



UNIVERSIDAD  
PABLO DE  
OLAVIDE  
SEVILLA



REVISTA DE MÉTODOS CUANTITATIVOS PARA  
LA ECONOMÍA Y LA EMPRESA (15). Páginas 45–64.  
Junio de 2013. ISSN: 1886-516X. D.L: SE-2927-06.  
URL: <http://www.upo.es/RevMetCuant/art.php?id=68>

## Selección y utilización de niveles de desagregación adecuados en pronósticos de series temporales: caso de estudio en una empresa de suscripción utilizando el proceso analítico jerárquico

ALVARADO VALENCIA, JORGE ANDRÉS

Departamento de Ingeniería Industrial

Pontificia Universidad Javeriana, Bogotá (Colombia)

Correo electrónico: [jorge.alvarado@javeriana.edu.co](mailto:jorge.alvarado@javeriana.edu.co)

GARCÍA BUITRAGO, JAVIER ALEXANDER

Departamento de Ingeniería Industrial

Pontificia Universidad Javeriana, Bogotá (Colombia)

Correo electrónico: [jgarcia.b@javeriana.edu.co](mailto:jgarcia.b@javeriana.edu.co)

### RESUMEN

El problema de la agregación o desagregación de series temporales para la realización de pronósticos se presenta frecuentemente en situaciones empresariales y econométricas. Este trabajo presenta una metodología novedosa para la selección de un nivel de desagregación adecuado de las series temporales a partir del cual realizar pronósticos. La metodología toma en cuenta criterios cualitativos –los recursos empresariales y el entorno de decisión– y cuantitativos –predictibilidad de las series y calidad de la información–, utilizando la metodología de toma de decisiones multicriterio conocida como el proceso analítico jerárquico (AHP) para llegar a una decisión final. Un caso de estudio en una empresa de suscripción muestra la utilidad de combinar AHP con técnicas de pronóstico de series de tiempo y la importancia de utilizar múltiples criterios en la selección de un nivel de desagregación adecuado.

**Palabras clave:** toma de decisiones multicriterio; análisis jerárquico; agregación de series temporales; pronósticos de series temporales; empresas de suscripción.

**Clasificación JEL:** C44; M11.

**MSC2010:** 90B50.

Artículo recibido el 5 de marzo de 2013 y aceptado el 8 de mayo de 2013.

**Selecting and Using  
an Adequate Disaggregation Level  
in Time Series Forecasting:  
A Study Case  
in a Subscription Business Model Company  
through the Analytic Hierarchy Process**

**ABSTRACT**

Hierarchical aggregation/disaggregation of time series in order to make forecasts is a frequent challenge in business and econometric scenarios. This work presents a novel approach for selecting an adequate time series disaggregation level as a starting point for making forecasts. The methodology combines qualitative criteria –such as business resources and decision environment– and quantitative criteria –such as information quality and forecastability– in a multicriteria decision making task which is addressed through the analytic hierarchy process (AHP) technique. Results from a study case in a subscription business model company show the usefulness of combining AHP and time series forecasting techniques and the importance of multicriteria decision-making in the task of selecting an adequate aggregation/disaggregation level.

**Keywords:** multicriteria decision making; analytical hierarchy process; time series aggregation; time series forecasting; subscription business model.

**JEL classification:** C44; M11.

**MSC2010:** 90B50.



## 1. INTRODUCCIÓN

El modelo de negocios por suscripción es aquel en el que se cobra un valor fijo por un periodo de tiempo para dar acceso a diferentes servicios que la empresa ofrece (Alt & Zimmermann, 2001). Una organización que posee un modelo de negocios por suscripción basa su negocio en un adecuado balance entre los costes de la suscripción y la utilización de los servicios que ofrece. Por ello, necesita destinar recursos importantes para la recopilación y análisis de la demanda de dichos servicios, los cuales son la fuente del costo de sus actividades. Pronosticar esta demanda es, por tanto, un elemento importante para la toma de decisiones.

Dependiendo del tipo y tamaño de la actividad de una organización, la elaboración y el análisis de sus costes y pronósticos se realiza a un nivel de agregación dado (Ewing, Sari & Soytaş, 2007; Man, 2004) y a este mismo nivel se realiza el proceso de toma de decisiones. Los niveles de agregación o desagregación pueden incluir diversos criterios tales como los geográficos (zonas de ventas), los organizacionales (áreas de la compañía, productos) y los temporales (trimestre, mes, año) o una combinación de estos. Generalmente se utilizan los criterios de clasificación contable establecidos por la contabilidad de costes (Oliver, 2006 p. 16) y a criterio del tomador de decisiones que define un determinado nivel de agregación o desagregación.

Determinar el nivel de detalle adecuado de desagregación de la demanda no es una decisión directa o fácil. La cantidad de series temporales a pronosticar no representa una limitante para el uso de métodos cuantitativos en los pronósticos, por tanto, la posibilidad de trabajar a múltiples niveles de desagregación para un mismo problema es operativa y técnicamente posible. Sin embargo, el proceso de interpretación y análisis de un gran número de series temporales resulta oneroso y poco productivo si el nivel de desagregación no es el adecuado para la toma de decisiones. Por lo menos tres elementos más son importantes para determinar cómo de adecuado es ese nivel: un análisis del entorno de la toma de decisiones, un análisis de los recursos disponibles y un análisis de la pronosticabilidad de la desagregación escogida.

Tras la selección del nivel adecuado de detalle, el análisis de series temporales permite la generación de pronósticos confiables para un fenómeno donde los datos históricos podrían explicar o influir sobre eventos futuros. Las técnicas de pronóstico de series temporales, siempre y cuando estén en un marco estable, son una excelente herramienta de predicción (Armstrong, 2006; Uddameri, 2007).

Los resultados de las predicciones hechas a partir del análisis de una serie de tiempo a un nivel de desagregación dado pueden utilizarse como criterio para la selección misma del nivel de desagregación que mejor se adecúe a las necesidades del tomador de decisiones, pues proporcionan información sobre la predictibilidad de las series, la estabilidad del entorno de predicción y la calidad de la información en cada nivel de detalle.

