

Técnicas de Predicción Cuantitativas Aplicadas a la Cadena de Suministro. Un Caso de Estudio

Quantitative Models for Supply Chain Forecasting. A Case Study

Trapero Arenas J.R.¹, García Márquez F.P.²

Abstract Demand forecasting is a complex topic due to different factors like promotions. Generally, promotions may be forecast by using an univariate statistical approach (system forecast) that is judgmentally adjusted by company experts. The present work reports an analysis of the managerial adjustments accuracy when promotions are taking place. Additionally, quantitative models will be assessed as an alternative to judgmental adjustments when referring to forecast promotions. The results show that judgmentally adjusted forecasts on promotion periods may enhance system forecasts, but not systematically and more importantly, multivariate models based on past promotions information might achieve lower forecasting errors than system and judgmentally adjusted forecasts.

Resumen Las ventas sujetas a promociones se pueden pronosticar mediante una técnica estadística univariante (predicción del sistema), que posteriormente se modifica de acuerdo a la opinión de los expertos de la compañía. Este trabajo tiene dos objetivos: en primer lugar, se pretende analizar la precisión de los expertos cuando predicen las ventas y en segundo lugar, se investigan modelos cuantitativos que puedan reducir o sustituir el ajuste realizado por los expertos. Los resultados muestran que bajo ciertas condiciones los expertos consiguen mejorar las predicciones automáticas del sistema. No obstante, la utilización de modelos

¹Juan Ramón Trapero Arenas (✉ e-mail: juanramon.trapero@uclm.es)
Grupo INGENIUM. Dpto. de Administración de Empresas. Facultad de Ciencias y Tecnologías Químicas. Universidad de Castilla-La Mancha. 13071 Ciudad Real.

²Fausto Pedro García Márquez (✉ e-mail: faustopedro.garcia@uclm.es)
Grupo INGENIUM. Dpto. de Administración de Empresas. ETSI Industriales. Universidad de Castilla-La Mancha. 13071 Ciudad Real.

* Los autores agradecen el apoyo proporcionado por la Unión Europea mediante el proyecto FP7-ENERGY-2012-2: 322430.

cuantitativos estimados en base al histórico de promociones consigue mejorar tanto los resultados de los ajustes de los expertos como las predicciones del sistema.

Keywords: Forecasting, Transfer Functions, Judgmental Forecasting, Marketing, Promotions.

Palabras Clave: Predicción, Funciones de Transferencia, Predicción experta, Marketing, Promociones.

1 Introducción

La predicción de demanda es un tema clave a la hora de reducir los gastos de inventario, mejorar la satisfacción del cliente y optimizar las operaciones de distribución. Normalmente, la predicción de demanda utiliza un Sistema de Apoyo a la Predicción (SAP) (Fildes et al, 2009), que integra una técnica estadística univariante junto con los ajustes *manuales* de los expertos de la organización. En principio, la predicción finalmente utilizada por la compañía es el resultado de dos fuentes de información. Por un lado, el SAP proporciona una predicción de índole estadística que se le conoce como predicción del sistema. Por otro lado, se organizan varias reuniones entre los responsables de las predicciones y el personal de ventas, marketing y producción para incorporar aquella información que no está incluida en el modelo estadístico. Por tanto, la predicción del sistema se modifica de acuerdo con las decisiones del grupo para así obtener una predicción final.

Un ejemplo de estas técnicas univariantes es la familia de métodos de suavizado exponencial (Gardner, 1985). Esta técnica es adecuada para compañías que necesitan predecir la demanda de cada producto de una forma automática. No en vano, estos métodos no son aptos para predecir las ventas cuando hay promociones y por tanto, se espera un aumento de las mismas. Para mejorar las predicciones, los expertos basados en sus experiencias y en el histórico de promociones anteriores modifican las predicciones automáticas proporcionadas por el SAP.

