

## Propuesta metodológica para la previsión de la demanda con modelos causales *Methodological proposal for demand forecasting using causal models*

Carolina Hoyos<sup>1</sup> y Raúl Poler<sup>2</sup>

<sup>1</sup> Escuela Técnica Superior de Ingenieros Industriales. Universitat Politècnica de València. (UPV). Camino Vera S/N. 46022 Valencia (España).

<sup>2</sup> Departamento de Organización de Empresas. Centro de Investigación Gestión e Ingeniería de Producción (CIGIP). Escuela Politécnica Superior de Alcoy. Universitat Politècnica de València. (UPV). Pl. Ferrándiz Carbonell S/N. 03801 Alcoy, Alicante (España).

*Fecha de recepción: 5-7-2012*

*Fecha de aceptación: 31-10-2012*

**Resumen:** En este trabajo se propone una metodología genérica para la previsión de la demanda con modelos causales que incorporan variables exógenas, conocidas o no. Para detectar eventos causales, cuando se desconoce dicha información, se contemplan dos modelos (uno estadístico y otro de exploración) que permiten realizar suposiciones fundamentadas de su existencia. La metodología se validó en un caso de estudio en una empresa colombiana del sector electrodomésticos de línea blanca. Los resultados demuestran que el porcentaje de error absoluto medio (MAPE) disminuye significativamente al utilizar el modelo causal propuesto, respecto al obtenido mediante la utilización de métodos de series temporales.

**Palabras claves:** previsión de demanda, modelos causales, programación matemática, compartir información.

**Abstract:** Through the last years, different collaborative practices have emerged in the supply chain. Progressively there is increasing belief that, working collaboratively, the partners in a supply chain achieve greater efficiency, both individually and collectively. Processes as demand forecasting are evolving from an individual process towards a more collaborative one, wherein sharing information is necessary and fundamental. To share relevant information constitutes a key factor to face the unexpected changes of demand, since it allows to know and to consider the information from various supply chain partners, especially the causes of demand variations, such as special offers information, new products/competitors introduction, market and price changes, among others.

However, applying collaborative forecasting models is not simply, considering that companies need to fulfill a series of conditions that allow to share information. One of these conditions is recording, documenting and controlling all those especial events that could affect the demand and, subsequently they should have enough trust to share that information. If companies could have that information, they could make more accurate forecasting. However, reality is different, usually they do not count with the necessary information on the causes and therefore the demand forecasting is less accurate.

This paper proposes a general methodology for demand forecasting with causal models, through a linear programming model incorporating exogenous variables, whether known or unknown. On this methodology, two models are included, one of them statistical, and the other one exploratory, to detect causal events when related information is unknown. With such models, supported assumptions on the existence of those factors can be made. The first one is up to reduce dimensions, through examination of variable interdependency and based on data structure. The goal for the second model is to find causal factors starting from the identification of unusual values (outliers) by applying the best time series forecasting methods without regard causal factors. Having identified the causal factors, they are incorporated into a linear programming model to generate the final demand forecast.

This methodology was validated in a case study in a Colombian household appliances manufacturing company, where the models to detect causal factors were applied, because the company did not have such information. The proposed exploratory model did not show sufficient information to identify causal factors, but it provided valuable information to perform a general analysis by product families. The statistical model was able to identify the causal factors to be incorporated to the proposed linear programming model. Results demonstrate a significant reduction of the mean absolute percentage error (MAPE), taking as reference the one obtained by using traditional time series forecasting methods, which evidences that assumption method can be highly useful for companies interested in obtaining more accurate forecasting without wide information on causal factors that affect demand. It is also the first step for companies that would want to start a collaborative forecast process, since it proves the importance of sharing information with which to explain the identified causal factors.

**Keywords:** demand forecasting, causal models, mathematical programming, sharing information.

## 1. Introducción

Generar proyecciones de demanda basadas en el análisis estático ya no es suficiente en el mercado actual, que cada vez es más volátil, fragmentado y dinámico (Lo, Luong, y Marian, 2006). Todos estos cambios, a los que la demanda es sensible, requieren de un proceso de pronóstico mejorado para proyectar con precisión las demandas futuras de una manera integral, sensible, adaptable, sistemática y colaborativa con otras áreas de la empresa y con los socios de la cadena de suministro en la que se está inmerso (Cheikhrouhou, Marmier, y Ayadi, 2011; Danese, 2007).

La importancia de la faceta colaborativa de la previsión radica en los beneficios que se le asocian: favorece una previsión de la demanda más precisa, mejora el rendimiento de la cadena de suministro, reduce los niveles de inventario, aumenta la calidad del servicio y la satisfacción del cliente (Poler, Mula, Ortíz y Lario, 2006; Yang, 2009; Zacharia, Nix y Lusch, 2009). Mejoras que se alcanzan si se comparte la información necesaria para realizarla (Danese, 2007; Huang, Chen y Chung, 2008; Kubde y Bansod, 2010) incluyendo los factores que la afectan (Cheikhrouhou, et al., 2011; Lo, et al., 2006; Ramanathan y Muyltermans, 2010). Como afirman Ali, Sayin, Woensel, y Fransoo (2009) un pronóstico incorrecto genera la mayoría de las roturas de inventario, ya que la demanda de un producto suele ser más alta por un incremento en el volumen de las ventas durante el periodo de la promoción (Divakar, Ratchford, y Venkatesh, 2005). Por ello es crítico entender el impacto de todos los factores que influyen en las previsiones (Ramanathan y Muyltermans, 2010).

No obstante la información de los cambios a los que la demanda es sensible no siempre está disponible, o es difícil recopilar los factores históricos que han afectado la demanda (Ramanathan y Muyltermans, 2010) y, aunque estén disponibles, es necesario contar con un modelo de previsión que incluya dichos factores, de manera que se encuentren valores más ajustados a la realidad (Carbonneau, Laframboise, y Vahidov, 2008).

