

Enfoques de Programación Matemática para la Previsión de la Demanda mediante descomposición de series temporales

Josefa Mula Bru¹, Raúl Poler Escoto², David Peidro Payá³, Angel Ortiz Bas⁴

^{1, 2, 3} CIGIP (Centro de Investigación Gestión e Ingeniería de Producción). Universidad Politécnica de Valencia. Departamento de Organización de Empresas, Economía Financiera y Contabilidad.

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

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

⁴ CIGIP (Centro de Investigación Gestión e Ingeniería de Producción). Universidad Politécnica de Valencia. Departamento de Organización de Empresas, Economía Financiera y Contabilidad.

Escuela Técnica Superior de Ingenieros Industriales. Campus Vera, s/n, 46021 Valencia. aortiz@cigip.upv.es

Resumen

Muchos métodos de previsión están basados en el concepto de que cuando existe un patrón subyacente en una serie de datos, este patrón puede distinguirse de la aleatoriedad mediante el suavizado (promediado) de los valores pasados. El efecto de este suavizado es eliminar la aleatoriedad de forma que el patrón pueda proyectarse en el futuro y usarse como previsión. En muchos casos el patrón puede descomponerse en sub-patrones que identifican separadamente cada componente de las series temporales. Tal descomposición proporciona un mejor entendimiento del comportamiento de las series, lo que mejora la exactitud de la previsión.

El objetivo de este artículo es determinar la previsión óptima para el modelo de descomposición de series temporales usando enfoques de Programación Matemática. Se han resuelto algunos ejemplos para ilustrar este enfoque.

Palabras clave: Programación Matemática, Previsión de la Demanda, Descomposición de Series Temporales.

1. Introducción

La Previsión de la Demanda futura es fundamental para la adecuada gestión de los Procesos de Negocio en las empresas industriales, tanto a nivel estratégico para las decisiones sobre capacidad a largo plazo, como a nivel táctico para la Planificación de Producción. En el nivel organizativo, los pronósticos de demanda se manifiestan como entradas esenciales para muchas actividades de decisión en varias áreas funcionales, tales como marketing, ventas, producción/compras, así como contabilidad y finanzas (Mentzer y Bienstock, 1998). Una adecuada Previsión de la Demanda también redundará en una gestión de inventarios más eficiente (Buffa y Miller, 1979; Hax y Candea, 1984; Silver *et al.* 1998).

Las técnicas para la realización de previsiones de demanda pueden clasificarse en tres categorías (Makridakis *et al.* 1998): (a) *Métodos Cualitativos*. Principalmente basados en la opinión de expertos; b) *Métodos Causales*. Desarrollan modelos que relacionan la demanda con un conjunto de variables independientes; y c) *Métodos Cuantitativos*. Los cuales se dividen en dos tipos principales: c.1) Series temporales, que predicen la continuación de patrones de datos históricos y c.2) Explicativos, que tratan de explicar como determinadas variables afectan a la previsión.

La elección de la técnica más apropiada depende de un amplio rango de consideraciones, tales como los horizontes temporales, objetivos, las propiedades de los datos y muchos otros aspectos. Además, el modelo de previsión debe ser manejable y producir resultados, que sean, a la vez, fidedignos y fáciles de interpretar.

En este artículo se proponen diversos modelos de Programación Matemática para la Previsión de la Demanda basada en la descomposición multiplicativa y aditiva de series temporales. En dichos modelos se puede optar por la minimización del error cuadrático medio o del error absoluto medio del ajuste.

El artículo se ha estructurado de la siguiente forma. En la sección 2 se introducen los modelos de descomposición de series temporales para la Previsión de la Demanda. A continuación, en la sección 3 se desarrollan los modelos de Programación Matemática para la Previsión de la Demanda. Seguidamente, en la sección se comparan los resultados alcanzados con el método de descomposición clásica de la serie temporal en movimientos característicos. Finalmente, la sección 5 presenta las conclusiones de este artículo.

2. Modelos de descomposición de series temporales

Una serie temporal es un conjunto de observaciones tomadas en instantes específicos, generalmente a intervalos iguales. Matemáticamente, una serie temporal se define como una función de la variable de tiempo: Y_t .