Dada la relación entre estas modificaciones de los expertos y las promociones, el primer objetivo de este trabajo es analizar la precisión de dichas modificaciones cuando hay una campaña promocional. Este análisis es útil de cara a formar a los expertos para que mejoren sus ajustes. Hay que destacar que en el presente caso de estudio, el software utilizado por esta compañía ofrece la posibilidad de modificar las previsiones automáticas pero no analiza la precisión de las mismas.

El problema de predecir las ventas promocionales también se puede estudiar mediante el uso de modelos econométricos que utilizan la información almacenada acerca de las promociones anteriores para formular modelos causales

en forma de regresión lineal múltiple. En este tipo de modelos las variables exógenas o independientes suelen estar relacionadas con las características de la promoción (descuento del precio, posición en las estanterías, tipo de publicidad, etc.). En este sentido se han desarrollado varios tipos de *software*, por ejemplo SCAN*PRO (Leeflang et al, 2002), PromoCastTM (Cooper et al, 1999) y CHAN4CAST (Divakar et al, 2005). Sin embargo, llama la atención que dichas metodologías no se hayan comparado con su competencia natural: las predicciones realizadas por los expertos. Esta pregunta es esencial para una compañía que se plantea invertir en uno de estos sistemas, es decir, lo primero que se preguntaría es si dichos programas son capaces de mejorar las predicciones que hacen sus expertos. Cabe destacar que los autores no han encontrado ninguna referencia donde se compare los modelos econométricos a las predicciones de los expertos en presencia de promociones. Por tanto, el segundo objetivo de este trabajo es desarrollar un modelo econométrico para determinar el grado en el que los modelos cuantitativos pueden mejorar las predicciones proporcionadas por los expertos. Se propone un modelo de predicción a nivel de SKU (*Stock Keeping Unit*) con las siguientes características: i) El número de variables independientes se reduce mediante el uso de Análisis de Componentes Principales. De esta forma también se evita un posible problema de multicolinealidad; ii) Para aquellos productos que no dispongan de suficientes observaciones sujetas a promociones, el modelo utiliza la información de otros productos (*Pool regression*) para realizar las estimaciones de los parámetros; iii) La dinámica de las promociones se modela mediante la introducción de retardos en las variables explicativas; iv) El término de error se modela mediante modelos ARIMA automáticamente identificados mediante la minimización del Criterio de Información de Schwartz.

Para elaborar este trabajo se han recopilado datos muestreados semanalmente acerca de las ventas y promociones de una empresa perteneciente a la industria química localizada en el Reino Unido.

Los resultados muestran que los expertos pueden llegar a mejorar las predicciones proporcionadas por el SAP, no obstante cuando los ajustes son relativamente grandes, dichos ajustes pueden ser contraproducentes. Además, se muestra que el modelo econométrico propuesto, basado en la identificación de patrones utilizando promociones anteriores, mejora las predicciones del SAP y de los expertos cuando hay alguna campaña promocional.

2 Análisis de la Precisión de los Expertos

Los datos se han obtenido de una empresa fabricante de detergentes y otros productos de limpieza. Los datos están compuestos por: i) Ventas; ii) predicciones proporcionadas por el SAP una semana hacia delante, las cuales las llamaremos Predicciones del Sistema (SF); iii) predicciones proporcionadas por los expertos

una semana hacia delante. Citaremos estas predicciones como Predicciones de los Expertos (FF).

Los datos previamente descritos contienen 145 SKUs. En total, se dispone de unos 10,000 registros desde Octubre del 2008 hasta Junio del 2010. La literatura que estudia los ajustes de los expertos señala que dichos ajustes suelen estar sesgados. En (Trapero et al, 2010) se apunta al tamaño y signo de los ajustes como variables explicativas, de forma que pequeños ajustes se espera que sean menos efectivos y que los ajustes positivos, es decir aquellos que aumentan el valor de predicción proporcionado por el sistema, suelen ser menos precisos que los negativos.

