

# Método automático de optimización para la selección de métodos de desagregación temporal

David Rey-Blanco<sup>1</sup>, Julio González-Arias<sup>1</sup>, Juan Antonio Vicente-Virseda<sup>1</sup>

<sup>a</sup>Facultad de Economía y Empresa - UNED, Paseo Senda del Rey, 11. 28040 Madrid, Spain

## Abstract

Cuando se trabaja con conjuntos de series temporales de diferentes frecuencias, es habitual aplicar procesos de desagregación temporal para adecuar las series a la mayor de las frecuencias del conjunto. A pesar de que existe un gran número de métodos para hacerlo, el método de selección suele ser manual, por este motivo es inviable aplicarlo sobre un gran conjunto de cientos o miles series. En este artículo, se propone un método de desagregación temporal sobre grandes conjuntos de series, para lo que se utiliza un criterio de mayor verosimilitud sobre una lista de técnicas candidatas. La serie seleccionada será aquella que más probabilidad tenga de cumplir los criterios de calidad de manera óptima. En este estudio, se realiza un análisis experimental sobre conjunto de 178 series temporales del precio de la vivienda de la Comunidad de Madrid y con cinco técnicas de modelización, donde se comprueba que el método de forma consistente logra seleccionar el método a aplicar a cada serie del conjunto, para que cada una ofrezca buenos niveles de calidad en la desagregación con un proceso que requiere una mínima intervención humana.

*Keywords:* Desagregación temporal, Series temporales

*JEL Codes:* C14, C21, C55, R32, R14, R32

## 1. Introducción

Las series temporales son un instrumento clave para la medición y control de variables macroeconómicas (Eurostat 2015). Sin embargo, estas pueden producirse con diferentes frecuencias temporales y, por tanto, distintas precisiones. El estudio de esta problemática se ha venido realizando desde principios del siglo XX, y existen un gran número de aproximaciones, tanto paramétricas como no paramétricas para resolverlas (Moauero and Savio 2005), denominadas de desagregación temporal. Estos métodos se utilizan para desagregar series de tiempo de baja frecuencia en series de frecuencia más alta, donde la suma, el

*Email addresses:* drey@idealista.com (David Rey-Blanco), jglez@cee.uned.es (Julio González-Arias), javicente@cee.uned.es (Juan Antonio Vicente-Virseda)

*Preprint submitted to Elsevier January 21, 2022*

promedio, el primer o el último valor de la serie de alta frecuencia resultante es consistente con la serie de baja frecuencia. En la Unión Europea, Eurostat y el Sistema Estadístico Europeo (SEE) desarrollaron una serie de directrices en (Eurostat 2015) para ayudar a los productores de datos a obtener series de alta frecuencia (trimestrales o mensuales) a partir de datos de baja frecuencia (anuales, bianuales, etc.) y para abordar las limitaciones temporales y contables relacionadas. Según la directiva europea, las aplicaciones típicas se conocen como desagregación temporal, evaluación comparativa y reconciliación. Las pautas dadas por Eurostat identifican las mejores prácticas para lograr tres objetivos: el primero, lograr la armonización en todos los procesos nacionales, el segundo para mejorar la comparabilidad entre resultados y el tercero para garantizar la coherencia entre dominios y entre agregados con sus componentes. El uso de estas técnicas es ampliamente utilizado por los institutos de estadística nacionales como por ejemplo: Francia, Italia y otros países europeos, donde se calculan las cifras trimestrales del Producto Interno Bruto (PIB) utilizando métodos de desagregación temporal (Sax and Steiner 2013).