Los métodos de descomposición establecen que la serie temporal se compone de cuatro movimientos característicos: tendencia, estacionalidad, ciclicidad e irregularidad. De estos cuatro movimientos únicamente pueden determinarse los tres primeros, aunque en la mayoría de los casos puede obtenerse una adecuada previsión mediante la combinación de tendencia y estacionalidad, obviando la ciclicidad que, por otro lado, es un movimiento de cálculo complicado (Makridakis *et al.* 1998). Por lo tanto, los métodos de descomposición pretenden identificar por separado dos componentes del patrón subyacente básico que suelen caracterizar las series de ventas y económicas. Éstos son la tendencia-ciclo y los factores de estacionalidad:

- 1) *Tendencia-ciclo (T)*. La tendencia-ciclo representa los cambios a largo plazo en el nivel de la serie. Dicha tendencia puede ser a la baja, al alza o invariable. Cuando se aprecia una tendencia alcista o bajista, las variaciones pueden ser más o menos acusadas (en forma lineal, exponencial, logarítmica, gompertz, etc.). Según la tipología de la tendencia se puede representar según una recta o una curva que generalmente es una variante de una exponencial. Algunas veces, la tendencia-ciclo es separada en tendencia y componentes cíclicos, pero esta distinción es un poco artificial y la mayoría de los procedimientos de descomposición consideran la tendencia y el ciclo como un único componente conocido como tendencia-ciclo (T).
- 2) *Factor de estacionalidad (E)*. El factor de estacionalidad se refiere a las variaciones periódicas de longitud constante que son debidas a causas tales como la temperatura, lluvia, mes del año, períodos de vacaciones o políticas empresariales.

La principal característica de estos modelos es la consideración de que toda la información requerida para producir la previsión permanece estable dentro de las mismas series. Sin embargo, la exactitud de la previsión depende de forma crítica de la estabilidad de la tendencia del histórico y del patrón. Además, una simple extrapolación de las tendencias pasadas podría producir resultados incorrectos cuando algún evento perturba el patrón del histórico de las series. Armstrong (1984) discute los métodos uni-variantes basados en series temporales, también denominados métodos de extrapolación, en contraposición con otros enfoques más sofisticados. Kandil *et al.* (2001) demuestran que los modelos que ajustan las

series a una línea recta o a un polinomio son relativamente mejores comparados con otros modelos para un sistema eléctrico de desarrollo rápido, mientras que la mayor parte de los modelos aplicados son válidos para un sistema de desarrollo normal.

3. Enfoques de Programación Matemática

En esta sección se formulan los modelos de Programación No Lineal, que minimizan el error cuadrático medio (ECM) de ajuste y el error absoluto medio (EAM) de ajuste, asociados con los modelos de descomposición multiplicativa de series temporales. Además, se formula también un modelo de Programación Cuadrática que minimiza el ECM basado en la descomposición aditiva de series temporales, este modelo se transforma en un modelo de Programación Lineal cuando se minimiza el EAM. Los modelos son implementados y resueltos utilizando el Solver de Excel y el lenguaje de modelado MPL (Maximal Software Corporation, 2000) con el Solver CPLEX (CPLEX Optimization Co., 1994) para problemas lineales y cuadráticos y el Solver CONOPT (Drudd, 1994) para problemas no lineales. La formulación de los problemas de Programación Matemática permite obtener, adicionalmente a la previsión, información completa sobre las características del modelo: parámetros de ajuste, componentes del patrón de la demanda y medidas del error de previsión.

El EAM consiste en hacer cada error de ajuste positivo a través de su valor absoluto y posteriormente promediar los resultados. En el caso del ECM, los errores se hacen positivos elevando cada uno al cuadrado y seguidamente promediando los cuadrados. El EAM tiene la ventaja de ser más interpretable y fácil de explicar a los usuarios no especialistas de la previsión. Por su parte, el ECM tiene la ventaja de ser más fácil de manejar matemáticamente y por tanto es muy frecuentemente utilizado en optimización estadística. También elevar al cuadrado los errores magnifica o proporciona mayor peso a los valores extremos, lo que resulta atractivo ya que los grandes errores son menos deseables que los pequeños (Makridakis *et al.* 1998).

En los modelos propuestos no se utiliza la función no lineal del valor absoluto sino una transformación lineal del mismo con lo que desaparece la desventaja del EAM respecto a su utilización en programación matemática.