Dados estos antecedentes, la toma de decisiones multicriterio basada en una combinación de criterios cualitativos –basados en el entorno de decisión– con criterios cuantitativos –basados en la información de las series temporales– resulta clave para la selección del nivel adecuado de agregación o desagregación en la toma de decisiones requerida por una empresa. Posteriormente, el uso de las herramientas automatizadas para la generación de pronósticos en el nivel apropiado de toma de decisiones disminuye el trabajo sin perder precisión. La aplicación conjunta de las técnicas de toma de decisiones multicriterio y pronósticos de series temporales representa el aporte fundamental de este artículo, que consiste en la propuesta y desarrollo de una metodología de toma de decisiones multicriterio para determinar un nivel adecuado de desagregación de una variable de costo que posteriormente será pronosticada como entrada en el proceso de toma de decisiones de una organización que presta servicios a través de suscripción en Colombia.

En la revisión de literatura, se encontraron múltiples aplicaciones de técnicas multicriterio (Manfren, Caputo & Costa, 2011; Sporicic, Landekic, Lovric, Bogdan & Segotic, 2010) y metodologías de pronóstico de variables a partir de series temporales (Giot & Petitjean, 2011; Velásquez-Henao, Franco-Cardona, & Olaya-Morales, 2012); sin embargo, en ninguno de ellos se encuentra aplicación conjunta o en serie de estas técnicas. La gran oportunidad radica en que no se han aplicado metodologías para determinar qué nivel de desagregación resulta satisfactorio de entre el total de posibles niveles de desagregación en un problema de pronósticos para posteriormente realizar pronósticos que puedan ser útiles para la toma de decisiones a la luz de múltiples criterios organizacionales.

## **2. SITUACIÓN ACTUAL**

El problema de la agregación y desagregación de series temporales ha sido ampliamente estudiado. Se han realizado aplicaciones prácticas tanto en empresas (Chen & Blue, 2010; Danese & Kalchschmidt, 2011) como en el análisis de información econométrica (Espasa, Senra & Albacet, 2002; Marcellino, Stock & Watson, 2003), así como desarrollos teóricos (R. J. Hyndman, Ahmed, Athanasopoulos & Shang, 2011). La necesidad de encontrar una metodología adecuada para realizar pronósticos a diferentes niveles partiendo de un nivel base para su agregación o desagregación ha sido una solicitud continua en el ámbito científico de la economía y los negocios (Fliedner, 2001; Kahn, 1998). Sin embargo, la forma de abordar el problema en la revisión de la literatura no ha tenido en cuenta la facilidad de uso del sistema de pronósticos, y los métodos propuestos están dirigidos básicamente a reconciliar pronósticos agregados y desagregados basados únicamente en criterios relativos a la predictibilidad de las series temporales.

Más allá de la predictibilidad, la facilidad de uso de un sistema de pronósticos depende de por lo menos tres grupos adicionales de factores: la disponibilidad y uso de los recursos para pronosticar, las características de la información disponible y el entorno de la decisión.

En relación con las características de la información disponible, y de acuerdo con encuestas a profesionales de los pronósticos, dos de los factores más importantes que llevan a la no realización de pronósticos por métodos cuantitativos son la escasez de información y la falta de precisión en los pronósticos (Sanders & Manrodt, 2003). De otra parte, las razones que conducen a las empresas al uso de métodos cuantitativos para sus pronósticos son la necesidad de pronosticar un gran número de productos, la disponibilidad de datos de calidad y la existencia de una demanda estable (Danese & Kalchschmidt, 2011; S. Makridakis, Wheelwright & Hyndman, 1997; Wright, Lawrence & Collopy, 1996). Entre los recursos necesarios que limitan el nivel de agregación a escoger están la oportunidad de la información y el costo. Estudios anteriores han evaluado la importancia de esos dos factores en la evaluación de un sistema de información de apoyo a los pronósticos (Winklhofer & Diamantopoulos, 2002).

El entorno de la decisión es un tercer factor de gran importancia al elegir un nivel de desagregación. Contar con poca o mucha información no necesariamente asegura que la salida del proceso resulte en la mejor decisión posible y puede ser que el tomador de decisiones no comprenda adecuadamente el entorno de la decisión por haber elegido un nivel de análisis inadecuado (Lederer & Smith, 1988). Diferentes roles dentro de la organización pueden requerir diferentes niveles de agregación de los pronósticos. Es por ello que se espera que los sistemas de soporte a la realización de pronósticos tengan diversos niveles de agregación (Smith & Mentzer, 2010). Asimismo, la capacidad para entender y valorar las situaciones de negocio y los posibles cursos de acción futuros a partir del nivel de agregación elegido para los pronósticos es quizás tan importante como la calidad misma de los pronósticos (Hogarth & Makridakis, 1981; Makridakis & Taleb, 2009; Tsoukiàs, 2008).

Dado que se presentan diferentes factores con diferentes posibles ponderaciones, analizar la selección del nivel de desagregación requiere una metodología de toma de decisiones multicriterio. La toma de decisiones multicriterio o análisis multicriterio es un conjunto de técnicas que contienen un conjunto de opciones de decisión que deben ser ponderadas, un conjunto de criterios típicamente medidos en diferentes unidades y un conjunto de medidas de desempeño para cada opción de decisión contra cada criterio. Existen múltiples técnicas para solucionar los problemas de toma de decisiones multicriterio (en adelante MCA). Entre las diversas técnicas MCA se escogió el proceso analítico jerárquico (en adelante AHP). El AHP es un procedimiento sistemático para la representación de los elementos de cualquier problema de forma jerárquica. Organiza la racionalidad descomponiendo un problema en sus partes constitutivas más pequeñas y luego guía a los tomadores de decisiones a través

de una serie de juicios de comparación por pares para expresar la fuerza relativa o la intensidad del impacto de los elementos dentro de la jerarquía. Estos juicios son convertidos a una escala numérica que facilita su interpretación (Saaty & Vargas, 2001). El AHP permite determinar una jerarquía entre los criterios adoptados por el tomador o tomadores de decisiones, permitiendo encontrar un balance entre los factores o variables que afectan el fenómeno a evaluar. Se ha probado que la técnica AHP es una técnica útil de toma de decisiones por encima de metodologías más simples de trabajo (Ishizaka, Balkenborg & Kaplan, 2011). De hecho, la técnica AHP es una de las más utilizadas en su aplicación práctica. Ha sido empleada en variedad de áreas, incluyendo planificación, asignación de recursos y resolución de conflictos, particularmente cuando se requiere combinar criterios cuantitativos y cualitativos en la toma de decisiones (Subramanian & Ramanathan, 2012). Esta metodología es suficientemente flexible para ser usada en combinación con otras herramientas de toma de decisiones (Vaidya & Kumar, 2006). Las principales herramientas con las que se la ha combinado incluyen programación matemática, QFD, metaheurísticas, análisis DOFA y DEA (Ho, 2008). Sin embargo, existe una escasez significativa en la investigación y aplicación de AHP en combinación con áreas de pronóstico (Subramanian & Ramanathan, 2012).