Es por esto que en este trabajo se plantea la posibilidad de realizar previsiones de demanda aplicando un modelo basado en factores causales que han sido supuestos en ausencia de información. Si bien estos no remplazan la calidad de los datos reales, se consideran un buen inicio para la implementación de un proceso de previsión colaborativa cuando se carece de este tipo de información.

El artículo está estructurado de la siguiente forma. En la sección 2 se describe la problemática abordada. En la 3 se presenta la metodología genérica para la previsión de la demanda con modelos causales propuesta, en la 4 su validación y el caso de estudio. Por último se exponen las conclusiones y líneas futuras de investigación.

## 2. Descripción del Problema

Cada vez es más necesario trabajar conjuntamente, intercambiar información y colaborar en el contexto de una cadena de suministro para ser más eficientes en el uso de recursos y más efectivos en el servicio al cliente. Uno de los principales instrumentos para conseguirlo es la gestión de la demanda colaborativamente (VICS, 2008).

Esta colaboración se puede llevar a cabo tanto en un nivel intraempresa, como interempresa, compartiendo información relevante para la toma de decisiones relativas al aprovisionamiento, producción y distribución (Cheikhrouhou, et al., 2011). Los beneficios de la Previsión Colaborativa (PC) son la comprensión entre los socios, las oportunidades logísticas, la disminución de la incertidumbre y la reducción del error de previsión (Langley, Coyle, Gibson, Novack, y Bardí, 2009; Poler, et al., 2006).

La información a compartir va desde las series temporales de demanda hasta los factores causales (nuevos productos, promociones, nuevos competidores, cambios en el mercado y en el precio) (Lo, et al., 2006) que generan cambios significativos en la demanda. El manejo de este tipo de información y los procedimientos para compartirla requiere de tecnología específica para su soporte y organización (Danese, 2007; Huang, et al., 2008).

En la literatura existen desarrollos que aportan al proceso de PC en cuanto a la selección de información, técnicas de previsión, tecnologías, metodologías y diferentes modelos, incluyendo los causales. Sin embargo, la información relevante para obtener una previsión de la demanda basándose en estos últimos no siempre está disponible o está desarticulada. Este hecho dificulta que se pueda obtener una PC que incluya estas variaciones en el corto plazo y dificulta iniciar un proceso de este tipo (Ramanathan y Muyltermans, 2010).

Ramanathan y Muyltermans (2010) encuentran que las técnicas de previsión tradicionales son adecuadas

para cadenas de suministro convencionales y para productos funcionales. Sin embargo, cuando hay eventos especiales, las técnicas de previsión son insuficientes para manejar las fluctuaciones, lo que lleva a la necesidad de desarrollar modelos para ayudar a los planificadores de la demanda ante estas situaciones.

El presente estudio se centra en un sector industrial en particular: el de la fabricación de electrodomésticos de línea blanca. Pese a ser un sector altamente competitivo, con una demanda influenciada por diferentes factores, una base de proveedores particular y cuyos costes de materias primas y almacenamiento son representativos, dicho sector no es una excepción a la carencia de información para iniciar la PC. Por este motivo, se ha desarrollado una metodología para la previsión con modelos causales que supone información fundamentada que sirva como base para el inicio de un proceso de PC.

### 3. Metodología Genérica

La metodología propuesta está compuesta por cinco pasos (Figura 1), los cuales pueden aumentarse en el caso de que se deban suponer los factores que afectan la demanda cuando no se conocen. A continuación se describirá cada uno de los pasos.

1. Entender la necesidad de la PC con factores causales. Para ello se utiliza un cuestionario para obtener una visión general del proceso de previsión que realiza la empresa, la información y recursos con los que cuenta y las necesidades de implementación. Este se aplica tomando como base la lista de capacidades básicas y avanzadas propuesta por ECR Europe (2001).
2. Determinar la información necesaria. Consiste en el intercambio de información entre los socios (internos y/o externos), de las series temporales y de los factores causales que puedan afectar a la demanda. Este paso puede ser difícil porque los socios pueden considerar como sensible el tipo de información a intercambiar.
3. Localizar las fuentes de datos de los factores que afectan la demanda. Garantizar que se dispone de todas las fuentes de información. En caso de que no se posea, se hace necesario encontrar un modelo que permita hallar esta información faltante, que es básica para iniciar y mantener un proceso de PC. Se proponen dos modelos para hacer suposiciones acerca de los factores causales que podrían estar afectando la demanda en ausencia de información: uno de exploración y otro estadístico. El primero busca reducir di-