La desagregación temporal se puede realizar con la ayuda de ninguna, una o más series de alta frecuencia denominadas indicadores<sup>1</sup>. Incluso cuando no hay una serie de indicadores de alta frecuencia, es posible que desee desagregar un bajo serie de frecuencias. Si bien la precisión de la serie de alta frecuencia resultante será baja, puede que valga la pena hacerlo. Por ejemplo, la estimación de un modelo autorregresivo vectorial requiere que todas las variables tengan la misma frecuencia. Aún así, es preferible tener una mala serie de alta frecuencia a cambiar a una frecuencia más baja. Todos los métodos de desagregación aseguran que una función de agregación sea la suma, el promedio, el primer o el último valor de la serie de alta frecuencia resultante es consistente con la serie de baja frecuencia. Pueden hacer frente a situaciones en las que la alta frecuencia es un múltiplo entero de la baja frecuencia (por ejemplo, años a trimestres, semanas a días), pero no con frecuencias irregulares (por ejemplo, semanas a meses).

El método propuesto tiene como objetivo ofrecer un método que permita una selección automática del método de desagregación temporal más adecuado dada la naturaleza de las series utilizadas en el modelado. Para asegurar la calidad de los resultados, se establecen una serie de criterios de calidad de las series temporales a generar, que son los más utilizados en la literatura; por tanto, será objetivo del proceso seleccionar aquellas técnicas que ofrezcan la mayor probabilidad de cumplir correctamente los criterios de calidad. Para evaluar el método se usan una serie de series temporales de índices de precios de la vivienda de la Comunidad de Madrid (España) con frecuencia anual que se desagregan a frecuencia mensual. Los resultados obtenidos con este método indican que efectivamente, este método selecciona automáticamente las series que cumplen mejor los criterios de calidad y por tanto cumple los dos objetivos perseguidos por la investigación: lograr un método automático y fiable con mínima intervención

<sup>1</sup>En el análisis experimental de este artículo la serie de alta frecuencia es mensual y la de baja frecuencia anual.

La metodología se ha validado con un análisis experimental realizado sobre 534 series temporales del precio de la vivienda, en un total de 178 zonas en Comunidad de Madrid. Se han usado cinco técnicas de desagregación temporal, una de ellas no paramétrica; entre las paramétricas hay tres basadas en métodos autorregresivos. Los resultados obtenidos indican que la metodología es capaz de seleccionar un método de desagregación temporal que ofrece unos altos niveles de calidad en la desagregación y que es una alternativa mejor, en términos de calidad, que seleccionar un único método para todas las series.

El artículo se estructura en cinco partes aparte de la introducción, la primera se refiere a una revisión de la literatura sobre las distintas técnicas de desagregación temporal de series temporales, así como a las recomendaciones oficiales por (Eurostat 2015). La segunda parte describe los datos utilizados para el desarrollo experimental. La tercera parte trata la metodología aplicada sobre las series de origen para la selección de las series más adecuadas. En la cuarta parte se desarrolla un análisis sobre los resultados arrojados por el método propuesto, y la quinta parte contiene las conclusiones finales y siguientes pasos de esta línea de investigación.

## **2. Marco teórico**

Existen varias aproximaciones para la adaptación del dato de baja frecuencia al de la alta frecuencia en series temporales: el proceso de desagregación temporal propiamente dicho, interpolación, el benchmarking o evaluación comparativa y la reconciliación de series. El objetivo final de cada técnica es combinar las series disponibles para lograr transformar la serie de baja frecuencia a una de alta frecuencia, manteniendo la consistencia cumpliendo una serie de restricciones.

En primer lugar, de forma general la desagregación temporal es la conversión de una serie de tiempo de flujo de baja frecuencia a una serie de mayor frecuencia (por ejemplo anual a mensual), como ejemplo de métodos utilizados para ellos son los basados en regresión como Chow-Lin (Chow and Lin 1971). La interpolación de series temporales se refiere a la generación de valores de una serie de tiempo para puntos de tiempo que no han sido muestreados dentro del intervalo de tiempo de la serie de tiempo original. Ejemplos de estos métodos son la interpolación cúbica o por splines, o métodos basados en regresión. El benchmarking de series temporales o evaluación comparativa <sup>2</sup> consiste en ajustar una serie de tiempo de alta frecuencia para que tenga consistencia temporal con una versión de frecuencia más baja de la misma variable, generalmente medida a partir de una fuente de datos diferente. Esto también se conoce como evaluación comparativa vinculante o binding benchmarking. Ejemplos de benchmarking son los métodos Denton, basados en regresión, Causey-Trager o preservación de ratios de crecimiento, y por último la reconciliación de series temporales, esta técnica

<sup>2</sup>Debido a uso generalizado en la literatura, utilizaremos indistintamente el término en inglés o en castellano en este documento.