En esta sección, se lleva a cabo un análisis descriptivo de los datos para averiguar la precisión obtenida por el sistema de predicción (SF) o por los expertos (FF). Siguiendo las publicaciones hasta la fecha se investigará el efecto del tamaño y signo de los ajustes, pero además este trabajo añade como aspecto novedoso el análisis del efecto de las promociones. Dado que la base de datos analizada posee productos con diferentes propiedades estadísticas (media y varianza) es conveniente normalizar los datos. Para ello se ha elegido normalizar las variables con respecto a la desviación típica de las ventas. Se ha procedido de esta manera de acuerdo a publicaciones anteriores, (Fildes et al, 2009) y (Trapero et al, 2010).

La normalización nos permite tratar a las observaciones como conjunto de datos de sección cruzada. Esto implica que se puede reordenar los datos en función del tamaño y del signo. Si definimos el error absoluto medio tal que:

$$MAE = \frac{1}{N} \sum_{t=1}^N |e_t| \quad (1)$$

Donde e_t representa el error normalizado en el tiempo t , tal que:

$$e_t = (y_t - F_t), \quad t = 1, \dots, N \quad (2)$$

Donde, y_t es el valor real de ventas normalizado y F_t es la predicción. N son las observaciones disponibles en total. La Fig 1 muestra el MAE ordenado de acuerdo al signo y al tamaño de los ajustes. Con respecto a los ajustes positivos (ajustes normalizados mayores que cero), los expertos (FF) consiguen errores de predicción menores cuando el tamaño del ajuste normalizado es inferior a 4 aproximadamente, para ajustes más grandes el SF funciona mejor.

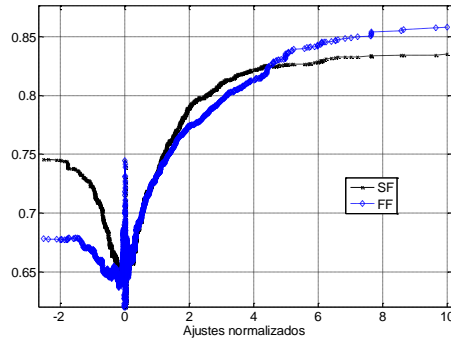


Fig. 1 MAE vs. ajustes normalizados

En relación a los ajustes negativos en la Fig. 1 se pueden extraer las siguientes conclusiones: i) el MAE es inferior al obtenido con los ajustes positivos; ii) el tamaño de los ajustes también es menor; y iii) FF obtiene menores errores de predicción que SF.

Este mejor comportamiento del FF para ajustes positivos se debe a que los expertos conocen de antemano cuando va a haber una determinada promoción y por tanto elevan el valor proporcionado por el SF. Para analizar dicha hipótesis, la Fig. 2 representa los errores de predicción sólo cuando hay activa alguna promoción. En este gráfico se observa claramente como los expertos mejoran las predicciones del sistema cuando los ajustes son positivos, que son la mayoría cuando hay promociones. No obstante, si los ajustes normalizados son muy grandes, los expertos cometen errores mayores que el SF. Es importante destacar la importancia de este tipo de gráficos porque si no se hubiera analizado el tamaño del ajuste lo único que se observaría serían los valores promedios finales, cuya conclusión sería que el SF es más preciso que el FF y dicha conclusión es incompleta.

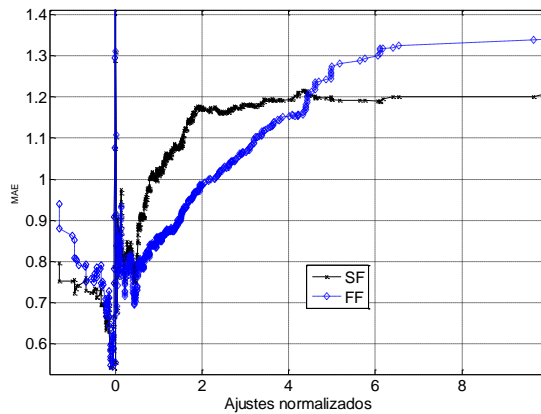


Fig.2 MAE del SF y FF frente a los ajustes normalizados cuando hay algún tipo de promoción.