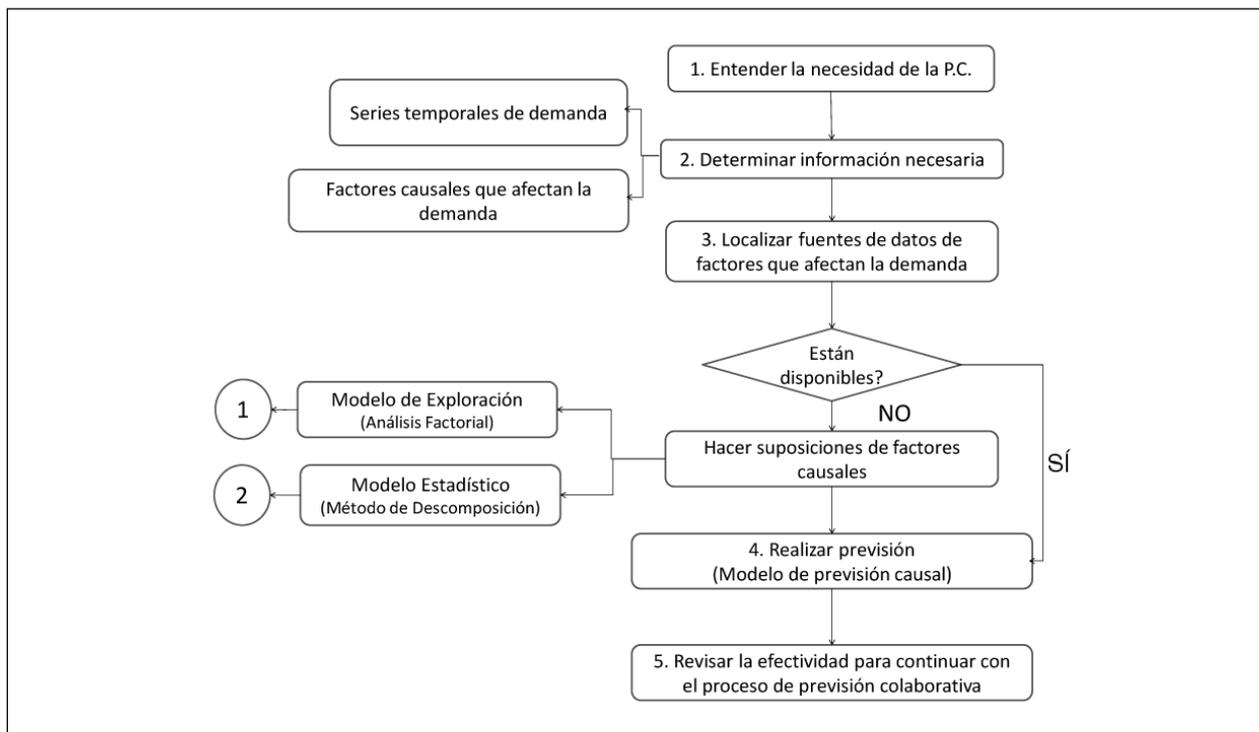


Figura 1  
Metodología para la previsión de la demanda con modelos causales

menciones, examinando la interdependencia de las variables a través de la estructura de los datos, con el fin de explorar la existencia de factores causales (apartado 3.1). El segundo busca encontrar factores a partir de la identificación de valores fuera de lo normal (outliers) al aplicar el mejor método de previsión (apartado 3.2).

- Realizar la previsión. En este paso, se propone un modelo de Programación Lineal basado en la descomposición aditiva de series temporales, pero que incluye la consideración de factores causales, que optimiza el error absoluto medio de ajuste. Las variables de decisión y los parámetros se presentan en la Tabla 1. A continuación se formula el modelo que supone el tratamiento de valores de demanda mensuales (puede extenderse fácilmente al tratamiento de valores de demanda semanales o diarios):

Minimizar:

$$Z = \sum_{t=1}^T \frac{ErrAt}{T} \quad [1]$$

Sujeto a:

$$Y_t = A_{\alpha=\alpha_t} + M_m = \mu_t + \sum_{\epsilon=1}^E E_{\epsilon} \cdot \theta_t^{\epsilon} \quad [2]$$

$$Err_t = Y_t - X_t \quad [3]$$

$$Err_t \leq Err_t A_t \quad [4]$$

$$-Err_t \leq Err_t A_t \quad [5]$$

La función objetivo [1] pretende minimizar el error absoluto medio del ajuste. La restricción [2] calcula el valor de la previsión para cada periodo a partir del valor que toma la previsión según el año y el mes y del valor de los factores cuando se presentan en dicho periodo. La restricción [3] calcula el valor del error de previsión para cada periodo como la diferencia entre la previsión calculada y el histórico de demanda. Las restricciones [4] y [5] tratan de forma lineal la función valor absoluto. La variable  $Err_t$  puede tomar valores negativos.

- Revisar la efectividad para continuar con el proceso de PC. Se calcula el porcentaje de error medio absoluto (MAPE) y se analiza la magnitud del error para establecer si se requiere de la identificación de más factores causales que expliquen parte del error de previsión que se estuviera cometiendo.

### 3.1. Modelo de Exploración para hallar factores causales

El primer modelo propuesto para suponer la información relativa a los factores causales se presenta gráficamente en la Figura 2, y los pasos se describen a continuación.

- Primero se calcula la previsión con el método de descomposición de series temporales (DST), pues trata de identificar los factores estacionales y la tendencia de ciclo (Makridakis, et al., 1998).

Tabla 1  
Variables de decisión y parámetros del modelo

Índices	
$t$	índice de periodos (mensuales) de histórico y previsión, $t \in \{1, \dots, T\}$
$\alpha$	índice de años que aparecen en el histórico y la previsión, $\alpha \in \{1, \dots, A\}$
$m$	índice de meses de un año, $m \in \{1, \dots, 12\}$
$\epsilon$	índice de tipos de eventos, $\epsilon \in \{1, \dots, E\}$
Datos	
$X_t$	demanda observada en el período $t$
$\mu_t$	mes del periodo $t$
$\alpha_t$	año del periodo $t$
$\theta_t^{\epsilon}$	toma el valor 1 si en el período $t$ aparece un evento de tipo $\epsilon$
Variables de decisión	
$A_{\alpha}$	valor de previsión para el año $\alpha$
$M_m$	valor de previsión para el año $m$
$E_{\epsilon}$	valor de la previsión aparece un evento de tipo $\epsilon$
$Y_t$	valor total de la previsión en el período $t$
$Err_t$	error de ajuste en el período $t$
$ErrA_t$	valor absoluto del error de ajuste en el período $t$

