

PROGNOS: Un sistema de soporte al proceso de previsión de demanda

Raúl Poler Escoto¹, Josefa Mula Bru¹, David Peidro Payá¹, José V. Tomás Miquel¹

¹ Centro de Investigación Gestión e Ingeniería de Producción. Ciudad Politécnica de la Innovación. Universidad Politécnica de Valencia. Camino de Vera s/n, 46022 Valencia. rpoler@cigip.upv.es, fmula@cigip.upv.es, dapeipa@cigip.upv.es, jotomi@cigip.upv.es

Resumen

Una previsión de demanda acertada es la base de una eficiente gestión de producción y puede incidir de manera importante en la satisfacción del cliente. Sin embargo, aunque la previsión de la demanda es un tema suficientemente estudiado y aunque existen muchas herramientas de software, no se puede considerar que se trate de un área bien resuelta en la práctica empresarial. Las empresas necesitan sistemas de soporte a la previsión de demanda con ciertas características: agregación flexible de los pedidos mediante la combinación de tipos de artículos, tipos de clientes y tipos de pedidos; detección automática de anomalías; ajustes estacionales; un sistema experto para la selección del mejor modelo; automatización completa para realizar previsiones de demanda masivas; y fácil integración con el sistema de información existente. En este artículo se presenta un sistema de soporte al proceso de previsión de demanda que trata de cubrir las características citadas. Este sistema ha sido implementado en un prototipo denominado PROGNOS que está siendo utilizado en una empresa real.

Palabras clave: Previsión de demanda, series temporales, sistema experto, integración

1. Introducción

La Previsión de la Demanda es un proceso crucial para cualquier proveedor, fabricante o minorista. Prever la demanda futura es necesario debido a que los procesos operativos de una empresa (aprovisionamiento, fabricación y suministro) requieren tiempo. La mayoría de las empresas no pueden esperar a un pedido en firme para reaccionar, sino que deben anticiparse y realizar planes ante una demanda futura. A nivel organizativo, las previsiones de las demandas futuras se requieren como entradas esenciales para muchas actividades de decisión en varias áreas funcionales como marketing, ventas, producción/compras, contabilidad y finanzas (Mentzaer y Bienstock, 1998) y la gestión de inventarios (Bufa y Miller, 1979). El acierto en las previsiones de demanda es un factor crítico para la reducción de costes y para lograr un mejor servicio al cliente (Spedding y Chan, 2000), así como para la mejora de las políticas de inventarios, de la gestión de almacenes y, en definitiva, la minimización del riesgo que asume la empresa para hacer frente a la demanda de sus clientes (Nikolopoulos y Assimakopoulos, 2003)

En la empresa se realizan previsiones para utilizarlas en diferentes niveles de toma de decisión. En cada nivel se requiere de diferentes agregaciones y longitudes del horizonte de toma de decisión. Para un Plan de Capacidad a largo plazo se utiliza un horizonte de varios años y una agregación de la demanda en unidades estadísticas. Para los propósitos un Plan Maestro de Producción puede utilizarse un horizonte equivalente al tiempo de ciclo de producto y unidades de producto final. Para el Plan de Distribución, si la compañía tiene

varios almacenes en las diferentes localizaciones, la pregunta no sólo es cuánto y cuando el cliente materializará su pedido, sino también dónde. Los períodos en cada horizonte también son diferentes: desde semanales para un Plan Maestro a anuales para un Plan de Capacidad. Y dependiendo de la cantidad de previsiones a realizar, pueden usarse métodos diferentes. Por ejemplo, si la compañía necesita prever, una vez al año, la demanda de una decena de familias de productos para los próximos cinco años, puede utilizarse la estadística causal o criterios de expertos; procedimientos que requieren una intervención importante de decisores humanos. Pero si se requiere prever, cada semana, la demanda semanal de miles de productos para un horizonte de tres meses, probablemente, el único método viable es la previsión de series temporales; utilizando un proceso automático con la menor intervención humana posible.