Denton (y sus variantes) y aproximaciones en dos pasos. Existen otros métodos complementarios como el de la extrapolación, que calcula valores de una serie de tiempo para puntos de tiempo que no han sido muestreados y están fuera del intervalo de tiempo de la serie de tiempo observada original. En un problema de desagregación temporal, la extrapolación se relaciona con la estimación de los datos de alta frecuencia para períodos de tiempo en los que los datos de baja frecuencia no están disponibles. Ejemplos de extrapolación son los modelos ARIMA, suavizado exponencial, métodos basados en regresión univariantes y multivariantes.

Entre los métodos de desagregación temporal más utilizados podemos destacar Denton, Cholette-Dagun, Causey-Trager y Chow-Lin, todas ellas paramétricas excepto Causey-Trager. Es más habitual el uso de los enfoque paramétricos sobre los no paramétricos, por diferentes motivos como el de la interpretabilidad del ajuste de los modelos y la ausencia de problemas de convergencia en la búsqueda de la solución.

#### *Método Denton*

El método de benchmarking conocido como método Denton (Denton 1971), tiene como objetivo minimizar los cambios en las series de alta frecuencia (indicadores) al tiempo que cumple un conjunto de restricciones de evaluación comparativa. Este método minimiza los cuadrados de las desviaciones absolutas o relativas de la serie original, y la serie indicadora siendo el parámetro  $h$  el grado de diferencias. Se basa en el principio de preservación del movimiento. En el caso de la versión aditiva del método, cuando  $h = 0$  se minimiza la suma de los cuadrados de las diferencias entre la serie original y la indicadora, para  $h=1$  se minimiza la suma de las primeras diferencias, para  $h = 2$  las segundas diferencia, y así en adelante. Para la versión proporcional del método las diferencias se miden en términos absolutos.

El método utiliza la minimización restringida de una forma cuadrática en relación con las diferencias entre las estimaciones desagregadas y una serie de indicadores. La función de penalización se puede especificar como diferencias aritméticas o proporcionales. Este método es comúnmente utilizado por la facilidad y estabilidad de su implementación, así como a su robustez ante diferentes problemas de armonización. El problema se plantea como una minimización cuadrática de una función de penalización, con el objeto de minimizar los ajustes en el movimiento de la serie original. Denton propuso dos funciones de penalización, una aditiva y otra proporcional. El problema que resuelve el método Denton Proporcional se plantea en las Ecuaciones 1 y 2.

$$\begin{aligned} \min_{X_t} & \sum_{t=2}^{4y} [(X_t/X_{t-1}) - (I_t/I_{t-1})]^2 & \text{s.a. } & X_{4n-3} \\ & & & X_t = A_n, \quad n = 1, \dots, y \quad (2) \end{aligned}$$

Donde  $X_t$  es la serie trimestral a ser estimada,  $I_t$  es la serie trimestral disponible (indicador),  $A_n$  es la serie anual de la variable,  $t = 1, \dots, 4y$  es el índice de la serie trimestral y  $n = 1, \dots, y$  es el índice de la serie anual.

Este método no preserva explícitamente las tasas de variación trimestral de la serie indicadora, utilizadas comúnmente por los analistas de coyuntura económica. Aunque existe una alternativa no paramétrica desarrollada por Causey y Trager, que se menciona más adelante, que explícitamente mantiene lo máximo posible las tasas trimestrales del indicador.