### 3. METODOLOGÍA

#### 3.1. Metodología del proceso analítico jerárquico

Existen  $n$  criterios a comparar. Sea  $w_i$ =peso dado al criterio  $i$ . Entonces la matriz de comparación por pares es:

$$A = \begin{bmatrix} \frac{w_1}{w_1} & \dots & \frac{w_1}{w_n} \\ \frac{w_1}{w_1} & \dots & \frac{w_n}{w_n} \\ \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \dots & \frac{w_n}{w_n} \\ \frac{w_1}{w_1} & \dots & \frac{w_n}{w_n} \end{bmatrix} \quad (1)$$

En esta matriz se realiza una comparación relativa de los pesos de los diferentes criterios. La matriz solo admite valores positivos y satisface la propiedad de reciprocidad:

$$a_{ij} = 1/a_{ji} \quad (2)$$

Considérese el sistema de  $n$  ecuaciones:

$$Aw^T = \Delta w^T \quad (3)$$

donde  $\Delta$  es un número desconocido y  $w^T$  es un vector columna  $n$ -dimensional. Para cualquier número  $\Delta$ , (1) siempre tiene la solución trivial  $w=[0, 0, \dots, 0]$ . Si  $A$  es la matriz de comparación por pares de una persona consistente que toma decisiones, entonces la única solución no trivial para (3) es:

$$\Delta = n \text{ y } w = [w_1, w_2, \dots, w_n] \quad (4)$$

Esto muestra que para una persona consistente que toma decisiones, las ponderaciones  $w_i$  se pueden obtener de la única solución no trivial para (3). Ahora, si quien toma la decisión no es perfectamente consistente, resulta lo siguiente: sea  $\Delta_{max}$  el número más grande para el cual (3) tiene una solución no trivial (llámese esta solución  $w_{max}$ ); si las comparaciones de quien toma la decisión no se desvían mucho de la consistencia perfecta, se esperaría que  $\Delta_{max}$  estuviera cerca de  $n$  y  $w_{max}$  estuviera cerca de  $w$ .

Entonces, para el grupo de expertos se realizan las comparaciones pareadas entre criterios y se procede a evaluar la consistencia del grupo experto con el fin de obtener una solución tan cercana como se pueda a  $w$ . Una vez obtenidas las comparaciones, el paso siguiente es encontrar un vector de normalización  $v$  a partir de la matriz de comparaciones pareadas  $A$ . Esto se realiza dividiendo la media geométrica de cada fila  $i$  de la matriz  $A$  entre la suma de todas las medias geométricas de las filas de la matriz  $A$ . Posteriormente, es necesario garantizar la consistencia de la solución. La consistencia es el grado de equilibrio resultante entre las comparaciones pareadas. No siempre puede existir una consistencia perfecta; por ello, el modelo AHP ofrece un método para medir el grado de consistencia de cada una de las matrices de comparaciones pareadas, mediante la razón de consistencia ( $R.C$ ):

$$R.C. = \frac{I.C.}{I.A.} \quad (5)$$

donde  $I.C.$  es el índice de consistencia de  $A$  e  $I.A.$  es el índice de consistencia obtenido cuando las matrices son generadas de forma aleatoria. Para obtener  $I.C.$  se calcula:

$$I.C. = \frac{\lambda_{max} - n}{n - 1} \quad (6)$$

El valor de  $\lambda_{max}$  se calcula usando el vector de normalización  $v$  y haciendo

$$Av^T = \bar{\lambda}_i \quad (7)$$

Y luego se calcula a partir de (7):

$$\lambda_{max} = \sum_{i=1}^n \bar{\lambda}_i = \sum_{i=1}^n \left( \sum_{j=1}^n a_{ij} v_j \right) \quad (8)$$

El Índice de Consistencia Aleatoria ( $I.A.$ ) a utilizar en (5) depende del número de elementos a comparar. Los valores con los que se debe comparar se han encontrado de forma empírica y están basados en lo propuesto por Saaty & Kearns (1985) . La Tabla 1 presenta esos valores.

Tamaño de la matriz	1	2	3	4	5	6	7	8	9	10
I.A.	0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49

Tabla 1. Índice de consistencia aleatoria. Fuente: Saaty & Kearns (1985).

### 3.2. Desarrollo del caso de estudio

La metodología se basa en usar las características de las series temporales como *input* cuantitativo de la decisión, y posteriormente integrar la realización de pronósticos de las mismas. La empresa objeto de estudio en Colombia es una compañía con más de 25 años en el mercado, que presta servicios de forma directa y a través de una red de terceros en todo el territorio nacional y cuenta con más de 8.000 empleados. De los servicios que presta, posee el 60% del mercado y es reconocida como líder en la prestación de estos servicios en el país, ofreciéndolos con los más altos estándares de calidad. El servicio que presta es bajo el modelo de negocios de suscripción. El comportamiento del costo total presenta estacionalidad y su tendencia durante los últimos tres años ha tenido un comportamiento similar al de la inflación del país y la del sector al que pertenece. Actualmente se utiliza el pronóstico de series temporales del valor agregado (País) y luego, mediante criterios contables, se realiza la desagregación mediante ponderación de las participaciones de períodos contables anteriores a criterio de los expertos que toman decisiones, –quienes realizan cambios a las ponderaciones resultantes– para finalmente establecer el plan estratégico para el siguiente período. Como resultado de este ejercicio se obtiene el presupuesto de costo para el siguiente período.

El proceso de toma de decisiones a partir de la información de costes utilizado actualmente podría no ser satisfactorio, pues se tiene incertidumbre sobre el método de desagregación utilizado, dado que los diferentes niveles de detalle podrían tener dinámicas diferentes a las pronosticadas a partir de los datos agrupados.

Para desarrollar la metodología propuesta, se conformó un grupo de expertos que conocían el problema de estudio y que normalmente toman decisiones sobre el proceso a nivel estratégico y táctico. Las características de este grupo se aprecian en la Tabla 2.