3.1. Descomposición Multiplicativa de Series Temporales

Un modelo de Descomposición Multiplicativa de Series Temporales es apropiado cuando las fluctuaciones de la estacionalidad aumentan y disminuyen proporcionalmente al incremento y decremento del nivel de la serie.

La descomposición asume que una serie temporal, Y_t , se forma como sigue:

$$Y_t = \text{patrón} + \text{error} = f(\text{tendencia-ciclo}, \text{estacionalidad}, \text{error}) \quad (1)$$

Por tanto, adicionalmente a los componentes del patrón, se asume también que está presente un componente de error o aleatoriedad. Este error es aceptado como la diferencia entre el efecto combinado de los dos sub-patrones (T , E) de la serie y el dato actual. Este error es conocido como el componente “irregular”, I .

Existen varios enfoques alternativos para descomponer una serie temporal, cuyo objetivo es aislar cada componente de la serie con la mayor precisión posible. El concepto básico en tal separación es empírico y consiste en remover primero el componente tendencia-ciclo y posteriormente aislar el componente de estacionalidad. Cualquier componente residual es asumido como aleatoriedad, que aunque no pueda preverse, puede identificarse.

La representación matemática general del enfoque de descomposición es:

$$Y_t = f(T_t, E_t, I_t) \quad (2)$$

Donde Y_t es el valor de la serie temporal (dato actual) en el período t , T_t es el componente tendencia-ciclo en el período t , E_t es el componente de estacionalidad en el período t , e I_t es el componente irregular (o residual) en el período t . El enfoque de descomposición multiplicativa asume que la ecuación anterior tiene la siguiente forma:

$$Y_t = T_t * E_t * I_t \quad (3)$$

Es decir, los componentes tendencia-ciclo, estacionalidad e irregular se multiplican para proporcionar la serie observada.

3.1.1. Modelo DSTM_ECM

Se trata de un modelo de Programación No Lineal que optimiza la previsión de la demanda minimizando el Error Cuadrático Medio del ajuste. El modelo DSTM_ECM es formulado como sigue. Las variables de decisión y parámetros del modelo se definen en la Tabla 1.

Minimizar
$$z = \sum_{t=1}^T \frac{Err_t^2}{T} \quad (4)$$

Sujeto a

$$Tend_t = a + b \times t \quad t = 1 \dots T \quad (5)$$

$$\sum_{p=1}^P E_p = P \quad p=1 \dots P \quad (6)$$

$$Prev_t = Tend_t \times E_{p=Mes_t} \quad t = 1 \dots T, p = Mes_t \quad (7)$$

$$Err_t = Prev_t - d_t \quad t = 1 \dots T \quad (8)$$

$$Tend_t, E_p, Prev_t \geq 0 \quad t = 1 \dots T, p=1 \dots P \quad (9)$$

La función objetivo (4) pretende minimizar el error cuadrático medio del ajuste. El conjunto de restricciones (5) determina el factor tendencia-ciclo a partir del ajuste de los datos históricos de la demanda a una recta. Se asume que el componente de estacionalidad es constante durante un horizonte de previsión. Por lo que sólo se requiere calcular un valor para cada mes. Al conjunto de los P valores que se repiten formando el componente de estacionalidad es conocido como índices de estacionalidad. La restricción (6) garantiza que la suma de los índices de estacionalidad obtenidos para todos los meses del horizonte de previsión debería dar P (12 para un horizonte de previsión anual). El conjunto de restricciones (7) calcula el valor de la previsión para cada período t a partir del producto del factor tendencia-ciclo y la estacionalidad. El conjunto de restricciones (8) determina el error de ajuste para cada período t como la diferencia entre la previsión calculada y los históricos de la demanda. Por último, la restricción (9) asegura que los valores de la tendencia-ciclo, la estacionalidad y la previsión sean positivos. Las variables de decisión a , b y Err_t pueden tomar valores negativos, por lo que son definidas como variables FREE en el lenguaje de modelado MPL.

Tabla 1. Variables de decisión y parámetros del modelo.