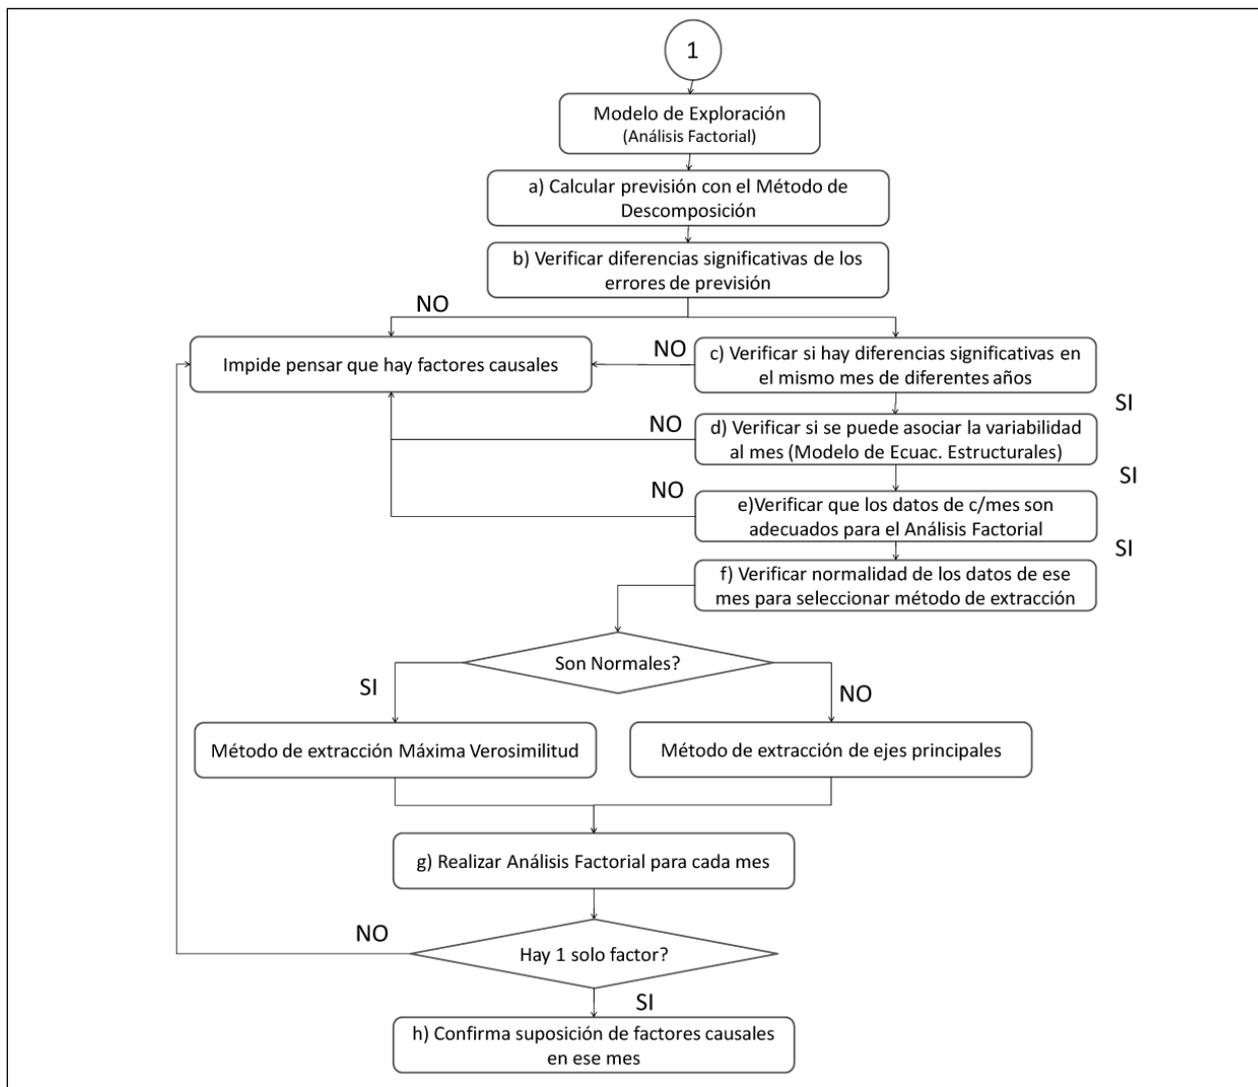


Figura 2

### Modelo de Exploración para hallar factores causales

- b) Luego se verifica si los errores de previsión hallados son significativos con la prueba de significancia  $\chi^2$ . Se consideran como valores significativos aquellos en los que el valor de  $\chi^2 \leq 0,050$  y  $\chi^2 \geq 0,095$ .
- c) Se verifica si hay diferencias significativas en el mismo mes de diferentes años. Se considera que habrá existido, al menos, un evento especial cuando, en el mismo mes de dos o más años diferentes se encuentre una diferencia significativa. Con base en esta información se realizan suposiciones de factores causales.
- d) Se comprueba la viabilidad de la suposición de que se puede asociar la variabilidad al mes. Para dar soporte a esto se realiza un análisis general

de la agrupación de los datos por meses en distintos años, esto en la medida que, cuando no se conocen factores causales, se debe iniciar con un supuesto o hipótesis. Con este supuesto se realiza un modelo de ecuaciones estructurales y se verifica el ajuste del modelo a través de la Estimación de Máxima Verosimilitud. La bondad de ajuste se evalúa a través de los índices: RMSEA, NFI, NNFI y CFI (Byrne, 2011; Hair, Black, Babin y Anderson, 2010). También se verifica el ajuste utilizando el índice Chi Cuadrado. El modelo ajustará si en cada uno de los 12 meses hay factores causales, el ajuste será bajo si no hay muchos meses con un factor causal. Lo importante es verificar que los datos del mismo mes de diferentes años se relacionan entre sí.

- e) Se revisa que los datos de cada mes son adecuados para el análisis factorial, a través de las medidas de adecuación muestral.
- f) Se verifica la normalidad de los datos, esto es necesario para seleccionar el método de extracción factorial. Se usa el Método de máxima verosimilitud si los datos son normales. Si no son normales se usa Factorización de ejes principales.
- g) Se realiza el análisis factorial, se aplica uno para cada mes del año en el que se haya encontrado un evento que explique su variabilidad.
- h) Por último, se confirma la suposición de que en ese mes existen factores causales. Si los resultados muestran un solo factor, se confirma la suposición, pero si presentan más de un factor no se puede ni confirmar ni rechazar esta idea.

**3.2. Modelo Estadístico para hallar factores causales**

En la Figura 3 se presenta gráficamente el otro modelo propuesto para suponer factores causales. Los pasos se describen a continuación.