Cargo	Género	Edad	Rol
Subgerente	Femenino	39	Toma decisiones administrativas y de servicio sobre regionales, proveedores y ciudades.
Subgerente	Masculino	34	Tiene influencia y responsabilidad nacional sobre el costo de regionales, proveedores y ciudades.
Coordinador	Masculino	38	Realiza el presupuesto de costes a nivel nacional.

Tabla 2. Características de los evaluadores.

Este grupo de expertos desarrolló la metodología como trabajo en equipo; es decir, las evaluaciones y análisis se lograron mediante lluvia de ideas (para las definiciones de criterios y alternativas) y mediante consenso (para las comparaciones pareadas de criterios, alternativas y análisis de resultados). Las capas de desagregación seleccionadas surgieron como resultado de la revisión de la forma como es analizada la información de costo tradicionalmente, de acuerdo a la empresa de estudio. La Tabla 3 presenta las posibles desagregaciones o niveles de detalle sobre los que se podía realizar la estimación o pronóstico de costes.

Tipo	Combinación	Número de series temporales (k)
Agregada	País	1
Pura	Regional	5
	Ciudad	39
	Proveedor	6.000
	Tipo	10
Combinada	Regional x Tipo de servicio	58
	Ciudad x Proveedor	6.111
	Ciudad x Tipo de servicio	310
	Ciudad x Proveedor x Tipo de servicio	14.791

Tabla 3. Número de series temporales por capa de desagregación.

El modelo AHP requiere establecer la jerarquía de criterios y alternativas a utilizar para la selección de la mejor alternativa. Los criterios seleccionados son de dos tipos: cualitativos y cuantitativos. Los cualitativos serán evaluados por los tomadores de decisiones, mientras que los cuantitativos son parámetros que describen propiedades de los datos que surgirán de un análisis de las series temporales  $k$ , para cada nivel de agregación  $j$  y que son de interés dada la naturaleza del estudio. Una vez establecidos los criterios y las alternativas, se realizaron comparaciones pareadas entre criterios y alternativas para cada criterio por parte del grupo de expertos. Posteriormente se establecieron los pesos relativos teniendo en cuenta la normalización y consistencia explicadas anteriormente. Los índices de consistencia aleatorios a utilizar son el de seis elementos (1,24) para la evaluación de criterios y el de nueve elementos (1,45) para la evaluación de alternativas.

### 3.3. Desarrollo de los criterios de evaluación

El grupo de expertos definió seis criterios importantes para ser analizados:

1. Oportunidad. Corresponde al intervalo de tiempo existente entre el análisis de la información y el momento de materializar la decisión resultante del análisis de los datos a este nivel de desagregación.

2. Toma de decisiones. Determina si la gestión del proceso normalmente permite la intervención a este nivel de desagregación.

3. Claridad. Determina si a este nivel de desagregación se mantiene el entendimiento y la comprensión global de lo que está sucediendo en el entorno de la decisión.

4. Impacto. Determina si realizar el análisis a este nivel de desagregación para tomar decisiones implica una cantidad (monetaria, horas, recursos) que amerite realizar el análisis sin limitar la capacidad para tomar decisiones.

5. Calidad de la información. Se define como la proporción de datos nulos dado el nivel de desagregación de la alternativa  $k$ . Los datos pueden ser nulos porque en realidad no se presentó costo o por faltantes en la información, pero no se sabe cuál es la causa para cada dato nulo. La presencia de datos nulos o faltantes genera dificultades específicas para el pronósticos de series temporales (Syntetos, Nikolopoulos, Boylan, Fildes & Goodwin, 2009). Este valor de calidad de información se calcula como el complemento de la proporción de datos nulos (o faltantes) sobre el total de datos para cada serie de tiempo al nivel de agregación  $j$ :

$$\text{Calidad de información}_{kj} = 1 - \frac{\sum_{k=1}^K \sum_{t=1}^n \text{nulos}_{ktj}}{k*t} \quad (9)$$

donde:

$\text{nulos}_{ktj}$ : 1 si el dato es nulo para la serie  $k$  en el momento  $t$  en el nivel de agregación  $j$ , o 0 si el dato es no nulo;

$k=1,2,\dots,K$  (Número total de series temporales para el nivel de desagregación);

$t=1,2,\dots,36$  (Número de datos por cada serie de tiempo, para el caso, 36 meses ( $n=36$ )).

6. Predictibilidad. Se define como la medida del error de un pronóstico de línea base al nivel de desagregación  $j$  de la alternativa  $k$ . Cada serie de tiempo cuenta con información de 36 meses (3 años). Para desarrollar la medida, se realizó división de cada una de estas series para obtener una serie de tiempo de entrenamiento y otra de validación. El tamaño de la serie de tiempo de entrenamiento es de 24 meses y la de validación de 12 meses.

La selección del parámetro de predictibilidad se basó en un análisis exploratorio de las series temporales, donde se detectaron altas asimetrías de los resultados de error de las series temporales. Para ello se tomaron los datos de los 36 meses para todos los niveles de desagregación y se realizaron predicciones con el modelador experto del paquete estadístico utilizado (SPSS), midiendo el MAPE (error porcentual promedio) de cada serie  $k$  para el nivel de agregación  $j$  dado, donde

$$\text{MAPE}_{KJ} = 100\% \sum_{t=1}^{n_{kj}} \left| \frac{(A_{t_{kj}} - F_{t_{kj}})}{A_{t_{kj}}} \right| \quad (10)$$

$A$  es el valor actual para el período  $t$  de la serie  $k$  al nivel de desagregación  $j$ ;

$F$  es el valor pronosticado para el período  $t$  de la serie  $k$  al nivel de desagregación  $j$ ;  
 $t=1,2,\dots,N$  (número total de períodos de la serie de tiempo);  
 $k=1,2,\dots,K$  (número de series temporales al nivel de desagregación);  
 $j=1,2,\dots,M$  (número de niveles de desagregación posibles).

Para cada nivel se calcularon los coeficientes de asimetría y curtosis de los  $MAPE_{kj}$ . Estos resultados se aprecian en la Tabla 4.

Nivel de desagregación	Nº de series temporales ( $k$ )	Coficiente de asimetría	Curtosis
País	1	No disp.	No disp.
Regional	5	-1,52	2,01
Ciudad	39	5,66	33,64
Proveedor	6.000	18,44	533,34
Tipo	10	3,14	9,91
Regional x Tipo de servicio	58	3,71	12,91
Ciudad x Proveedor	6.111	4,55	20,77
Ciudad x Tipo de servicio	310	6,22	47,02
Ciudad x Proveedor x Tipo de servicio	14.791	33,03	1422,21

Tabla 4. Asimetría y curtosis de la base de datos de entrenamiento y validación de los  $MAPE_{kj}$  (36 meses).