Durante los últimos 40 años, se han publicado una gran cantidad trabajos de investigación sobre técnicas de previsión de series temporales. Una revisión de los últimos 25 años puede verse en De Gooijer y Hyndman (2005). Además existen muchas herramientas de software para la previsión de series temporales (Yurkiewicz, 2000). Podría considerarse, por lo tanto, que la previsión de demanda en el mundo empresarial es un problema resuelto. Sin embargo la experiencia nos indica lo contrario. Las dificultades de integración de dichas herramientas con el sistema de información de la empresa y, en algunos casos, la dificultad de automatizar el proceso son dos de los principales problemas encontrados.

El objetivo principal de este trabajo es describir las características de un sistema de apoyo a la toma de decisiones en relación a la previsión de series temporales, que resuelva los problemas mencionados: una definición sencilla del nivel de agregación y el horizonte y períodos de la previsión, automatización total y la interoperabilidad con el sistema de información existente.

2. De los pedidos a las series temporales

La demanda se define como la cantidad de producto que el mercado está dispuesto a adquirir. Si la empresa tiene suficiente capacidad para hacerle frente, los pedidos registrados, convertidos en ventas, igualarán a la demanda. En caso contrario la demanda puede ser superior a las ventas en determinados períodos de tiempo. Las empresas, normalmente, no registran la demanda (entendida como cualquier propuesta de pedido, aunque no acabe por materializarse) sino que lo que se almacena en el sistema de información de la empresa son las ventas realizadas. Estos datos pueden agregarse temporalmente o por otros tipos de dimensiones. La agregación temporal se realiza cuando los datos se suman según un período definido (diario, semanal, mensual, etc.). Como dimensiones no temporales pueden considerarse: el producto, el cliente y el pedido. Definiendo tipos para cada una de estas dimensiones y combinándolos pueden conseguirse diferentes agregaciones y segmentaciones.

Los productos pueden clasificarse en base a sus características. La más típica es la familia, pero pueden utilizarse otras como la clasificación comercial o la segmentación por precio. El resultado de la aplicación de una dimensión de tipo de producto es una agregación. La agregación de la demanda normalmente proporciona previsiones más acertadas debido a la eliminación de comportamientos no deseados en el histórico (intermitencia, observaciones inusuales, etc.). Además, un patrón estacional se identifica con más claridad en una serie agregada. Bunn y Vassilopoulos (1993) mostraron cómo el patrón estacional obtenido en las series agregadas puede ser utilizado como la estacionalidad de los productos individuales.

Los clientes pueden ser clasificados geográficamente, por comportamiento en sus pedidos (regularidad, cantidad, etc.) o por otras características dependiendo del caso en concreto.

Cuando se aplica una clasificación por cliente a los datos de demanda, lo que se obtiene es una segmentación por tipo de cliente. Por ejemplo, si se utiliza una clasificación geográfica, la demanda de un producto será segmentada en tantas series temporales como localizaciones geográficas se hayan considerado.

Los pedidos pueden ser clasificados, por ejemplo, por el origen de su producción (la planta que fabrica los productos que se entregarán en el pedido), por el punto de distribución (el almacén desde donde se sirve el pedido), etc.

Combinando estas tres dimensiones podemos obtener un conjunto de series temporales que describen el mismo fenómeno. Como ejemplo, consideremos 10 productos que pertenecen a la misma familia, 20 clientes clasificados geográficamente en 4 zonas y 2 almacenes de distribución desde los cuales se sirven los pedidos. La Tabla 1 muestra las combinaciones y el número de series temporales resultantes cuando se realizan agregación de producto (aP), segmentación de clientes (sC) o clasificación de pedidos (cP).