El método Denton Proporcional, es sin embargo una aproximación muy buena cuando la serie indicadora de referencia no muestra cambios inesperados de un año a otro (lo que más adelante llamaremos periodos frontera) y cuando la serie indicadora no es muy volátil.

#### *Método Denton-Cholette*

Este método es una modificación sobre el método Denton, también conocida como Cholette-Dagum, elimina los movimientos espúreos de carácter transitorio al principio de las series resultados. Cholette y Dagum (Cholette and Dagum 1994) proponen un procedimiento de benchmarking basado en una regresión por mínimos cuadrados generalizados. Este procedimiento toma en consideración la presencia de sesgo en el indicador y de autocorrelación y heterocedasticidad en los errores de los datos originales. El método Denton mencionado anteriormente, puede verse como un caso particular (aproximado) de este método más general. Esta técnica se basa en las Ecuaciones 3 y 4.

$$I_t = a_t + X_t + e_t, t = 1, \dots, q \quad (3)$$

$$A_t = X_{4n-3} \quad X_t + w_n, n = 1, \dots, y \quad (4)$$

donde  $X_t$  es la serie trimestral a ser estimada,  $I_t$  es la serie trimestral disponible (indicador),  $A_n$  es la serie anual de la variable,  $t = 1, \dots, 4y$  es el índice de la serie trimestral y  $n = 1, \dots, y$  es el índice de la serie anual.  $a_t$  es un efecto determinístico combinado,  $e_t$  es un error trimestral autocorrelacionado y heterocedástico,  $w_n$  es el error heterocedástico de  $A_n$  incorrelacionado con  $e_t$ .

Se asume que:

$$E(e_t) = 0, E(e_t e_{t-h}) \neq 0, E(w_n) = 0, E(w_n^2) = \sigma^2_n, E(e_t w_n) = 0 \quad (5)$$

En una publicación posterior (Dagum and Cholette 2006), los autores definen un marco de regresión unificado para hacer una regresión de los indicadores de alta frecuencia sobre las restricciones de baja frecuencia disponibles, los efectos

5

deterministas y los errores autocorrelacionados. El modelo, también adaptable a una forma multiplicativa, anida métodos comunes de desagregación como Chow y Lin, Fernández y Litterman.

#### *Método de Chow y Lin*

Este método, en adelante también Chow-Lin, pertenece a la familia de los modelos basados en regresión, como son (Chow and Lin 1971), (Fernandez 1981) y (Litterman 1983). Estos métodos se basan en modelos lineales generalizados de la serie anual sobre un conjunto de series indicadoras, por tanto

es importante tener en cuenta que se asume que existe una relación lineal entre la serie de baja frecuencia y la serie de alta frecuencia. Los distintos modelos difieren esencialmente en los modelos propuestos para la estructura de los residuos. Chow y Lin amplían el enfoque de mínimos cuadrados generalizados para la desagregación temporal, proponiendo una regresión univariante de datos objetivo de baja frecuencia sobre indicadores de alta frecuencia. El método también proporciona una solución óptima para la extrapolación y propone un método para interpolar, armonizar y extrapolar series de tiempo basado en un modelo de regresión, utilizando como variable explicativa el indicador observado de alta frecuencia. Este procedimiento asume un modelo de regresión entre la variable a estimar no observada en la alta frecuencia (la serie armonizada) y una serie de indicadores relacionados de alta frecuencia observados, según la Ecuación 6.

$$X_t = \sum_{j=1}^p \beta_j I_{j,t} + u_t \quad (6)$$

donde  $X_t$  es la serie trimestral a ser estimada,  $I_t$  es la serie trimestral disponible (indicador),  $\beta_j$  es el coeficiente de regresión del indicador  $j$  anualizado y  $u_t$  es un error aleatorio  $AR(1)$  con  $v_t$ .