Índices	
T	Conjunto de periodos del horizonte de previsión ($t = 1 \dots T$)
P	Conjunto de meses que forman el horizonte de previsión ($p = 1 \dots P$)
Variables de Decisión	
E_p	Factor de estacionalidad en el mes p
$Tend_t$	Factor de tendencia-ciclo en el período t
$Prev_t$	Previsión de demanda 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
A	Parámetro a de la recta de ajuste
B	Parámetro b de la recta de ajuste
Datos	
d_t	Histórico de demanda en el período t
Mes_t	Mes correspondiente al período t

3.1.2. Modelo DSTM_EAM

En esta sección el modelo anterior es modificado con el objetivo de minimizar el Error Absoluto Medio del ajuste. El modelo DSTM_EAM es formulado como sigue. Las variables de decisión y parámetros del modelo aparecen definidos en la Tabla 1.

$$\text{Minimizar } z = \sum_{t=1}^T \frac{ErrA_t}{T} \quad (10)$$

Sujeto a

$$Tend_t = a + b \times t \quad t = 1 \dots T \quad (11)$$

$$\sum_{p=1}^P E_p = P \quad p=1 \dots P \quad (12)$$

$$Prev_t = Tend_t \times E_{p=Mes_t} \quad t = 1 \dots T, p = Mes_t \quad (13)$$

$$Err_t = Prev_t - d_t \quad t = 1 \dots T \quad (14)$$

$$ErrA_t \geq Err_t \quad t = 1 \dots T \quad (15)$$

$$ErrA_t \geq -Err_t \quad t = 1 \dots T \quad (16)$$

$$Tend_t, E_p, Prev_t, ErrA_t \geq 0 \quad t = 1 \dots T, p=1 \dots P \quad (17)$$

La función objetivo (10) pretende minimizar el error absoluto medio del ajuste. El conjunto de restricciones (15) y (16) tratan de forma lineal la función valor absoluto que además de ser no lineal es una función no diferenciable. Por último, la restricción (17) asegura que los valores de la tendencia-ciclo, la estacionalidad, la previsión y el error absoluto en el período t sean positivos. Las restricciones (11), (12), (13) y (14) se añaden de forma similar al modelo que las restricciones (5), (6), (7) y (8).

3.2. Descomposición Aditiva de Series Temporales

Un modelo de Descomposición Aditiva de Series Temporales es apropiado cuando la magnitud de las fluctuaciones de la estacionalidad no varía con el nivel de la serie.

La descomposición aditiva asume que una serie temporal, Y_t , se forma como sigue:

$$Y_t = patrón + error = f(tendencia-ciclo, estacionalidad, error) \quad (18)$$

El enfoque de descomposición aditiva asume que la ecuación anterior tiene la siguiente forma:

$$Y_t = E_t + T_t + I_t \quad (19)$$

Es decir, los componentes de estacionalidad, tendencia-ciclo e irregular se suman para proporcionar la serie observada.

3.2.1. Modelo DSTA_ECM

Se trata de un modelo de Programación Cuadrática que optimiza la previsión de la demanda minimizando el Error Cuadrático Medio del ajuste. El modelo DSTA_ECM es formulado como sigue. Las variables de decisión y parámetros del modelo aparecen definidos en la Tabla 1.

$$\text{Minimizar } z = \sum_{t=1}^T \frac{Err_t^2}{T} \quad (20)$$

Sujeto a

$$Tend_t = a + b \times t \quad t = 1 \dots T \quad (21)$$

$$\sum_{p=1}^P E_p = 0 \quad p=1 \dots P \quad (22)$$

$$Prev_t = Tend_t + E_{p=Mes_t} \quad t = 1 \dots T, p = Mes_t \quad (23)$$

$$Err_t = Prev_t - d_t \quad t = 1 \dots T \quad (24)$$

$$Tend_t, Prev_t \geq 0 \quad t = 1 \dots T, p=1 \dots P \quad (25)$$

La función objetivo (20) pretende minimizar el error cuadrático medio del ajuste. El conjunto de restricciones (21) determina el factor tendencia-ciclo a partir del ajuste de los datos históricos de la demanda a una recta. Igual que en los modelos anteriores se asume que el componente de estacionalidad es constante durante un horizonte de previsión. La restricción (22) garantiza que la suma de los índices de estacionalidad obtenidos para todos los meses del horizonte de previsión sea igual a 0. El conjunto de restricciones (23) calcula el valor de la previsión para cada período t a partir de la adición del factor tendencia-ciclo y la estacionalidad. El conjunto de restricciones (24) determina el error de ajuste para cada período t como la diferencia entre la previsión calculada y los históricos de la demanda. Por último, la restricción (25) asegura que los valores de la tendencia-ciclo y la previsión sean positivos. En este caso, las variables de decisión a , b , E_p y Err_t pueden tomar valores negativos.