Tabla 1. Agregación, segmentación y clasificación de series temporales

aP	sC	cP	Series temporales
No	No	No	10 series temporales que corresponden a la demanda individual de los 10 productos
Sí	No	No	1 serie temporal que corresponde a la agregación de la demanda de los 10 productos en 1 familia
No	Sí	No	40 series temporales que corresponden a la segmentación de 10 productos en 4 zonas
No	No	Sí	20 series temporales que corresponden a la clasificación de 10 productos en 2 almacenes
Sí	Sí	No	4 series temporales que corresponden a la agregación de la demanda de 10 productos en 1 familia y la segmentación en 4 zonas
Sí	No	Sí	2 series temporales que corresponden a la agregación de la demanda de 10 productos en 1 familia y la clasificación en 2 almacenes
Sí	Sí	Sí	8 series temporales que corresponden a la agregación de la demanda de 10 productos en 1 familia, la segmentación en 4 zonas y la clasificación en 2 almacenes
No	Sí	Sí	80 series temporales que corresponden a la demanda de 10 productos segmentada en 4 zonas y clasificada en 2 almacenes

Dependiendo del tipo de previsión en que estemos interesados, escogeremos diferentes caminos para obtenerla. Algunos de ellos nos proporcionarán directamente la información perseguida y otros requerirán de agregaciones o desagregaciones. La Tabla 2 muestra algunos ejemplos de los post-tratamientos necesarios sobre la previsión para obtener la información deseada.

Tabla 2. Post-tratamientos para obtener la previsión requerida

aP	sC	cP	P	P-Z	P-W
No	No	No	O	dZ	dA
Sí	No	No	dP	dP-dZ	dP-dA
No	Sí	No	aZ	O	aZ-dA
No	No	Sí	aA	aA-dZ	O
Sí	Sí	No	aZ-dP	dP	dP-aZ-aA
Sí	No	Sí	aA-dP	dP-aA-dZ	dP
Sí	Sí	Sí	aZ-aA-dP	dP-aA	dP-aZ
No	Sí	Sí	aZ-aA	aA	aZ

P: producto	aZ: agregación de zonas por producto
P-Z: producto-zona	aA: agregación de almacenes por producto
P-A: producto-almacén	dP: desagregación en productos
O: previsión obtenida directamente	dZ: desagregación en zonas
	dA: desagregación en almacenes

Para seleccionar el mejor proceso para obtener la previsión requerida, debemos analizar qué tipo de series temporales serán más fácilmente previsibles y qué agregaciones y desagregaciones pueden ser realizadas sin pérdida de información. Si los procedimientos de agregación y desagregación están definidos, podemos analizar el resultado que generan todos los posibles caminos y seleccionar el más adecuado mediante un test de acierto.

El sistema de soporte diseñado permite la definición de diferentes tipos de productos, clientes y pedidos de manera sencilla y proporciona procedimientos para la selección del mejor proceso de obtención de previsiones a diferentes niveles de agregación, segmentación o clasificación.

3. Métodos de previsión de series temporales

En las últimas décadas han ido apareciendo diferentes métodos de previsión de series temporales. Entre todos ellos, la familia de los modelos de lisaje exponencial (Montgomery *et al.*, 1990) ha sido muy utilizada en la práctica y los modelos ARIMA (Autoregressive Integrated Moving Average) (Box y Jenkins, 1970) han sido ampliamente tratados en la investigación.

No obstante la amplia diversidad de modelos, la experiencia ha demostrado que no existe ningún método de previsión que funcione mejor que los demás en cualquier situación (Collopy y Armstrong, 1992). Por lo tanto, una adecuada selección del método a utilizar para cada serie temporal puede incrementar las probabilidades de acierto en la previsión.

Dependiendo de las características de una determinada serie temporal unos métodos de previsión darán mejores resultados que otros. Un adecuado sistema de soporte para la previsión de demanda debe ser capaz de proponer unos pocos métodos entre un conjunto de ellos en función de ciertas características de la serie. El conjunto de métodos a considerar debe cubrir los diferentes comportamientos (estacionalidad, tendencia, intermitencia, aleatoriedad, etc.) que puedan observarse en las series temporales que vayan a tratarse. PROGNOSES considera un total de 26 métodos de previsión diferentes, cada uno de ellos con sus pertinentes parametrizaciones:

- ❖ Métodos de descomposición
 - Descomposición clásica aditiva o multiplicativa
 - Modelo Theta (Assimakopoulos y Nikolopoulos, 2000)
- ❖ Métodos de Lisaje Exponencial
 - Lisaje simple
 - Holt (Holt *et al.* 1960)
 - Holt-Winter (aditivo o multiplicativo) (Winters, 1960)
 - Croston (Croston, 1972)
 - Syntetos-Boylan (Syntetos y Boylan, 2005)
- ❖ Métodos de Medias Móviles

- Media móvil simple
- Media móvil simple ponderada
- ❖ Métodos ARIMA (Box y Jenkins, 1970)
 - Tramo/Seats (Gomez y Maravall, 2001)

Se han implementado los métodos “clásicos” de cálculo de estos modelos y, para los métodos que requieren la estimación de uno o varios parámetros, se han implementado modelos de programación matemática (deterministas y *fuzzy*) que minimizan los errores de ajuste (*in-sample*) o de acierto (*out-of-sample*). El lenguaje de modelado utilizado ha sido MPL (Maximal Software Corporation, 2000). Y los *solvers* son CPLEX (CPLEX Optimization Inc., 1994) para modelos lineales y cuadráticos y CONOPT para los modelos no lineales. Con este conjunto de modelos, una gran variedad de series temporales con diferentes características pueden ser convenientemente tratadas.

Por otro lado, PROGNOSES utiliza un sistema automatizado de ajuste de datos, con la finalidad de eliminar anomalías en las series temporales como *outliers*, cambios en la tendencia básica o última observación inusual.

4. Un Sistema Experto para la previsión automatizada

La relación entre la bondad de un modelo de previsión y ciertas características de las series temporales ha sido tema de investigación para una variedad de autores (Makridakis *et al.*, 1982). Las series temporales pueden ser clasificadas en subcategorías (anual, cuatrimestral, mensual, micro, macro, industrial, demográfica, estacional, etc.) pero, además, han de tenerse en cuenta los patrones de las series temporales para explicar la diferencia de rendimiento entre unos modelos y otros.

Existen dos fuentes básicas de conocimiento acerca de selección de métodos de previsión; los estudios empíricos y los expertos en previsión (Collopy y Armstrong, 1989). La literatura empírica proporciona una variedad de guías para la selección de métodos de previsión. La previsión basada en reglas (*Rule-based forecasting* – RBF) es un tipo de sistema experto en el que las reglas se han extraído del conocimiento de cinco expertos en métodos de previsión. Consiste en un total de 99 reglas y la previsión se obtiene por combinación de 4 métodos de previsión: *random walk*, regresión, lisaje exponencial con tendencia (Brown, 1959) y método de Holt (Holt *et al.* 1960) teniendo en cuenta 18 características de las series temporales (Collopy y Armstrong, 1992) (Armstrong *et al.*, 2001).

Los algoritmos de aprendizaje también pueden ser aplicados a la selección de métodos de previsión (Arinze, 1994) como un problema de clasificación. Estos algoritmos aprenden a relacionar series temporales con los mejores modelos. Prudencio *et al.* (2004) propusieron un método de clasificación supervisado basado en el análisis simbólico de datos para la selección de métodos de previsión.

Flores y Pearce (2000) describen un sistema experto diseñado originariamente para prever la demanda mensual de productos industriales, que fue modificado para participar en la competición M3 (Makridakis and Hibon, 2000). Este sistema experto se basa en la implementación de reglas IF-THEN. El proceso completo es el siguiente: detección y corrección de datos tempranos irrelevantes, eliminación de *outliers*, verificación del tipo de tendencia, detección de la estacionalidad y el período, selección del método de previsión, generación de previsiones y presentación al usuario para la selección final y, en su caso,

modificación manual de algunos valores. Los métodos de previsión utilizados son: lisaje exponencial simple, lisaje exponencial con tendencia amortiguada de Gardner, descomposición clásica y media móvil de 6 períodos. Además se utiliza un promediado de los resultados para obtener la previsión definitiva.