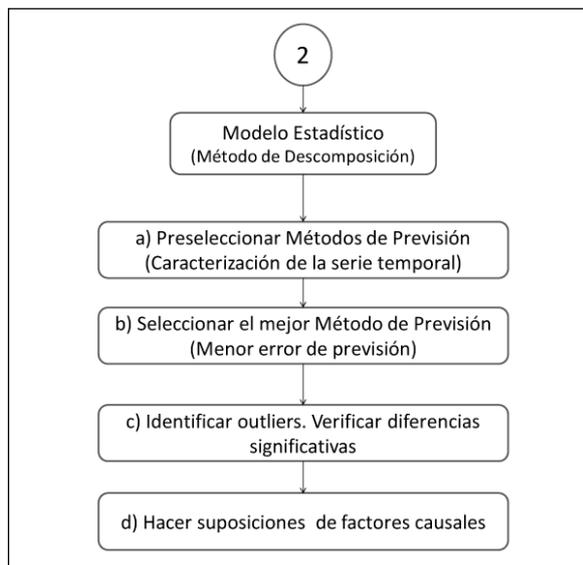


Figura 3  
Modelo estadístico para hallar factores causales

- a) Se caracteriza la serie temporal para descartar los modelos de previsión que no son apropiados. Aunque se podrían utilizar métodos de caracterización que tengan en cuenta tanto la rotación

de los ítems, como el tipo y complejidad de la demanda, como por ejemplo el ABC/XYZ (Errasti, Chackelson y Poler, 2012), se opta por analizar solo la demanda, a partir del cálculo de su tendencia, estacionalidad, aleatoriedad e intermitencia. Para el cálculo de la tendencia, se propone utilizar métodos de ajuste que expliquen la variable en función del tiempo (Pérez, 2005). Para determinar si la serie es estacionaria se aplica el test de Dickey-Fuller (StataCorp, 2011). Para la aleatoriedad y la intermitencia se calculan el Coeficiente de Variación (CV) y el Promedio entre los intervalos de demanda (ADI) de Ghobbar y Friend (Poler, Mula, Peidro, y Tomás, 2006).

- b) A continuación se selecciona el mejor método de previsión, calculando los errores de ajuste (MAPE) de los métodos de previsión que no fueron descartados con el paso anterior. Se selecciona aquel método con menor MAPE de ajuste. Luego se calculan los errores de acierto (MAPE) del método seleccionado variando los parámetros y se seleccionan aquellos con menor MAPE de acierto. Por último, se calcula de nuevo el MAPE de ajuste con el método y los parámetros seleccionados.
- c) Se identifican los outliers, con las diferencias significativas  $\chi^2$  de los errores de previsión hallados. Considerando como valores significativos aquellos en los que el valor de  $\chi^2$  están entre  $0,0 \leq \chi^2 \leq 0,090$ , para valores por encima y entre  $0,91 \leq \chi^2 \leq 1,0$  para valores por debajo.
- d) Por último, se suponen factores causales que agrupen los outliers identificados. Se proponen cuatro eventos o factores, dos de ellos por encima y dos por debajo, según los siguientes rangos:

Valores por encima:  $0,0000 \leq F1 \leq 0,0006$   
 $0,0006 < F2 \leq 0,0960$

Valores por debajo:  $0,9100 \leq F3 \leq 0,9890$   
 $0,9890 < F4 \leq 1,0000$

**4. Validación de la metodología propuesta en una empresa del sector electrodomésticos de línea blanca**

La metodología propuesta se ha validado en una empresa de electrodomésticos de línea blanca de Colombia, cuyo objetivo era mejorar su proceso de previsión de la demanda. Se seleccionó la familia de productos más representativa. Se encontró que no

contaba con información sobre los factores que afectaron las demandas pasadas. Por esto se debió proceder con el paso 3 de la metodología propuesta. Con la validación se buscó responder a la siguiente pregunta: *¿El error de previsión se reduce al introducir factores causales supuestos a la previsión de la demanda?* Para contestar a esta pregunta, se tomaron los datos de demanda desde septiembre de 2008 a septiembre de 2011, de las referencias que tuvieron un movimiento constante, quedando, de este modo, 94 de las 144 referencias que eran parte de la familia seleccionada.

#### 4.1. Validación del Modelo de Exploración

El modelo de exploración propuesto permite conocer si hay tendencias generales asociadas al mes que contribuyan a explicar aumentos o reducciones de la demanda. Por fines prácticos se valida con referencias con diferencias significativas por encima. Primero se aplicó el modelo DST y se calculó la prueba de significancia  $\chi^2$  para determinar si la desviación del error de previsión era significativa o no.

Luego, se realizó el análisis de Ecuaciones Estructurales y se encontró que, aunque los índices de ajuste del modelo no eran favorables ( $\chi^2 = 5344.650$ ;  $Df = 563$ ;  $RMSEA = 0.302$   $p = 0.00$ ;  $NFI = 0.580$ ;  $TLI = 0.531$ ;  $CFI = 0.603$ ) los estimados estandarizados y su nivel de significación indican que tiene sentido buscar rela-

ciones basadas en la idea de que hay una variabilidad asociada al mes, lo cual se evidencia porque las relaciones fijadas entre los meses son estadísticamente significativas, es decir, presentan pesos altos cercanos a 1 (ver Tabla 2).

A continuación se utilizó el método de exploración para confirmar los factores. Esto se hizo para cada uno de los meses en los que se identificaron observaciones (referencias) con factores causales o eventos especiales, que afectan la demanda generando variaciones de aumento.

Dado que los datos siguen una distribución normal se seleccionó el Método de extracción de máxima verosimilitud. Se verificó si se cumplían los supuestos del análisis factorial antes de proceder a confirmar si había un único factor que explicara la varianza de los datos. En tal caso, si presenta cargas factoriales altas, se sugiere que cada uno de los años está altamente integrado con el factor (evento especial). Si, por el contrario, no cumple todos los supuestos del Análisis factorial no es posible confirmar la existencia de un factor común. Los análisis realizados sugirieron que había un evento especial en los meses de Enero, Marzo, Abril y Diciembre, como se observa en la tabla 3.