3.2.2. Modelo DSTA_EAM

En esta sección el modelo anterior es modificado con el objetivo de minimizar el Error Absoluto Medio del ajuste al igual que se hizo anteriormente con el modelo DSTM_EAM. El modelo DSTA_EAM es formulado como sigue. Las variables de decisión y parámetros del modelo aparecen definidos en la Tabla 1.

$$\text{Minimizar } z = \sum_{t=1}^T \frac{ErrA_t}{T} \quad (26)$$

Sujeto a

$$Tend_t = a + b \times t \quad t = 1 \dots T \quad (27)$$

$$\sum_{p=1}^P E_p = 0 \quad p=1 \dots P \quad (28)$$

$$Prev_t = Tend_t + E_{p=Mes_t} \quad t = 1 \dots T, p = Mes_t \quad (29)$$

$$Err_t = Prev_t - d_t \quad t = 1 \dots T \quad (30)$$

$$ErrA_t \geq Err_t \quad t = 1 \dots T \quad (31)$$

$$ErrA_t \geq -Err_t \quad t = 1 \dots T \quad (32)$$

$$Tend_t, Prev_t, ErrA_t \geq 0 \quad t = 1 \dots T, p=1 \dots P \quad (33)$$

4. Ejemplos numéricos con datos reales

Para ilustrar los resultados proporcionados por los modelos de optimización propuestos, se comparan éstos empíricamente con los resultados generados por los métodos tradicionales de Previsión de la Demanda basada en descomposición de series temporales.

El conjunto de datos corresponde a series de demanda real de 116 productos industriales (productos siderúrgicos para el sector de la construcción) con períodos de tiempo comprendidos entre 32 y 36, casi a partes iguales. Se considera un ciclo estacional de 12 períodos ($P = 12$). A cada serie se le aplican los 4 modelos planteados, DSTM_ECM, DSTM_EAM, DSTA_ECM, DSTA_EAM, y los 2 métodos tradicionales, multiplicativo y aditivo, DSTM y DSTA.

Las estadísticas proporcionadas por los ECM y EAM, utilizados como objetivo a minimizar en los modelos de optimización, se basan en medidas de precisión cuyo tamaño depende de la escala de los datos. Por tanto, estas medidas no facilitan la comparación entre diferentes series temporales y para diferentes intervalos de tiempo. Para hacer comparaciones entre series temporales diferentes es necesario utilizar medidas de error porcentuales o relativas (Makridakis *et al.* 1998).

Para comparar los modelos se analizan los valores del error relativo cuadrático medio (ERCM) y del error relativo absoluto medio (ERAM):

$$ERCM = \frac{1}{T} \sum_{t=1}^T \left(\frac{d_t - Prev_t}{d_t} \right)^2 \quad (34)$$

$$ERAM = \frac{1}{T} \sum_{t=1}^T \left| \frac{d_t - Prev_t}{d_t} \right| \quad (35)$$

Además, se consideran los errores de ajuste del modelo durante los 12 últimos meses del histórico de datos, principalmente para evitar alteraciones de los mismos debido a cambios en los patrones de la demanda. Obviamente, cuando menores son estos errores, mejor es el ajuste. La Tabla 2 muestra los errores promediados (ERCM y ERAM) obtenidos por cada modelo para las 116 series.

Tabla 2. Ranking de errores medios de ajuste para todas las series.

Modelo	Promedio ERCM	Modelo	Promedio ERAM
DSTM_EAM	0,5402	DSTM_EAM	0,3119
DSTA_EAM	0,7569	DSTA_EAM	0,5362
DSTA_ECM	1,0226	DSTM_ECM	0,6932
DSTM	1,1532	DSTA_ECM	0,7194
DSTM_ECM	1,2237	DSTM	0,7693
DSTA	2,6833	DSTA	0,8348

El modelo DSTM_EAM es el que ha proporcionado el mejor ajuste mientras que el modelo DSTA ha generado el peor ajuste. Cuando se comparan los resultados en función del promedio del ERAM todos los modelos propuestos se comportan mejor que los modelos tradicionales, DSTA y DSTM. En el caso de una comparativa en función del promedio del ERCM, todos los modelos propuestos se comportan mejor que el modelo DSTA y que el modelo DSTM a excepción del modelo DSTM_ECM que presenta un error ligeramente superior al del modelo DSTM.

