2	69,3	27,3	65,6	23,6	65,6		65,6		65,6		65,6		65,6		65,6	
15	54			54,2	0,2	69,3	15,3	65,6	11,6	56,2	2,2	56,2		56,2		56,2		56,2		56,2	
16	25					69,3	44,3	65,6	40,6	56,2	31,2	55,3	30,3	55,3		55,3		55,3		55,3	
17	20							65,6	45,6	56,2	36,2	55,3	35,3	43,2	23,2	43,2		43,2		43,2	
18	14									56,2	42,2	55,3	41,3	43,2	29,2	33,9	19,9	33,9		33,9	
19	57											55,3	-1,7	43,2	-13,8	33,9	-23,1	25,9	-31,1	25,9	
20	20													43,2	23,2	33,9	13,9	25,9	5,9	38,4	18,4

	T-s	10	9	8	7	6	5	4	3	2	1	
μ	λ	0,02	0,04	0,05	0,07	0,09	0,11	0,13	0,15	0,16	0,18	
	0,4	0,17	0,55	0,2	0,69	0,08	1,32	1,18	1,16	2,03	1,34	
	0,3	0,15	0,06	0,45	0,25	0,85	1,16	1,11	1,01	0,29		
	0,2	0,01	0,09	0,17	0,59	0,66	0,9	0,35	0,4			
	0,1	0,04	0	0,24	0,33	0,38	0,02	0,3				18,5

ponencial. Las previsiones comienzan a calcularse a partir del período 11 y se prevé un horizonte de 4 períodos. Se han registrado las previsiones desde el período 11 al 20 y, alcanzado ese instante en el tiempo, se han calculado los errores cometidos. Se ha considerado una potencia del error igual a 1, un factor multiplicativo del error según el avance del pronóstico inversamente proporcional al grado de avance y un factor multiplicativo del error según la antigüedad del pronóstico inversamente proporcional a la antigüedad.

Para el ejemplo descrito, una vez conocidos los valores reales de los 9 períodos pronosticados, el valor de RHE es de 18,54 para un factor de lisaje de 0,4. Si se aplicara el criterio para la selección del factor de lisaje (el conjunto de modelos considerados sería de lisaje exponencial con diferentes factores de lisaje), el criterio seleccionaría el que arrojará un valor menor. Para este caso en concreto, el factor de lisaje que minimiza el criterio es 0,56 con un valor de 18,06.

5. Experimento computacional

Para la validación del criterio de parametrización de métodos de previsión de series temporales propuesto se decidió experimentar con un conjunto de datos sobre los que ya se hubieran calculado errores de acierto obtenidos por varios métodos de previsión. Se seleccionaron las 1.428 series temporales mensuales de la *M3-Competition* de Makridakis y Hibon (2000).

Se seleccionó un único método de previsión (medias móviles ponderadas, con cálculo de los pesos con un modelo de programación cuadrática) y se trataba de definir el número de datos a promediar más adecuado (el parámetro N). Dicho parámetro se varió entre 2 y 18, lo que significaban 17 valores diferentes.

El modelo de programación cuadrática utilizado determina los pesos de los promedios minimizando los errores de ajuste (para evitar influencias en la selec-

ción del parámetro según el criterio propuesto basado en errores de acierto). Su formulación es:

$$\text{Minimizar } z = \frac{\sum_{t=N+1}^T e_t^2}{T-N} \quad [5]$$

$$\text{Sujeto a } F_t = \sum_{n=1}^N p_n \cdot Y_{t-(N-n)+1} \quad t = N+1 \dots T \quad [6]$$

$$\sum_{n=1}^N p_n = 1 \quad [7]$$

$$e_t = Y_t - F_t \quad t = N+1 \dots T \quad [8]$$

$$F_t, p_n \geq 0 \quad t = 1 \dots T, n = 1 \dots N \quad [9]$$

La función objetivo [5] pretende minimizar el error cuadrático medio del ajuste. El conjunto de restricciones [6] se utilizan para calcular la previsión según una media móvil ponderada. La restricción [7] garantiza que la suma de los pesos es igual a 1. El conjunto de restricciones [8] determina el error de ajuste para cada período t como la diferencia entre los valores históricos y la previsión calculada. Por último, la restricción [9] asegura que los valores de las previsiones y los pesos sean positivos. Las variables relativas a los errores pueden tomar valores negativos.