Este método se limita al análisis de los cambios en la demanda por familia de productos, lo cual puede ser útil para la empresa pero no permite ver cambios es-

Tabla 2  
Pesos de regresión estandarizados

Año	Mes	Estim	S.E.	P	Año	Mes	Estim	S.E.	P	Año	Mes	Estim	S.E.	P
2009	07	,898			2008	11	,770			2011	03	,903		
2010	07	,972	,086	***	2009	11	,937	,122	***	2010	03	,967	,045	***
2011	07	,938	,115	***	2010	11	,955	,151	***	2009	03	,792	,056	***
2009	08	,896			2008	12	,786			2011	04	,965		
2010	08	,989	,054	***	2009	12	,953	,097	***	2010	04	,978	,023	***
2011	08	,973	,067	***	2010	12	,962	,152	***	2009	04	,810	,034	***
2008	09	,615			2011	01	,930			2011	05	,957		
2009	09	,919	,263	***	2010	01	,948	,030	***	2010	05	,959	,029	***
2010	09	,932	,359	***	2009	01	,690	,035	***	2009	05	,820	,034	***
2008	10	,735			2011	02	,906			2011	06	,959		
2009	10	,926	,135	***	2010	02	,931	,051	***	2010	06	,973	,028	***
2010	10	,923	,197	***	2009	02	,664	,061	***	2009	06	,826	,044	***

Nota: Estim.=Pesos de regresión estandarizados, S.E.= Desviación estándar, P= Nivel de probabilidad

Tabla 3  
Resultados Análisis Factorial

Mes	Determinante	KMO	Valor Chi <sup>2</sup>	Diferencia significativa	Varianza explicada (%)
Enero	0.005	0.642	21.797	0.000	83.2
Marzo	0.062	0.530	25.562	0.000	67.1 <sup>1</sup>
Abril	0.152	0.526	51.256	0.000	63.4
Diciembre	0.019	0.561	32.318	0.000	88

<sup>1</sup> En la matriz factorial de marzo en los años 2010 y 2011 hay cargas factoriales altas, que sugieren que están altamente integradas con el factor (0.966 y 0.999) mientras marzo de 2009 no (-0.284). Se eliminan la existencia de un factor en marzo de 2009.

pecíficos para cada referencia, por lo tanto se debe continuar con el otro método de suposición de factores causales.

4.2. Validación del Modelo Estadístico

Para hacer más práctico el análisis se usaron las 62 referencias seleccionadas en el modelo anterior. Para preseleccionar el modelo de previsión se caracterizaron cada una de estas series, calculando los estadísticos requeridos para determinar si la serie tenía tendencia, era aleatoria, intermitente, errática o estacional.

De las series caracterizadas se tomó una muestra representativa del 20% (12 series), de aquellas que presentan las mismas características. Para cada una de estas series se evaluaron los modelos de previsión en los que se esperaba hubiera un menor error de previsión. Con esta información se verificó si había

diferencias significativas entre el valor de la demanda y el valor previsto. Se clasificaron las diferencias en cada uno de los cuatro factores supuestos, que se definieron previamente en la metodología. En el ejemplo de la Figura 4 se puede observar el resultado de aplicar el modelo de previsión Holt-Winters (como modelo de mejor ajuste) para la referencia AC, además están señaladas las diferencias significativas en los cuatro factores supuestos.

A continuación, se aplicó el modelo de programación lineal propuesto, teniendo en cuenta los factores causales supuestos. En la Figura 5 se encuentra el gráfico de previsión de la demanda obtenido en este paso para el ejemplo, se observa un mejor ajuste del modelo.

En la tabla 4 se encuentran los errores de ajuste al aplicar los dos métodos, el porcentaje de cambio del error con respecto al mejor método y el total de outliers identificados, distribuidos en los factores cau-