El coeficiente de asimetría indica que la distribución de los  $MAPE_{kj}$  es asimétrica en todos los niveles desagregados, lo cual indica que algunas series temporales presentan valores extremadamente altos en sus  $MAPE_{kj}$ ; lo mismo sucede con la curtosis, señal de una cola larga de frecuencias pequeñas debido a la amplia gama de resultados. Tras este análisis, se decide utilizar la mediana de los  $MAPE_{kj}$  para cada nivel de agregación  $j$  ( $MdMAPE_j$ ) como parte de la medida de predictibilidad para cada nivel de agregación por dos razones. Primero, expresa porcentualmente el error y, de ese modo, es posible comparar series temporales a diferentes niveles de desagregación; segundo, no se ve afectada por valores extremos, como si lo estaría el promedio de los errores porcentuales.

$$MdMAPE_j = \text{Mediana}(MAPE_{1j}, MAPE_{2j}, \dots, MAPE_{Kj}) \quad (11)$$

$j=1,2,\dots,m$

Las series temporales de las  $k$  alternativas fueron procesadas en el programa SPSS versión 20 y se utilizaron los siguientes criterios:

- Se utilizó el modelizador experto, que incluye modelos de suavización exponencial y modelos ARIMA.
- La identificación de puntos atípicos no se utiliza.
- No se realiza transformación de los datos.

d) El modelo se construye con los datos de entrenamiento (24) meses y se realiza la predicción para la base de datos de validación (12) meses.

Para la matriz de predictibilidad, se utilizó el  $MdMAPE_j$  calculado con el conjunto de  $MAPE_{kj}$  de las series temporales obtenidos a partir de la base de validación (12 meses) dado que resulta más exigente construir el modelo con la base de entrenamiento y probar el modelo con datos reales, de modo que se evite el sobre ajuste del modelo.

Al comparar los resultados del  $MdMAPE_j$  de la base total (Entrenamiento + Validación) con los resultados del  $MdMAPE_j$  de la base de solo validación se encuentra que un nivel de desagregación presenta un gran incremento (Ciudad por Proveedor), 6 niveles de desagregación presentan un incremento leve (País, Regional, Ciudad, Tipo de servicio, Regional por Tipo de servicio, Ciudad por Proveedor por Tipo de servicio). 1 nivel se mantiene estable (Proveedor) y 1 nivel disminuye (Regional por Tipo de servicio). Esto hace que los modelos de series temporales sean posiblemente buenos predictores y que los pronósticos sean útiles como información de entrada para el proceso de toma de decisiones. El resultado del  $MdMAPE_j$  sobre la base de validación utilizada como criterio de predictibilidad para cada una de las series temporales  $k$  y los 12 meses de validación se presenta en la Tabla 5.

Parámetro	País	Regional	Ciudad	Proveedor	Tipo	Regional x Tipo de servicio	Ciudad x Proveedor	Ciudad x Tipo de servicio	Ciudad x Proveedor x Tipo de servicio
Mediana	3,550	7,453	29,314	42,046	7,511	10,871	42,664	39,934	51,513

Tabla 5.  $MdMAPE_j$  de la base de datos de validación (12 meses).

Finalmente, para que se premie un valor alto sobre uno bajo en los cálculos pareados de la metodología AHP, se define la predictibilidad como el complemento de la mediana de los  $MAPE_{kj}$  para las  $k$  series en el nivel de desagregación  $j$  dado:

$$predictibilidad_j = 100 - MdMape_j \quad (12)$$

#### 4. RESULTADOS

El vector de resultados para las alternativas planteadas, organizados por peso desde el mayor hasta el menor, se presenta en la Tabla 6. La mejor alternativa de desagregación es Tipo de servicio, la cual obtuvo una puntuación de 0,1639. Lo anterior indica que la diferenciación por naturaleza del servicio es la más importante para tomar decisiones. Esto es relevante porque para la empresa objeto de estudio,

el servicio en su gran mayoría tiene un comportamiento que es uniforme independientemente de los otros niveles de desagregación como la geografía o el Proveedor.

Alternativa	Tipo desagregación	Cantidad de series	Puntuación	Jerarquía
Tipo de servicio	Pura	10	0,1639	1
Regional	Pura	5	0,1621	2
País	No desagregada	1	0,1374	3
Ciudad	Pura	39	0,1291	4
Regional por Tipo de servicio	Combinada	58	0,1116	5
Ciudad por Tipo de servicio	Combinada	310	0,0851	6
Proveedor	Pura	6.000	0,0754	7
Ciudad por Proveedor	Combinada	6.111	0,0684	8
Ciudad por Tipo de servicio por Proveedor	Combinada	14.791	0,0670	9

Tabla 6. Vector de resultados para las alternativas planteadas (organizado de mayor a menor).

La segunda mejor alternativa de desagregación es la regional, la cual obtuvo una puntuación de 0,1621, tan solo 1,1% por debajo de la primer alternativa, lo cual indica que también es interesante realizar la desagregación por regional. Adicionalmente, la empresa objeto de estudio define directrices nacionales con algunas variaciones por región e incluso por ciudad, sobre todo para las ciudades cabeceras de regional. La tercera mejor alternativa de desagregación es la no desagregación, es decir trabajar con los datos agregados de país, el cual representa el enfoque tradicionalmente utilizado. Sin embargo, la distancia frente a la primera alternativa es amplia, lo cual indica que efectivamente cualquiera de los dos primeros criterios resultaría más aconsejable que la situación actual.

Las cinco primeras alternativas obtuvieron una puntuación superior a 0,10. Entre ellas se encuentran tres alternativas de desagregación puras (Tipo de servicio, Regional y Ciudad), la alternativa de no desagregación (País) y solo una alternativa de desagregación combinada (Regional por Tipo de servicio). De lo anterior se puede observar que las alternativas más desagregadas (que cuentan con mayor cantidad de series temporales) obtuvieron en general bajas puntuaciones, y que la única alternativa de desagregación combinada con una puntuación mayor a 0,10 es precisamente la resultante de la interacción de las dos primeras alternativas con mayores puntuaciones (Regional por Tipo de servicio). En consecuencia, la alternativa Regional por Tipo de servicio (conformada por 58 series temporales) podría utilizarse como desagregación de soporte para ayudar a interpretar los resultados obtenidos por el nivel de desagregación preferido (Tipo de servicio) de modo que complemente el análisis.