Los investigadores generalmente están de acuerdo en que el acierto en las previsiones debe ser evaluado utilizando una parte del histórico que no se haya usado en el cálculo de la previsión (*out-of-sample*) (Fildes and Makridakis, 1995). Normalmente los errores de ajuste (*in-sample*) son menores que los errores de acierto. La Competición M (Makridakis *et al.*, 1982) y otros estudios empíricos han demostrado que los errores cometidos en la previsión normalmente exceden a los errores de ajuste. El sobre-ajuste agrava las diferencias entre los errores de ajuste y de acierto (Leonard, 2000).

Normalmente los tests de acierto utilizan un horizonte rodante. Makridakis (1990) utilizó la simulación móvil para la selección del método de previsión y la estimación de parámetros del modelo. Makridakis aplicó variaciones de la simulación móvil a algunas series de la Competición M (Makridakis *et al.*, 1982) y demostró que los errores de acierto se reducían cuando los parámetros se estimaban con el objetivo de reducir los errores de acierto en lugar de los errores de ajuste. Fildes (1989) también utilizó el método de horizonte rodante para comprobar la eficacia de varias reglas de selección de métodos. Weiss y Anderson (1984) analizaron el caso de previsiones acumuladas y propusieron la calibración del método de previsión a partir de la minimización de los errores de acierto acumulados.

PROGNOS integra un sistema experto basado en reglas para la selección de los métodos de previsión más adecuados a cada serie temporal. Se basa en la identificación de las características de las series y en los requerimientos introducidos por el usuario. Se ha establecido una base teórica basada en el conocimiento de expertos, implementada en reglas del tipo IF-THEN. El sistema experto considera los siguientes factores principales: el horizonte de previsión, los patrones de la serie (tendencia, estacionalidad, aleatoriedad e intermitencia) y los errores de ajuste o acierto (sMAPE, sMSPE)

La tendencia es un patrón importante en una serie temporal. Para determinar si una serie es estacionaria o no puede utilizarse el test de Dickey-Fuller. Una serie temporal puede ser no estacionaria debido a una tendencia determinista o estocástica o ambas.

Una serie temporal con estacionalidad presenta ciclos que se repiten dentro de un año, normalmente causados por el clima, vacaciones, etc. La estacionalidad puede identificarse mediante el cálculo de la función de autocorrelación (ACF) o la función de autocorrelación parcial (ACFP). Si una serie es clasificada como estacional sólo pueden utilizarse directamente los métodos de previsión que consideren este patrón. Para el resto de métodos se requiere una desestacionalización previa. Para el cálculo de los valores estacionales pueden utilizarse métodos de filtrado o métodos basados en regresión. Los métodos de filtrado operan eliminando el impacto de la estacionalidad alrededor de alguna clase de media móvil con tendencia. Estos incluyen Census X11 (Shiskin *et al.*, 1967), X11-ARIMA (Dagum, 1980), X12-ARIMA (Findley *et al.*, 1996) y SEATS (Maravall y Gomez, 1992).

Para evaluar la aleatoriedad y la intermitencia pueden utilizarse el coeficiente cuadrático de la variación de la demanda (CV^2) y el promedio del intervalo entre demandas (ADI) respectivamente. De acuerdo con sus valores una serie temporal puede ser clasificada en 4 categorías (Syntetos, 2001) basándose en el criterio de Williams (1984) (ver Figura 1).

PROGNOS utiliza los valores de estos coeficientes en lugar de la clasificación para tener en cuenta el grado de aleatoriedad e intermitencia.



Figura 1. Intermitencia y aleatoriedad de series temporales. Fuente: (Ghobbar and Friend, 2002)

5. La Arquitectura de PROGNOS

El sistema de información se ha diseñado para facilitar la integración con la base de datos existente en una empresa. Las clases principales son: Artículo, Cliente, Pedido, Artículo-tipo, Cliente-tipo, Pedido-tipo, Histórico y Previsión. El sistema de información diseñado como un *datawarehouse* se actualiza periódicamente obteniendo la información relevante del sistema de información transaccional de la empresa. Todos los procesos de tratamiento de la información han sido ubicados en el DBMS utilizando procedimientos almacenados de SQL.

La arquitectura diseñada es de 3 capas: la lógica de acceso a datos está localizada en el servidor de base de datos, los clientes pesados tienen la lógica de negocio y la de presentación, mientras que los clientes ligeros únicamente tienen la lógica de presentación.