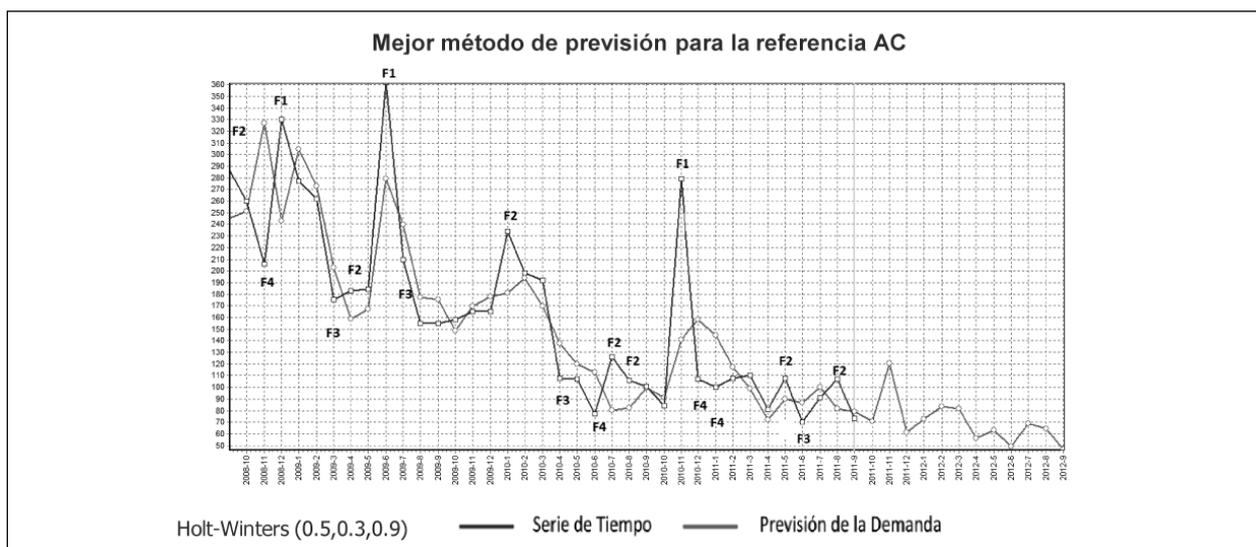


Figura 4  
Identificación de factores causales para la referencia AC

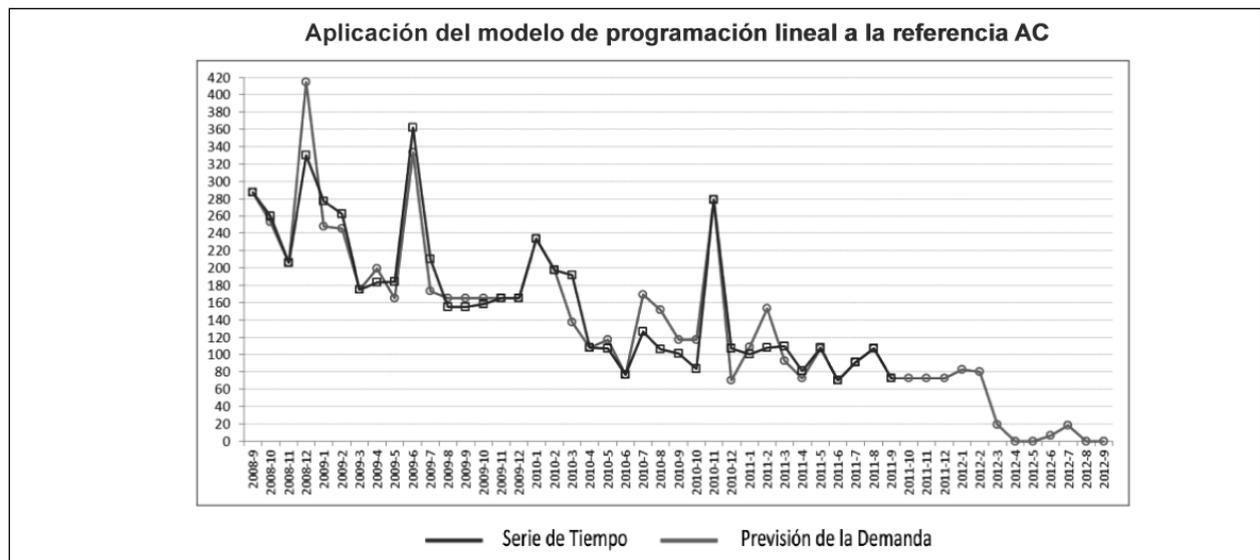


Figura 5

**Modelo de previsión causal para la referencia AC**

sales. Los datos sombreados significan que, para esa referencia, el modelo de previsión causal no ofrece mejores resultados que el mejor método. Puede verse que, en general el error de previsión del modelo con factores causales es menor que el calculado con el mejor método, excepto cuando el error de previsión obtenido con este último es bajo (según lo analizado cuando es menor al 15%).

**5. Conclusiones**

La metodología propuesta permite realizar suposiciones de factores causales que impactan la demanda, logrando superar la problemática de ausencia de este tipo de información, la cual se supone es muy útil si se comparte (Danese, 2007; Huang, Chen y Chung, 2008; Kubde y Bansod, 2010), incluir este tipo

Tabla 4

**MAPE Mejor método vs. Modelo de programación lineal**

Ref	MAPE (AJUSTE) Mejor método	MAPE (AJUSTE) Previsión Causal	DIFERENCIA DEL ERROR	Nº de outliers en los factores causales
AC	Holt-Winters (0.5, 0.3, 0.9)=18.44%	10.6%	42.52%	18
AL	Holt-Winters (0.1, 0.1, 0.9)=14.43%	17.2%	-19.20%	10
BK	Holt-Winters (0.2, 0.3, 0.1)=24.81%	17.4%	29.87%	31
BN	Holt-Winters (0.1, 0.4, 0.1)=40.51%	31.4%	22.49%	30
BY	Holt (0.1,0.1)=35%	13.5%	61.43%	29
CM	Holt-Winters (0.2, 0.4, 0.9)=8.02%	14.4%	-79.55%	5
CP	Holt-Winters (0.2, 0.2, 0.9)=9.76%	19.9%	-103.89%	8
CZ	Holt-Winters (0.3, 0.6, 0.3)=35.93%	22.7%	36.82%	14
DC	Holt (0.1,0.4)=25.41%	10.1%	60.25%	16
DJ	Holt-Winters (0.4, 0.8, 0.3)=401.64%	39.2%	90.24%	14
DM	Holt-Winters (0.2, 0.7, 0.5)=32.27%	31.7%	1.77%	23
DS	Media Móvil Doble (9)=29.33%	18.1%	38.29%	8

de factores puede servir para mejorar la previsión de la demanda (Cheikhrouhou, et al., 2011; Lo, et al., 2006; Ramanathan y Muyldermans, 2010) ya que es crítico entender el impacto de dichos factores en las previsiones (Ramanathan y Muyldermans, 2010).

La metodología incluye un modelo de programación lineal que demuestra que, al incluir factores que afectan la demanda, se obtienen mejores resultados en el acierto de previsión que cuando se sigue el procedimiento tradicional, de esta manera se cuenta con un modelo de previsión que busca encontrar valores más ajustados a la realidad (Carbonneau, Laframboise, y Vahidov, 2008).

La problemática encontrada en el caso de estudio permitió aplicar la metodología, incluyendo los pasos referentes a la realización de suposiciones de los factores causales que afectan la demanda, ya que fue necesario suplir la ausencia de esta información. Aunque el modelo de exploración propuesto para la suposición de factores no arrojó la información esperada en este caso de estudio, sí proporcionó otra información que pudo ser utilizada para análisis generales por familias de productos. Con el modelo estadístico, por su parte, se demostró que se puede reducir el error de previsión obtenido con el mejor método de previsión.

Pese a que la revisión de la literatura permitió plantear el modelo, el diseño resulta novedoso, por tanto, difícilmente se puede contrastar con resultados previos, lo cual más que una dificultad, debe considerarse como un reto para futuras investigaciones, que permitan verificar los hallazgos de esta.