El gráfico en la Fig. 3 muestra el MAE frente a los ajustes normalizados cuando no hay promociones. Se puede observar que los ajustes positivos no mejoran significativamente con respecto al SF. No obstante, hay que señalar la precisión alcanzada por los ajustes negativos que mejoran considerablemente a las predicciones del sistema (SF). Una posible explicación a esta notable mejoría es el hecho de que una vez acabada la promoción el SAP seguirá produciendo unas previsiones más altas de lo normal ya que sus modelos no incluyen información acerca de cuándo empieza o acaba una promoción. Este defecto del SAP es conocido por los expertos, los cuales reajustan a la baja esas previsiones.

3 Modelado de los Efectos de las Promociones sobre las Ventas

En la sección anterior se mostró que los expertos pueden incorporar información en sus predicciones que el sistema no es capaz de procesar. Esta conclusión abre la puerta a la siguiente cuestión: ¿se basaron los expertos en los resultados de promociones anteriores para realizar los ajustes? En otras palabras, los expertos pudieron haber analizado los efectos que tuvieron promociones parecidas en el pasado e intentar proyectar esos patrones para las promociones futuras. En tal caso, modelos multivariantes como una regresión lineal múltiple es posible que mejoren los resultados obtenidos por los expertos ya que las mentes humanas son buenas para identificar patrones pero no lo son tanto para trabajar con grandes cantidades de información como la que manejamos en este caso de estudio.

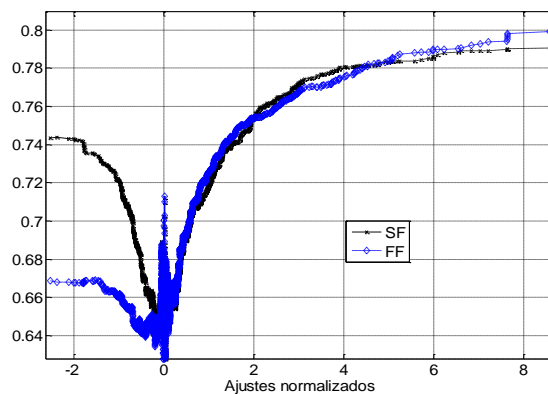


Fig. 3 MAE del SF y FF frente a los ajustes normalizados cuando no hay promociones.

Además de las variables definidas en la sección anterior, se han incluido las siguientes variables que dan información particular sobre las promociones: i) Descuento; ii) Tipo de publicidad; iii) Lugar de exposición y iv) Categoría.

Con el fin de comprobar si las técnicas cuantitativas pueden mejorar las predicciones de los expertos, se propone la siguiente Regresión Dinámica (RD):

$$F_{t+1} = \beta_0^i + \sum_{j=1}^N \beta_j^i X_{j,t+1}^i + e_t \quad (3)$$

Donde las variables $X_{j,t+1}$ son los componentes principales que resumen la información sobre la promoción. N es el número de componentes principales que incluimos en el modelo. En general, una o dos componentes principales han sido suficiente para estimar los modelos. El efecto dinámico de las promociones se ha incluido en el modelo mediante la incorporación de diferentes retrasos en las variables originales utilizadas antes de realizar el análisis de componentes principales. F_{t+1} son las predicciones de ventas un paso hacia delante que corresponden al SKU i .

Para poder utilizar el modelo (3) es necesario conocer de antemano cuándo la empresa va a realizar las promociones. En nuestro caso de estudio las promociones son negociadas con antelación entre el fabricante y el distribuidor. En el caso que no haya suficientes promociones para el SKU sujeto a estudio, se utiliza la información sobre promociones procedentes de otros SKUs en la muestra. Por último el término de error e_t , no se supone ruido blanco sino que se modela utilizando la metodología ARIMA, cuyos órdenes se identifican minimizando el Criterio de Información de Schwartz.

Para analizar el modelo propuesto, vamos a reducir la muestra a aquellos SKUs con demanda continua, y que dispongan de 20 semanas de observaciones con al menos una promoción en la muestra. En total, de los 145 SKUs pasamos a 60 SKUs con un tamaño cada uno que varía entre 53 y 148 observaciones, resultando una muestra de 7,790 casos.