Los métodos de previsión de demanda han sido implementados de un modo modular con el objetivo de utilizar la computación distribuida. Cualquier cliente puede seleccionar cualquier cliente pesado que implemente el método de previsión requerido. Esta arquitectura permite distribuir la carga de computación y conseguir cálculos masivos en menor cantidad de tiempo.

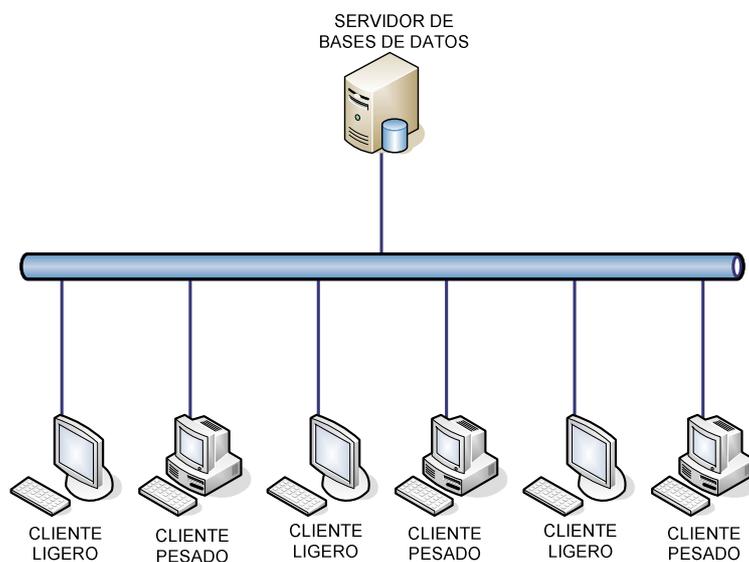


Figura 2. Arquitectura PROGNOS.

6. El proceso de previsión

Previamente al inicio del proceso de previsión, el usuario debe crear las series temporales mediante la agregación temporal y por tipos de los datos de demanda. Dependiendo de la agregación de productos, segmentación de clientes y clasificación de pedidos realizada, se crearán una cantidad determinada de series temporales (ver Tabla 1). En una empresa real, el número de series temporales creadas puede exceder el millar. Las nuevas series temporales creadas no tienen asociada, todavía, ninguna previsión. Estas series serán actualizadas periódicamente a partir de nuevos datos de demanda.

El proceso de previsión comienza cuando la información del *datawarehouse* es actualizada a partir del sistema de información transaccional de la empresa. Normalmente, esta actualización se realiza según una periodificación establecida (diaria, semanal o mensualmente) que coincide con el período de las series. El usuario puede seleccionar un conjunto del total de series utilizando filtros. Para el conjunto seleccionado el usuario puede definir las estrategias a seguir para lanzar el proceso de previsión masivo:

- a) Si una serie no tiene predicciones en los períodos anteriores, el usuario puede especificar un conjunto de métodos de previsión y una medida de error de ajuste o de acierto para seleccionar el mejor método. El usuario también puede almacenar la previsión obtenida por todos los métodos para realizar una selección manual.
- b) Si una serie de tiempo se ha previsto en períodos anteriores, el usuario puede seleccionar el último método de previsión utilizado. Este proceder se basa en el hecho de que el último método de previsión aplicado se ha seleccionado después de considerar otras alternativas, y un período más en la serie no modificará sus características de manera sustancial.
- c) En ambas situaciones descritas, el usuario puede seleccionar el sistema experto. En este caso, se realiza un análisis de las características de la serie temporal. Entonces, se realiza una pre-selección de métodos de previsión y, finalmente, se selecciona el mejor método por comparación de errores de ajuste o acierto (dependiendo de la selección del usuario).