A continuación, las 116 series se han clasificado en tres grupos en función del número de ceros presentes en la misma. Así, el primer grupo formado por 93 series cuenta con menos de 11 ceros, el segundo grupo formado por 10 series tiene entre 11 y 20 ceros y el tercer grupo formado por 13 series tiene más de 20 ceros. A continuación las Tablas 3, 4 y 5 muestran los errores medios de ajuste de cada grupo de series.

Tabla 3. Ranking de errores medios de ajuste para las series con menos de 11 ceros (93 series).

Modelo	Promedio ERCM	Modelo	Promedio ERAM
DSTM_EAM	0,2082	DSTM_EAM	0,1552
DSTA_EAM	0,5464	DSTA_EAM	0,4449
DSTA_ECM	0,5815	DSTM_ECM	0,4983
DSTM_ECM	0,6658	DSTA_ECM	0,5336
DSTM	0,6986	DSTM	0,6202
DSTA	1,2083	DSTA	0,6514

Tabla 4. Ranking de errores medios de ajuste para las series con entre 10 y 20 ceros (10 series).

Modelo	Promedio ERCM	Codigo	Promedio ERAM
DSTM_EAM	1,6233	DSTM_EAM	0,8027
DSTA_EAM	1,7783	DSTA_EAM	1,0245
DSTA_ECM	2,0217	DSTA_ECM	1,1838
DSTM	3,4957	DSTM_ECM	1,4039
DSTM_ECM	3,9523	DSTM	1,4341
DSTA	13,4608	DSTA	1,6364

Tabla 5. Ranking de errores medios de ajuste para las series con más de 20 ceros (13 series).

Codigo	Promedio ERCM	Codigo	Promedio ERAM
DSTA_EAM	1,5074	DSTA_EAM	0,8351
DSTM_EAM	2,0957	DSTM_EAM	1,0607
DSTM	2,6599	DSTM	1,3538
DSTM_ECM	3,1871	DSTA	1,5634
DSTA_ECM	3,4627	DSTM_ECM	1,5699
DSTA	5,1182	DSTA_ECM	1,7219

En el caso de las series con menos de 20 ceros, de forma general, todos los modelos propuestos proporcionan mejores ajustes que los métodos tradicionales. Esto deja de ser así cuando existe un gran número de ceros entre la demanda observada mensualmente. Para este tipo de series con un gran número de valores cero, Segura y Vercher (2001) proponen un enfoque de programación matemática, concretamente de Programación No Lineal, para la Previsión de la Demanda basada en el modelo de suavizado exponencial de Holt-Winters.

La Figura 1 muestra el porcentaje de las ocasiones en el que cada modelo ha presentado un comportamiento mejor para todas las series, en términos de menor error de ajuste, que el resto de los modelos utilizados.

Como puede observarse la evaluación de los modelos en función de ambos errores (EAM y ECM) presenta resultados similares. Es importante resaltar como para el conjunto de series analizadas los modelos de optimización basados en la descomposición multiplicativa presentan un mejor comportamiento. Aunque, como es de esperar en el caso de las series con un mayor número de ceros los métodos modelos aditivos generan mejores resultados.