La configuración del criterio adoptada para este experimento fue:

$$\alpha = 18 \quad [10]$$

$$\pi(\alpha) = 1 \quad [11]$$

$$\pi(\alpha) = \frac{(\max\{\alpha\} - \alpha + 1)}{\sum \alpha} \quad [12]$$

Tabla 2
Variables de decisión y parámetros del modelo

Índices	
T	Conjunto de períodos del horizonte de previsión ($t = 1 \dots T$)
N	Número de puntos a promediar ($n = 1 \dots N$)
Variables de decisión	Datos
F_t	Previsión en el período t
e_t	Error de ajuste en el período t
	Y_t Histórico en el período t

$$\lambda(\beta) = \frac{(\max\{\beta\} - \beta + 1)}{\sum \beta} \quad [13]$$

Es decir, un avance en el pronóstico de 18 períodos (en la *M3-Competition* se solicitaba el pronóstico de los siguientes 18 meses al último valor del histórico), una potencia del error igual a la unidad (en la *M3-Competition* una de las mediciones de error más significadas fue sMAPE), un factor multiplicativo del error según el avance en el pronóstico inversamente proporcional al grado de avance y un factor multiplicativo del error según la antigüedad del pronóstico inversamente proporcional a la antigüedad.

Se ha realizado una simulación *ex-ante* con horizonte rodante suponiendo desconocidos los 18 últimos valores de cada serie temporal e incorporando, en cada cálculo, un valor del histórico, lo que significa un total de 19 previsiones por cada serie temporal. Se aplicó el modelo de previsión descrito con 17 variaciones del parámetro N a las 1.428 series temporales de la *M3-Competition*, lo cual arroja un número de 24.276 previsiones, para cada una de las cuales se calculan 18 meses de pronóstico. Se utilizó un procedimiento estándar de detección de *outliers*. Al obtener los errores de acierto sobre los valores del histórico, supuestos desconocidos, según el procedimiento de horizonte rodante, por cada previsión se computan un total de 171 errores. En total, se obtuvieron 4.151.196 errores de acierto que fueron procesados siguiendo el criterio propuesto para la parametrización del modelo.

El resultado del experimento situó al criterio RHE entre los 3 primeros métodos de previsión de la citada competición en diferentes horizontes de previsión y sus promedios. Este resultado evidencia el interés del procesamiento de errores de acierto en horizonte rodante para la parametrización de modelos de previsión, ya que el experimento se ha realizado con un método sencillo (medias móviles) aunque dotado de una parte de optimización (de los pesos, minimizando los errores de ajuste).

En contrapartida, la cantidad de errores de acierto a calcular con el proceso de simulación con un horizonte rodante es mayor que los calculados en una validación cruzada simple. No obstante, dependerá del tamaño del horizonte considerado, del punto de inicio de la simulación y del avance establecido.

6. Conclusiones

Se ha propuesto un método de parametrización de modelos de pronósticos de series temporales basa-

do en los errores de acierto en un horizonte rodante, que permite al decisor definir la importancia otorgada a los errores según la antelación y la edad del pronóstico. Ha sido testado seleccionando el parámetro N de un modelo de medias móviles ponderadas utilizando las series mensuales de la *M3-Competition*. El método propuesto obtiene resultados similares a los alcanzados por los vencedores de la competición utilizando un método de previsión sencillo (que obvia ciertos patrones de las series temporales como la tendencia y la estacionalidad).

A partir de los experimentos realizados se han identificado varias líneas futuras de investigación:

- Realización de experimentos con diferentes potenciaciones del error; vectores de factores multiplicativos del error según el avance en el pronóstico y vectores de factores multiplicativos del error según la antigüedad.
- Análisis de experimentos con variaciones en los parámetros, determinando el impacto de cada parámetro.
- Relación de los parámetros del criterio con las caracterizaciones de los históricos a tratar.