7. Conclusiones

Se ha presentado un sistema de soporte al proceso de previsión de demanda que incluye una gran diversidad de métodos de previsión, un sistema experto automatizado para la selección del modelo de previsión más apropiado a cada serie temporal, y una arquitectura robusta para ser implementada en pequeñas, medianas y grandes empresas. Entre los modelos de previsión implementados hay modelos muy conocidos pero también otros nuevos, como los modelos de basados en programación lineal, cuadrática y non-lineal y los métodos de previsión que incorporan conceptos *fuzzy*.

Las características principales de este sistema son: la agregación flexible de los datos combinando tipos de artículos, clientes y órdenes; la identificación automática de anomalías en los datos; la consideración de variaciones de calendario; los ajustes estacionales; un sistema experto basado en reglas para escoger entre un juego de modelos de previsión; automatización total para la previsión de una cantidad masiva de series temporales; y una fácil integración con el sistema de información existente.

Este sistema ha sido implementado en un prototipo llamado PROGNOS, y está siendo evaluado por un fabricante de productos de acero para la industria de la construcción. En esta compañía PROGNOS realiza docenas de miles de previsiones por mes.

La investigación futura se dedicará a la transformación del sistema del experto estático actual en un sistema experto evolutivo, entrenado continuamente de manera semejante a una red neuronal.

Referencias

- Arinze, B. (1994), "Selecting appropriate forecasting models using rule induction," *Omega-International Journal of Management Science* 22 (6), pp. 647–658.
- Armstrong, J. S., M. Adya and F. Collopy (2001), "Rule-based forecasting: Using judgment in time-series extrapolation," in J. S. Armstrong (ed.), *Principles of Forecasting*. Norwell, MA: Kluwer Academic Press.
- Assimakopoulos, V., Nikolopoulos, K., (2000), "The theta model: a decomposition approach to forecasting," *International Journal of Forecasting*, Vol.16, No. 4, pp.521–530.
- Box, G.E., Jenkins, G.M. (1970), *Time Series Analysis: Forecasting and Control*, Holden-Day, San Francisco.
- Brown, R. G. (1959), *Statistical Forecasting for Inventory Control*, McGraw-Hill, New York.
- Buffa, E.S. y Miller, J.G. (1979) *Production Inventory Systems: Planning and Control*. Third Edition. Homewood, IL, Irwin.
- Bunn, D. W. And Vassilopoulos, A. I. (1993), "Using group seasonal indices in multi-item short-term forecasting," *International Journal of Forecasting* 9, pp. 517-526.
- Collopy, F. and Armstrong, S. (1992), "Rule-based forecasting: development and validation of an expert systems approach to combining time-series extrapolations," *Management Science*, Vol. 38, No. 10, pp.1394–1414
- CPLEX Optimization Inc., (1994), "Using the CPLEX callable library,"
- Croston, J.D. (1972), "Forecasting and stock control for intermittent demands," *Operational Research Quarterly*, 23, pp. 289–303.
- Dagum, E.B. (1980), "The X-11-ARIMA Seasonal Adjustment Method," Statistics Canada.
- De Gooijer, J.G.; Hyndman, R.J.(2005) 25 Years of IIF Time Series Forecasting: A Selective Review. *Tinbergen Institute Discussion Paper*.
- Dickey, D. A. and Fuller, W. A. (1979), "Distribution of estimators for time series regressions with a unit root," *Journal of the American Statistical Association*, 74, pp. 427-431.
- Fildes, R. (1989), "Evaluation of aggregate versus individual forecast method selection rules," *Management Science* 35, pp. 1056-1065.
- Fildes, R., & Makridakis, S. (1995), "The impact of empirical accuracy studies on time series analysis and forecasting," *International Statistical Review* 63, 289-308.
- Findley, D.F., Monsell, B.C., Bell, W.R., Otto, M.C., Chen, B.C. (1996), "New capabilities and methods of the X-12-ARIMA seasonal-adjustment program," *Journal of Business and Economic Statistics* 16, PP. 127–152.
- Flores B.E, Pearce S.L. (2000), "The use of an expert system in the M3 competition," *International Journal of Forecasting* 16 pp. 485–496
- Fred Collopy and J. Scott Armstrong (1989), "Toward Computer-Aided Forecasting Systems: Gathering, Coding, And Validating The Knowledge," *DSS-89 Transactions: Ninth International Conference On Decision Support Systems*, ed. George R. Widmeyer, Institute of Management Sciences, pp. 103-119.
- Ghobbar A.A., Friend C.H. (2002), "Sources of intermittent demand for aircraft spare parts within airline operations," *Journal of Air Transport Management*, 8, pp. 221–231