Por otra parte, los resultados para los criterios, ordenados de mayor a menor, se aprecian en la Tabla 7.

Criterio	Ponderación
Calidad de la información	0,3716
Predictibilidad	0,1846
Toma de decisiones	0,1571
Claridad	0,1243
Impacto	0,1117
Oportunidad	0,0506

Tabla 7. Vector de resultados para los criterios.

Los criterios cuantitativos obtuvieron pesos mayores que los criterios cualitativos, siendo el criterio *Calidad de la información* el primero con un peso de 0,3716 (Casi dos veces el valor del segundo). Para el criterio *Calidad de la información*, la alternativa *Tipo de servicio* tiene un valor de 95,23% mientras que la alternativa *Regional* tiene un resultado de 100%; es decir que para este criterio la alternativa con mayor puntuación final (*Tipo de servicio*) tiene un menor resultado.

Para el criterio *Predictibilidad*, la alternativa *Tipo de servicio* tiene un resultado de 92,49 mientras que la alternativa *Regional* tiene un resultado de 92,55, lo que las hace casi iguales. Nótese entonces que a pesar de que la alternativa *Regional* tenía el mayor valor para el criterio de mayor peso (*Calidad de información*) y que estaba muy de cerca del primero en la matriz del segundo criterio (*Predictibilidad*) no resultó en primer lugar en la valoración final. Lo anterior es debido a que en la evaluación de los demás criterios siempre le fue mejor a la alternativa *Tipo de servicio*. De esto se puede concluir que el criterio de mayor ponderación es importante pero no necesariamente es el único relevante, porque la suma de los criterios con menor ponderación puede llegar a cambiar el análisis de resultados. La alternativa seleccionada –*Tipo de servicio*– consta de 10 series temporales y una vez seleccionada se realiza el pronóstico de línea base de acuerdo con las especificaciones establecidas. Los modelos seleccionados para las 10 series temporales se presentan en la Tabla 8.

Tipo de servicio	Tipo de modelo
Tipo de servicio 1	Estacional simple
Tipo de servicio 2	Multiplicativo de Winters
Tipo de servicio 3	Aditivo de Winters
Tipo de servicio 4	Aditivo de Winters
Tipo de servicio 5	Aditivo de Winters
Tipo de servicio 6	Aditivo de Winters
Tipo de servicio 7	Aditivo de Winters
Tipo de servicio 8	Estacional simple
Tipo de servicio 9	Simple
Tipo de servicio 10	Aditivo de Winters

Tabla 8. Resultados del modelo de pronóstico de línea base para Tipo de servicio.

Todos los modelos de línea base son de tipo estacional, presentan buenos resultados de correlación (R corregida > 0,73) y, lo más importante, pueden ser mejorados a partir de este resultado mediante técnicas avanzadas de series temporales, antes de comenzar los procesos de agregación / desagregación necesarios.

La realización de un análisis de sensibilidad es importante en cualquier técnica de toma de decisiones multicriterio y el AHP no es la excepción. Por ello se realizaron dos tipos de análisis de sensibilidad. Primero, se revisó la sensibilidad del criterio de predictibilidad si se modificaba el parámetro utilizado para medir la misma y posteriormente se revisó la sensibilidad de la decisión a cambios en los pesos de los criterios.

En lo referente al cambio del parámetro de medición de la predictibilidad, se utilizaron como fuentes de posibles alternativas las propuestas por dos artículos específicos de la literatura (Hyndman & Anne, 2006; Temurshoev, Webb & Yamano, 2011). Entre las propuestas de estos autores, se seleccionaron tres posibles parámetros de interés. Primero, se seleccionó un parámetro que ponderara el MAPE de acuerdo al valor real que tuviera la serie. Esta ponderación se consideró puesto que la importancia de la precisión puede variar de acuerdo a la importancia misma de la serie en volumen. Por ello se escogió el  $WAPE_j$ , donde:

$$WAPE_j = \left( \frac{A_{tkj}}{\sum_{k=1}^K \sum_{t=1}^{n_{kj}} A_{tkj}} \right) * \left( \left| \frac{A_{tkj} - F_{tkj}}{A_{tkj}} \right| \right) \quad (13)$$

Y posteriormente se definió la predictibilidad para este parámetro como:

$$predictibilidad_{wapej} = 1 - WAPE_j \quad (14)$$

En segundo lugar se buscó un parámetro que fuese una medida de precisión relativa a un pronóstico ingenuo (MASE), porque de ese modo se compara la precisión con una línea ingenua, siendo:

$$MASE_k = \frac{1}{n_{kj}} * \sum_{t=1}^{n_{kj}} \left| \frac{(A_{tkj} - F_{tkj})}{\sum_{t=2}^{n_{kj}} (A_{tkj} - A_{(t-1)kj}) / (n-1)} \right| \quad (15)$$

Una vez obtenidos los  $MASE_K$ , se procedió a utilizar la mediana de los mismos para cada agregación  $j$  ( $MdMASE_j$ ) y a restarla de 1 para usarla como medida de predictibilidad:

$$predictibilidad_{masej} = 1 - Mediana(MASE_{1j}, MASE_{2j}, \dots, MASE_{Kj}) \quad (16)$$

En tercer lugar se seleccionó un parámetro que utilizara criterios basados en información. El más conocido de ellos es el criterio de información de Aikake (AIC), el cual se obtuvo para cada serie  $k$ . Posteriormente se procedió a calcular la mediana de los  $AIC_K$  para el nivel de agregación  $j$  ( $MdAIC_j$ ) y a usar el recíproco de la misma como medida de predictibilidad para premiar los valores más altos.

$$predictibilidad_{AICj} = \frac{1}{MdAIC_j} \quad (17)$$

La Tabla 9 presenta los valores de estos parámetros de predictibilidad para cada nivel de agregación  $j$ .

Nivel de desagregación	Predictibilidad WAPE <sub>j</sub>	Predictibilidad MASE <sub>j</sub>	Predictibilidad AIC <sub>j</sub>
País	0,964	0,426	0,0020
Regional	0,960	0,471	0,0022
Ciudad	0,955	0,316	0,0025
Proveedor	0,786	0,241	0,0034
Tipo	0,945	0,326	0,0021
Regional x Tipo de servicio	0,938	0,370	0,0025
Ciudad x Proveedor	0,786	0,241	0,0036
Ciudad x Tipo de servicio	0,689	0,302	0,0030
Ciudad x Proveedor x Tipo de servicio	0,757	0,243	0,0037

Tabla 9. Parámetros de predictibilidad alternativos por nivel de desagregación (sin normalizar).