Para finalizar, se han identificado las siguientes líneas de investigación: (i) realizar la caracterización de la serie temporal para el modelo estadístico propuesto utilizando otro método, establecer un modelo que permita que las suposiciones realizadas para identificar *outliers* sean más objetivas y que permita identificar el número óptimo de factores causales, realizar relaciones entre la caracterización de la serie y los factores causales; (ii) construir un modelo causal para la previsión cuando la demanda es intermitente; (iii) comparar la metodología propuesta frente a otros modelos de series temporales, como los AR, ARMA o ARIMA que incluyen componentes estacionales; (iv) aplicar otros criterios para seleccionar el mejor modelo de previsión, como el criterio de información bayesiano (BIC) y el criterio de información Akaike (AIC), ambos verifican el grado de acierto del modelo teniendo en cuenta su comple-

jididad (Poler, Mula y Peidro, 2009) (v) validar la metodología propuesta en otros sectores industriales con otra tipología de productos.

## Bibliografía

- ALI, Ö. G., SAYIN, S., WOENSEL, T.V., y FRANSOO, J. (2009). SKU demand forecasting in the presence of promotions. *Expert Systems with Applications* (36), pp. 12340-12348.
- BYNE, B.M. (2011). *Structural Equation Modeling with Mplus; Basic Concepts, Applications, and Programming*. Routledge Academic.
- CARBONNEAU, R., LAFRAMBOISE, K., y VAHIDOV, R. (2008). Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research* (184), pp. 1140-1154.
- CHEIKHROUHOU, N., MARMIER, F., y AYADI, O. (2011). A collaborative demand forecasting process with event-based fuzzy judgements. *Computers y Industrial Engineering*, 61 (2).
- DANESE, P. (2007). Designing CPFR collaborations: insights from seven case studies. *International Journal of Operations y Production Management*, 27(2), pp.181-204.
- DIVAKAR, S., RATCHFORD, B.T., y VENKATESH, S. (2005). CHAN4CAST: A Multichannel, Multiregion Sales Forecasting Model and Decision Support System for Consumer Packaged Goods. *Marketing Science*, 24 (3), pp. 334-350.
- ECR EUROPE. (2001). *A guide to CPFR implementation*. Brussels: ECR Europe facilitated by Accenture.
- ERRASTI, A., CHACKELSON, C. y POLER, R. (2012). Definición de un sistema experto de para mejorar la gestión de inventarios: estudio de caso. *Dirección y Organización* (46), pp. 45-55.
- HUANG, C.-F., CHEN, Y.-S., y CHUNG, Y.-K. (2008). An Autonomous Collaborative Forecasting System Implementation –The First Step towards Successful CPFR System. *Engineering and Technology* (47), pp. 119-128.
- HAIR, J.F., BLACK, W.C., BABIN, B.J. y ANDERSON, R.E. (2010). *Multivariate Data Analysis*. Seventh Edition. Prentice Hall, Upper Saddle River, New Jersey.
- KUBDE, R., y BANSOD, S. (2010). Collaborative Planning Forecasting and Replenishment Initiatives: A State of Art. *Asia Journal of Industrial Engineering*, 2(3), pp. 89-104.
- LANGLEY, J. J., COYLE, J. J., GIBSON, B. J., NOVACK, R. A., y BARDI, E. J. (2009). *Managing Supply Chains: A logistics approach*. Mason, OH, USA: South-Western, Division of Thomson Learning.

- LO, T. S., LUONG, L. H., y MARIAN, R. M. (2006). *Holistic and Collaborative Demand Forecasting Process*. IEEE International Conference on Industrial Informatics, pp. 782-788.
- MAKRIDAKIS, S., WHEELWRIGHT, S. C., y HYNDMAN, R. J. (1998). *Forecasting Methods and Applications*. (Third Edition ed.). United States of America: John Wiley y Sons, Inc.
- PÉREZ, C. (2005). *Métodos estadísticos avanzados con SPSS*. Madrid: International Thomson Editores Spain Paraninfo, S.A.
- POLER, R., MULA, J., ORTÍZ, Á., y LARIO, F. C. (2006). *Un modelo de Empresa Virtual para la Gestión del Proceso de Previsión Colaborativa en Cadenas de Suministro*. X Congreso de Ingeniería de Organización. Valencia.
- POLER, R., MULA, J., y PEIDRÓ, D. (2009). Determinación de parámetros de modelos de previsión de demanda a través de los errores de acierto en horizonte rodante. *Dirección y Organización* (37), pp. 76-82.
- POLER, R., MULA, J., PEIDRÓ, D., y TOMÁS, J. V. (2006). *PROGNOS: Un sistema de soporte al proceso de previsión de la demanda*. X Congreso de Ingeniería de Organización, (págs. 1-10). Valencia.
- RAMANATHAN, U., y MUYLDERMANS, L. (2010). Identifying demand factors for promotional planning and forecasting: A case of a soft drink company in the UK. *Int. J. Production Economics* (128), pp. 538-545.
- STATACORP. (2011). *Stata Time-Series Reference Manual: Release 12*. En StataCorp, Stata: Release 12. Statistical Software (págs. 140-144). Texas: College Station.
- VICS. (2008). *Docs: Collaborative Planning, Forecasting y Replenishment (CPFR®)*. Recuperado en febrero de 2011, del sitio web VICS: [http://www.vics.org/docs/committees/CPFR\\_Whitepaper\\_Spring\\_2008-VICS.pdf](http://www.vics.org/docs/committees/CPFR_Whitepaper_Spring_2008-VICS.pdf).
- YANG, J. (2009). The determinants of supply chain alliance performance: an empirical study. *International Journal of Production Research*, 47(4), pp. 1055-1069.
- ZACHARIA, Z., NIX, N., y LUSH, R. (2009). An analysis of supply chain collaborations and their effect on performance outcomes. *Journal of Business Logistics*, 30(2), pp. 101-123.