- Gomez, V. and Maravall, A. (2001), "Seasonal adjustment and signal extraction in economic time series," Chapter 8 in *A course in time series analysis*, ed. D. Peña, G.C. Tiao and R.S. Tsay, John Wiley & Sons: New York.
- Holt, C. C., Modigliani F., Muth J. F. and Simon H. A. (1960), *Planning Production Inventories and Work Force*, Prentice-Hall, Englewood Cliffs, NJ.
- K. Nikolopoulos, K., Assimakopoulos, V. (2003), "Theta intelligent forecasting information system," *Industrial Management & Data Systems* 103/9 pp. 711-726
- Leonard J. Tashman (2000), "Out-of-sample tests of forecasting accuracy: an analysis and review," *International Journal of Forecasting*, Volume 16, Issue 4, Pages 437-450.
- Makridakis, S. (1990) "Sliding simulation: a new approach to time series forecasting," *Management Science* 36, pp. 505-512.
- Makridakis, S. and M. Hibon (2000), "TheM3-Competition: results, conclusions and implications," *International Journal of Forecasting*, 16, pp. 451-476.
- Makridakis, S., Anderson, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., Newton, I., Parzen, P., and Winkler, R. (1982), "The accuracy of extrapolation (time series) methods: results of a forecasting competition," *Journal of Forecasting* 1, pp. 111-153.
- Maravall, A. and Gomez, V. (1992), "Signal Extraction in ARIMA Time Series – Program SEATS," Eui Working Paper Eco N. 92/65, Department of Economics, European University Institute.
- Maximal Software Corporation (2000) "MPL modelling system," Release 4.11, USA
- Mentzas, G., Linardopoulos, I., Assimakopoulos, V. (1995), "An Architecture for Intelligent Assistance in the Forecasting Process," *Proceedings of the 28th Annual Hawaii International Conference on System Sciences*
- Mentzer, J.T. y Bienstock, C.C. (1998) *Sales Forecasting Management*. Sage, Thousands Oaks, CA.
- Montgomery, D.C., Johnson, L.A., Gardiner, J.S. (1990), *Forecasting and Time Series Analysis*, McGraw-Hill, New York.
- Prudencio R.B.C., Ludermir T.B., Carvalho F.A.T. (2004), "A Modal Symbolic Classifier for selecting time series models," *Pattern Recognition Letters* 25, pp. 911-921
- Shiskin, J., Young, A.H. and Musgrave, J.C. (1967), "The X-11 Variant of Census Method II Seasonal Adjustment," Technical Paper No. 15, Bureau of the Census, U.S. Department of Commerce.
- Spedding, T.A. and Chan, K.K. (2000), "Forecasting demand and inventory management using bayesian time series," *Integrated Manufacturing Systems*, Vol. 11, No. 5, pp. 331-339
- Syntetos A.A. (2001), *Forecasting of intermittent demand*. Ph.D. thesis, Buckinghamshire Business School, Brunel University, UK
- Syntetos, A.A. and J.E. Boylan (2005), "The accuracy of intermittent demand estimates," *International Journal of Forecasting*, 21, pp. 303-314.
- Weiss, A. A., and Anderson, A. P. (1984), "Estimating time series models using relevant forecast evaluation criteria," *Journal of the Royal Statistical Society* 147, pp.484-487.
- Williams T.M. (1984), "Stock control with sporadic and slow-moving demand," *Journal of the Operational Research Society* 35(10) pp.939-48.
- Winters, P.R. (1960), "Forecasting sales by exponentially weighted moving averages," *Management Science*, 6, pp. 324-342.
- Yurkiewicz, J. (2000) Software Survey: *Forecasting 2000 OR/MS Today*, Vol. 27, No. 1