Al aplicar estos valores de predictibilidad normalizados para las alternativas planteadas, se encuentra que hay una cierta sensibilidad al parámetro de predictibilidad, si bien no es muy grande, es decir, hay robustez al cambio de parámetro de predictibilidad. En particular, el conjunto de cinco alternativas identificadas como superiores dentro de las alternativas planteadas siguen manteniéndose; y hay un único cambio posicional dentro de esas cinco alternativas para cada parámetro de predictibilidad. Al utilizar WAPE y MASE, las dos primeras posiciones se intercambian, pasando a ser preferida la alternativa *Regional* sobre la alternativa *Tipo de servicio*; y al utilizar AIC las posiciones tercera y cuarta se intercambian, pasando a ser preferida la alternativa *Ciudad* sobre la alternativa *País*.

Para evaluar la sensibilidad de la decisión a cambios en los pesos de los criterios se tomó como referencia la propuesta de análisis elaborada por Triantaphyllou & Sánchez (1997). En este estudio se propone un método para determinar los criterios y alternativas que son más sensibles a producir cambios en los resultados de los modelos de toma de decisiones multicriterio. Para el caso de análisis de esta sensibilidad para los criterios utilizados, se utilizaron los modelos de suma ponderada y de producto ponderado. En este caso se define un grado crítico del criterio, que es el mínimo cambio porcentual que debe sufrir la ponderación del criterio para generar cambios en el orden de preferencia de las alternativas. También se define un criterio de sensibilidad del coeficiente, que es el recíproco del grado crítico de criterio.

Los resultados obtenidos para el caso utilizando los dos métodos se pueden observar en las Tablas 10 y 11.

Modelo de suma ponderada		
Sensibilidad	Grado crítico del criterio (Min $\delta$ )	Criterio de sensibilidad del coeficiente
Oportunidad	15,67	6,38%
Toma de decisiones	34,64	2,89%
Claridad	36,65	2,73%
Impacto	57,68	1,73%
Predictibilidad	57,78	1,73%
Cantidad/Calidad de la información	65,56	1,53%

Tabla 10. Sensibilidad de los criterios por el método de suma ponderada.

Modelo de producto ponderado		
Sensibilidad	Grado crítico del criterio (Min $\delta$ )	Criterio de sensibilidad del coeficiente
Oportunidad	68,88	1,45%
Claridad	78,74	1,27%
Cantidad/Calidad de la información	104,24	0,96%
Toma de decisiones	211,26	0,47%
Impacto	252,63	0,40%
Predictibilidad	303,87	0,33%

Tabla 11. Sensibilidad de los criterios por el método de producto ponderado.

Los resultados obtenidos por el modelo inicial son más sensibles a variaciones en el peso del criterio *oportunidad*, sin embargo todos los criterios resultaron sensibles para algún porcentaje de cambio en sus ponderaciones. Una observación importante es que los criterios cuantitativos, a pesar de ser menos en cantidad que los criterios cualitativos, no son por completo irrelevantes ni podrían eliminarse del modelo sin afectarlo, si bien su sensibilidad es inferior a la de los criterios cualitativos.

## 5. CONCLUSIONES

La metodología presentada permite la selección de un nivel de desagregación de datos para efectuar predicciones para la organización que toma en cuenta no solo el criterio de predictibilidad usual en este tipo de trabajos sino también otros criterios cuantitativos –como la calidad de los datos– y los combina con criterios cualitativos relacionados con la naturaleza de la toma de decisiones en una empresa. En ese sentido, es una metodología más integral que las existentes hasta el momento, realiza un balance entre los diferentes criterios y genera nuevas miradas al uso y manejo de la información dentro de la empresa. Una extensión de esta metodología al problema de escoger un nivel de desagregación en la

predicción de variables econométricas es el siguiente paso de investigación, así como su utilización en más casos de estudio.

Los resultados obtenidos en el caso de estudio evidencian que la consideración de más de un criterio en la toma de decisiones respecto al nivel de desagregación de las series temporales es relevante; normalmente los tomadores de decisiones en el día a día solo consideran un criterio –el que es más importante para ellos–. Si bien los criterios cuantitativos resultaron ser los más importantes, el peso de los criterios cualitativos finalmente inclinó la balanza por una alternativa de desagregación diferente, enfatizando la conclusión relativa a la utilización de múltiples criterios en este problema de decisión.

El análisis de sensibilidad mostró que todos los criterios, tanto cuantitativos como cualitativos, son necesarios para el modelo y la eliminación o modificación de sus pesos podría llevar a cambios en la selección de alternativas. Asimismo, los resultados son robustos, aunque no completamente, al parámetro de predictibilidad escogido, lo que obliga a los tomadores de decisiones a revisar con cuidado la métrica que se utilizará para valorar la predictibilidad.

La utilización del modelador automático del paquete estadístico para obtener los pronósticos de series temporales origina una línea base de estas predicciones; es decir, al nivel de desagregación finalmente seleccionado es posible obtener una estimación suficientemente buena mediante un procesamiento estadístico riguroso de los datos que componen las series. Esto da libertad al tomador de decisiones para escoger el nivel de desagregación adecuada sin considerar el trabajo que se requeriría para generar las líneas bases en alternativas con gran cantidad de series temporales. Sin embargo, un paso recomendable a realizar una vez se ha hecho la selección es intentar mejorar esta línea base, es decir, reducir el  $MdMAPE_j$  para los datos de validación de acuerdo con la naturaleza de los datos seleccionados en el nivel de agregación escogido.