7. Referencias

- AKAIKE, H. (1973). *Information theory and an extension of the maximum likelihood principle*. In: Petrov, B.V.N., y Csaiki, F. (eds.): *Second international symposium on information theory*, pp. 267-281. Budapest: Akademiai Kiado.
- ARINZE, B. (1994). «Selecting appropriate forecasting models using rule induction». *Omega-International Journal of Management Science*, 22 (6), pp. 647-658.
- ARMSTRONG, J.S.; ADYA, M., y COLLOPY, F. (2001). «Rule-based forecasting: using judgment in time-series extrapolation». In: J. S. Armstrong (ed.), *Principles of forecasting*. Norwell, M.A.: Kluwer Academic Press.
- BROWN, R.G. (1959). *Statistical forecasting for inventory control*. McGraw-Hill, New York.
- COCCARI, R.L., y GALUCCI, C. (1984). *Average two best forecasts can reduce forecasting risk*. *Journal Business Forecasting*, Fall.
- COLLOPY, F., y ARMSTRONG, S. (1992). «Rule-based forecasting: development and validation of an expert systems approach to combining time-series extrapolations». *Management Science*, 38 (10), pp. 1394-1414.
- DE GOOIJER, J.G., e HYNDMAN, R.J. (2005). *25 years of IIF time series forecasting: a selective review*. Tinbergen Institute Discussion Paper.
- FILDES, R. (1989). «Evaluation of aggregate versus individual forecast method selection rules». *Management Science*, 35, pp. 1056-1065.
- FILDES, R., y MAKRIDAKIS, S. (1995). «The impact of empirical accuracy studies on time series analysis and forecasting». *International Statistical Review*, 63, pp. 289-308.
- FLORES, B.E., y PEARCE, S.L. (2000). «The use of an expert system in the M3 competition». *International Journal of Forecasting*, 16, pp. 485-496.
- FRANSES, P.H., y KOEHLER, A.B. (1998). «A model selection strategy for time series with increasing seasonal variation». *International Journal of Forecasting*, 14, pp. 405-414.
- HOLT, C.C.; MODIGLIANI, F.; MUTH, J.F., y SIMON, H.A. (1960). *Planning production inventories and work force*. Prentice-Hall, Englewood Cliffs, NJ.
- MAKRIDAKIS, S. (1990). «Sliding simulation: a new approach to time series forecasting». *Management Science*, 36, pp. 505-512.
- MAKRIDAKIS, S.; ANDERSEN, A.; CARBONE, R.; FILDES, R.; HIBON, M.; LEWANDOWSKI, R.; NEWTON, J.; PARZEN, E., y WINKLER, R. (1982). «The accuracy of extrapolation (time series) methods: results of a forecasting competition». *Journal of Forecasting*, 1, pp. 111-153.
- MAKRIDAKIS, S., y HIBON, M. (2000). «The M3-Competition: results, conclusions and implications». *International Journal of Forecasting*, 16, pp. 451-476.
- MAKRIDAKIS, S.; WHEELRIGHT, S.C., e HYNDMAN (1998). *Forecasting: methods and applications*. Wiley.
- MILLER, A. (1990). *Subset selection in regression*. Chapman and Hall.
- NIKOLOPOULOS, K., y ASSIMAKOPOULOS, V. (2003). «Theta intelligent forecasting information system». *Industrial Management & Data Systems*, 103/9, pp. 711-726.
- PRUDENCIO, R.B.C.; LUDERMIR, T.B., y CARVALHO, F.A.T. (2004). «A modal symbolic classifier for selecting time series models». *Pattern Recognition Letters*, 25, pp. 911-921.
- SCHWARZ, G. (1978). «Estimating the dimension of a model». *The Annals of Statistics*, 6, pp. 461-464.
- SPEDDING, T.A., y CHAN, K.K. (2000). «Forecasting demand and inventory management using bayesian time series». *Integrated Manufacturing Systems*, 11 (5), pp. 331-339.
- STONE, M. (1974). «Cross validation choice and assessment of statistical predictions». *Journal of the Royal Statistical Society*, B36, pp. 111-147.
- TASHMAN, L.J. (2000). «Out-of-sample tests of forecasting accuracy: an analysis and review». *International Journal of Forecasting*, 16 (issue 4), pp. 437-450.
- WEISS, A. A., y ANDERSON, A.P. (1984). «Estimating time series models using relevant forecast evaluation criteria». *Journal of the Royal Statistical Society*, 147, pp. 484-487.