El modelo descrito en (3) se va a comparar con otros modelos de predicción típicamente utilizados en este contexto como son el suavizado exponencial simple (SES), el método ingenuo (*Naïve*) y el *last like promotion* (LL). Este último se aplica comúnmente cuando hay que realizar previsiones de demanda sujetas a promociones. Generalmente consiste en aumentar las previsiones obtenidas por un suavizado exponencial simple de acuerdo al último aumento que se obtuvo en la última promoción con características similares.

El ejercicio de predicción propuesto va a consistir en un experimento *rolling origin*, donde una vez que la predicción se ha realizado, el origen se mueve una semana hacia delante hasta completar la muestra de validación. En este caso la muestra de validación se fija en las últimas 30 semanas, de forma que el 21% de las promociones se encuentran en dicha muestra de validación.

Tabla 1 MAE calculado en la muestra de validación por las diferentes técnicas consideradas.

SF	FF	Naïve	SES	LL	RD
1.069	1.327	1.092	0.904	1.122	0.868

En la Tabla 1 se muestra el error de predicción (MAE) obtenido por cada uno de los métodos de predicción considerados en la muestra de validación. En dicha tabla se puede observar como la regresión dinámica propuesta (RD) consigue obtener los menores errores de predicción en ventas en comparación con el resto de técnicas e incluso consigue una reducción del 19% con respecto a la precisión de los expertos. El MAE se ha calculado solamente sobre las ventas en las que hay algún tipo de promoción activada.

Estos resultados sugieren que los ajustes que los expertos realizan para modelar las promociones pueden ser sustituidos por modelos multivariantes estadísticos, los cuales consiguen mejorar las predicciones y a su vez reducir la carga de trabajo de los expertos.

4 Conclusiones

Los modificación de las predicciones por parte de los expertos es un método comúnmente empleado para modelar las promociones. Sin embargo, los autores no han encontrado casos de estudio en la literatura que analice la eficiencia de dichas modificaciones. Este trabajo investiga la precisión alcanzada por los expertos para predecir la demanda de los clientes cuando hay activa una campaña promocional. El primer resultado encontrado muestra que efectivamente los expertos pueden mejorar las predicciones pero no sistemáticamente, ya que si los ajustes son relativamente grandes, estos ajustes pueden no ser aconsejables.

En base a que los expertos ajustan las predicciones analizando los resultados obtenidos en promociones anteriores, este trabajo plantea otra alternativa que utiliza un modelo cuantitativo para predecir las ventas promocionales. Los resultados indican que este modelo mejora en promedio las predicciones realizadas tanto por el sistema como por los expertos para nuestro caso de estudio.

5 Referencias

- Cooper LG, Baron P, Levy W et al (1999) PROMOCAST Trademark: A New Forecasting Method for Promotion Planning. *Marketing Science*, 18(3):301.
- Divakar S, Rachford BT, Shankar V (2005) CHAN4CAST: A multichannel, multiregion sales forecasting model and decision support system for consumer packaged goods. *Marketing Science*, 24:334-350.

- Fildes R, Goodwin P, Lawrence M et al (2009). Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. *International Journal of Forecasting*, 25:3-23.
- Gardner ES (1985) Exponential smoothing: The state of the art. *Journal of Forecasting*, 4:1-28.
- Leeftang PSH, van Heerde HJ, Wittink D (2002) How promotions work: SCAN*PRO-Based evolutionary Model Building. *Schmalenbach Business Review*, 54:198-220.
- Pedregal DJ, Contreras J, Sanchez A (2010) Handbook of Networks in Power Systems, chapter ECOTOOL: A general MATLAB forecasting toolbox with applications to electricity markets, pages 69-104. Springer Verlag.
- Trapero JR, Fildes R, Davydenko A (2010) Nonlinear identification of judgmental forecasts effects at SKU level. *Journal of Forecasting*, 30:490-508.