## **BIBLIOGRAFÍA**

- Alt, R. & Zimmermann, H.-D. (2001). Preface: Introduction to special Section- Business Models. *Electronic Markets*, 11(1), 3–9.
- Armstrong, J.S. (2006). Findings from evidence-based forecasting: Methods for reducing forecast error. *International Journal of Forecasting*, 22(3), 583–598.
- Chen, A. & Blue, J. (2010). Performance analysis of demand planning approaches for aggregating, forecasting and disaggregating interrelated demands. *International Journal of Production Economics*, 128(2), 586–602. doi: 10.1016/j.ijpe.2010.07.006
- Danese, P. & Kalchschmidt, M. (2011). The role of the forecasting process in improving forecast accuracy and operational performance. *International Journal of Production Economics*, 131(1), 204–214. doi: 10.1016/j.ijpe.2010.09.006

- Espasa, A., Senra, E. & Albacet, R. (2002). Forecasting inflation in the European Monetary Union. *European Journal of Finance*, 8(4), 402–421.
- Ewing, B.T., Sari, R. & Soytas, U. (2007). Disaggregate energy consumption and industrial output in the United States. *Energy Policy*, 35(2), 1274–1281. doi: 10.1016/j.enpol.2006.03.012
- Fliedner, G. (2001). Hierarchical forecasting: issues and use guidelines. *Industrial Management & Data Systems*, 101(1-2), 5–12. doi: 10.1108/02635570110365952
- Giot, P. & Petitjean, M. (2011). On the statistical and economic performance of stock return predictive regression models: an international perspective. *Quantitative Finance*, 11(2), 175–193. doi: 10.1080/14697680903468971
- Ho, W. (2008). Integrated analytic hierarchy process and its applications -A literature review. *European Journal of Operational Research*, 186(1), 211–228. doi: 10.1016/j.ejor.2007.01.004
- Hogarth, R.M. & Makridakis, S. (1981). Forecasting and Planning: An Evaluation. *Management Science*, 27(2), 115–138.
- Hyndman, R.J., Ahmed, R.A., Athanasopoulos, G. & Shang, H.L. (2011). Optimal combination forecasts for hierarchical time series. *Computational Statistics & Data Analysis*, 55(9), 2579–2589. doi: 10.1016/j.csda.2011.03.006
- Hyndman, R.K. & Anne, B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22, 679–688.
- Ishizaka, A., Balkenborg, D. & Kaplan, T. (2011). Does AHP help us make a choice? An experimental evaluation. *Journal of the Operational Research Society*, 62(10), 1801–1812. doi: 10.1057/jors.2010.158
- Kahn, K.B. (1998). Revisiting top-down versus bottom-up forecasting. *The Journal of Business Forecasting*, 17(5), 14–19.
- Lederer, A.L. & Smith, G.L. (1988). Individual Differences and Decision-Making Using Various Levels of Aggregation of Information. *Journal of Management Information Systems*, 5(3), 53–69.
- Makridakis, S. & Taleb, N. (2009). Decision making and planning under low levels of predictability. *International Journal of Forecasting*, 25, 716–733.
- Makridakis, S., Wheelwright, S. & Hyndman, R. (1997). *Forecasting: methods and applications*: Wiley.
- Man, K.S. (2004). Linear prediction of temporal aggregates under model misspecification. *International Journal of Forecasting*, 20(4), 659–670. doi: 10.1016/j.ijforecast.2003.11.010
- Manfren, M., Caputo, P. & Costa, G. (2011). Paradigm shift in urban energy systems through distributed generation: Methods and models. *Applied Energy*, 88(4), 1032–1048. doi: 10.1016/j.apenergy.2010.10.018
- Marcellino, M., Stock, J.H. & Watson, M.W. (2003). Macroeconomic forecasting in the Euro area: Country specific versus area-wide information. *European Economic Review*, 47(1), 1–18. doi: 10.1016/s0014-2921(02)00206-4

- Oliver, L. (2006). *The cost management toolbox: A Manager's Guide to Controlling Costs and Boosting Profits*. USA: AMACOM.
- Saaty, T. & Kearns, K. (1985). *Analytical Planning. The Organization of Systems* (Vol. IV). Pittsburgh, PA, USA: RWS Publications.
- Saaty, T. & Vargas, L. (2001). *Models, Methods, Concepts & Applications of the Analytic Hierarchy Process*. Pittsburgh, PA, USA: Springer.
- Sanders, N. & Manrodt, K.B. (2003). The efficacy of using judgmental versus quantitative forecasting methods in practice. *Omega*, 31(6), 511–522.
- Smith, C.D. & Mentzer, J.T. (2010). Forecasting task-technology fit: The influence of individuals, systems and procedures on forecast performance. *International Journal of Forecasting*, 26(1), 144–161.
- Sporcic, M., Landekic, M., Lovric, M., Bogdan, S. & Segotic, K. (2010). Multiple criteria decision making in forestry -Methods and experiences. *Sumarski List*, 134(5-6), 275–286.
- Subramanian, N. & Ramanathan, R. (2012). A review of applications of Analytic Hierarchy Process in operations management. *International Journal of Production Economics*, 138(2), 215–241. doi: 10.1016/j.ijpe.2012.03.036
- Syntetos, A.A., Nikolopoulos, K., Boylan, J.E., Fildes, R. & Goodwin, P. (2009). The effects of integrating management judgement into intermittent demand forecasts. *International Journal of Production Economics*, 118(1), 72–81.
- Temurshoev, U., Webb, C. & Yamano, N. (2011). Projection of supply and use tables: methods and their empirical assessment. *Economic Systems Research*, 23(1), 91–123.
- Triantaphyllou, E. & Sánchez, A. (1997). A sensitivity analysis approach for some deterministic multi-criteria decision making methods. *Decision Sciences*, 28(1), 151–194.
- Tsoukiàs, A. (2008). From decision theory to decision aid methodology. *European Journal of Operational Research*, 187, 138–161.
- Uddameri, V. (2007). Using statistical and artificial neural network models to forecast potentiometric levels at a deep well in South Texas. *Environmental Geology*, 51(6), 885–895. doi: 10.1007/s00254-006-0452-5
- Vaidya, O.S. & Kumar, S. (2006). Analytic hierarchy process: An overview of applications. *European Journal of Operational Research*, 169(1), 1–29. doi: 10.1016/j.ejor.2004.04.028
- Velásquez-Henao, J.D., Franco-Cardona, C.J. & Olaya-Morales, Y. (2012). A Review of DAN2 (Dynamic architecture for artificial neural networks) model in time series forecasting. *Ingeniería y Universidad*, 16(1), 135–146.
- Winklhofer, H. & Diamantopoulos, A. (2002). Managerial evaluation of sales forecasting effectiveness: A MIMIC modeling approach. *International Journal of Research in Marketing*, 19(2), 151–166.
- Wright, G., Lawrence, M.J. & Collopy, F. (1996). The role and validity of judgment in forecasting. *International Journal of Forecasting*, 12(1), 1–8.