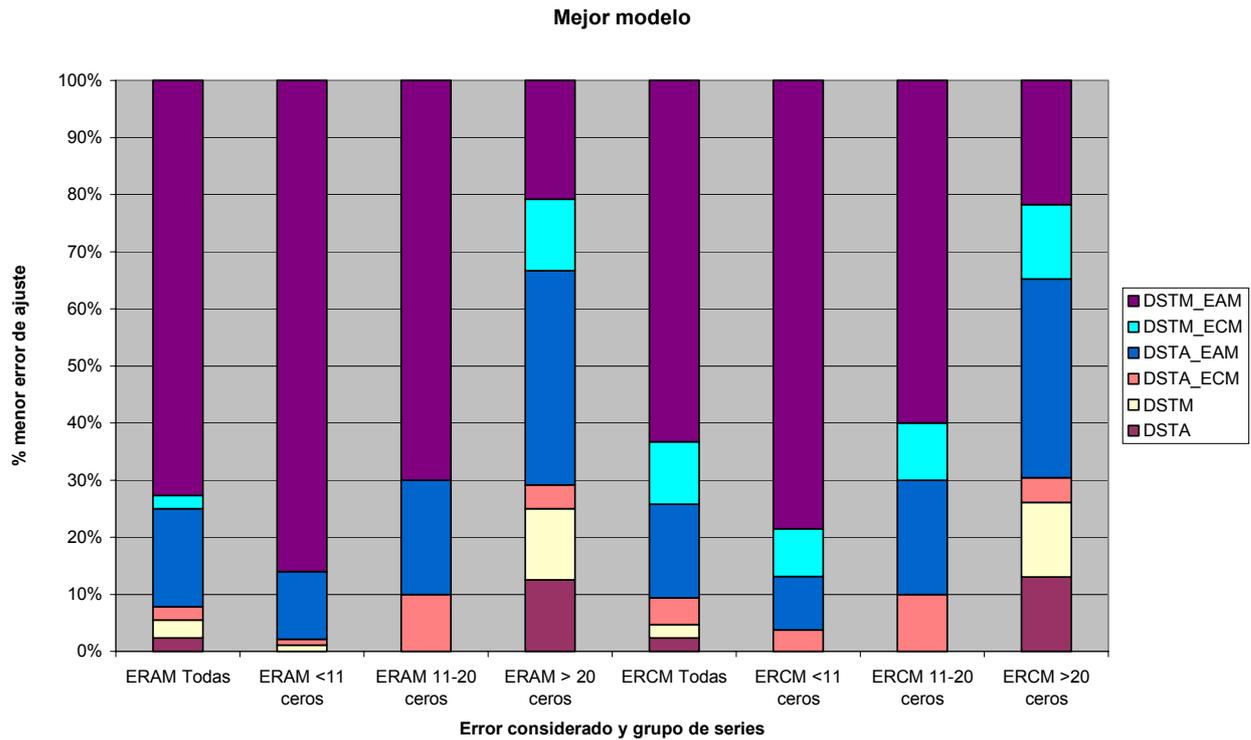


Figura 1. Mejor modelo en función de los errores de ajuste (ERAM y ERCM) y grupo de series.

5. Conclusiones

El objetivo de este trabajo ha sido desarrollar y aplicar modelos de optimización para la previsión de la demanda basados en los Métodos Cuantitativos. Se ha analizado el interés de utilizar modelos de Programación Matemática (Programación Lineal, Programación Cuadrática y Programación No Lineal) para la obtención de los movimientos característicos de una serie temporal con el objetivo de minimizar los errores de ajuste, en contraposición al método clásico de descomposición. Las conclusiones son la obtención de funciones de previsión con menor error de ajuste al histórico mediante los modelos de Programación Matemática, con un mínimo aumento del coste computacional respecto a los métodos clásicos de descomposición de series temporales.

Referencias

- Armstrong, J.S. (1984) Forecasting by extrapolation: conclusions from 25 years of research. *Interfaces*, 14, 52-66.
- Buffa, E.S. y Miller, J.G. (1979) *Production Inventory Systems: Planning and Control*. Third Edition. Homewood, IL, Irwin.
- CPLEX Optimization Co. (1994) *Using the CPLEX callable library*.
- Drud, A. (1994) CONOPT – a large-scale GRG code, *ORSA Journal on Computing* 6, 2, 207-216.
- Hax, A.C. y Candea, D. (1984) *Production and Inventory Management*. Prentice Hall, Englewood Cliffs, New York.
- Kandil, M.S., El-Debeiky, S.M. y Hasanien, N.E. (2001) Overview and comparison of long-term forecasting techniques for a fast developing utility: part I. *Electric Power Systems Research*, 58, 11-17.

Makridakis, S., Wheelwright, S.C y Hyndman, R.J. (1998) Forecasting Methods and Applications. Third Edition. John Wiley and Sons, Inc, New York.

Maximal Software Corporation (2000) MPL modelling system. Release 4.11, USA.

Mentzer, J.T. y Bienstock, C.C. (1998) Sales Forecasting Management. Sage, Thousands Oaks, CA.

Segura, J.V. y Vercher, E. (2001) Theory and methodology: A spreadsheet modeling approach to the Holt-Winters optimal forecasting. European Journal of Operational Research, 131, 375-388.

Silver, E.A., Pyke, D.F. y Peterson, R. (1998) Inventory Management and Production Planning and Scheduling. John Wiley and Sons, Inc, New York.