Como  $X_t$  no se observa, a Ecuación 6 no puede estimarse. El método asume que la misma relación entre la variable y los indicadores en frecuencia trimestral se mantiene en frecuencia anual, y propone una agregación del modelo a estimar en la Ecuación 7.

$$A_n = \sum_{j=1}^p \beta_j I_{j,t} + u_n^a \quad n = 1, \dots, y \quad (7)$$

donde  $A_n$  se define como una agregación de valores trimestral tal y como se define en la Ecuación 8.

$$A_n = \sum_{t=4n-3}^{4n} X_t \quad (8)$$

$I_t$  es la serie trimestral del índice,  $\beta_j$  es el coeficiente de regresión del indicador  $j$  anualizado y  $u_n^a$  es un error anual  $ARMA(1, 1)$  derivado del autorregresivo  $AR(1)$  de alta frecuencia. El método asume que los residuos de la serie de alta

6

frecuencia siguen un proceso autorregresivo de orden 1 ( $AR(1)$ ),  $u_t = \rho u_{t-1} + \epsilon_t$ , donde  $\epsilon$  es  $WN(0, \sigma_\epsilon)$ .<sup>3</sup>

Chow y Lin derivan el estimador BLUE<sup>4</sup> de los coeficientes  $\beta$  y de  $\rho$ . Dagum y Cholette muestran que el modelo de Chow y Lin es un caso particular de su modelo de regresión aditivo con una serie relacionada. En Chow y Lin es necesario asumir un comportamiento  $AR(1)$  para los residuos de la regresión, estimando el coeficiente autorregresivo con los datos en lugar de calibrarlo por el usuario

*Método Causey y Trager*

El método desarrollado por Causey y Trager (1981) plantea armonizar la serie de alta frecuencia minimizando los ajustes a la tasa de variación de la serie del índice, en el caso trimestral definida según las Ecuaciones 9 y 10.

$$\begin{aligned} \min_{X} & \sum_{t=2}^{4y} [(X_t/X_{t-1}) - (I_t/I_{t-1})]^2 \quad (9) \\ \text{s.a. } & X_{A_n}, n = 1, \dots, y \quad (10) \end{aligned}$$

4n-3

Como se observa en la Ecuación 9, la función objetivo es cuadrática y no lineal, por tanto no es posible obtener una solución algebraica para la serie a estimar de las condiciones de primer orden del problema. La estimación de la serie de alta frecuencia armonizada debe realizarse a través de procedimientos de optimización no lineales. La eficiencia y robustez de los procedimientos utilizados en la estimación, depende de las particularidades de cada problema de armonización. Esta aproximación no paramétrica puede dar lugar ciertos problemas como la falta de convergencia en la búsqueda de solución o estimaciones inexactas o muy dependientes de los valores iniciales.

*Otros métodos y consideraciones sobre el parámetro autorregresivo*

Los métodos restantes como Fernandez o Litterman se aplican a los casos en los que los indicadores de alta frecuencia y la serie anual no están cointegrados.<sup>5</sup> Fernandez y Litterman asumen que los residuos trimestrales siguen un proceso no estacionario, es decir,  $u_t = u_{t-1} + v_t$ , donde  $v$  es un un modelo autorregresivo de orden 1 AR1 ( $v_t = \rho \cdot v_{t-1} + \epsilon_t$ , donde  $\epsilon$  Es  $WN(0, \sigma_\epsilon)$ ). Fernández es un caso especial de Litterman, donde  $\rho = 0$  y, por lo tanto,  $u$  sigue una camino aleatorio. La matriz de varianza-covarianza se puede calcular según la Ecuación 11.

<sup>3</sup>WN hace referencia a Ruido Blanco, del inglés White Noise.

<sup>4</sup>Mejor estimador lineal insesgado, o Best Linear Unbiased Estimator. <sup>5</sup>La cointegración es una característica estadística de las variables en series temporales donde dos o más series de tiempo están cointegradas si comparten una tendencia estocástica común.

7

$$\Sigma_L(\rho) = \sigma_\epsilon^2 [\Delta' H(\rho)' H(\rho) \Delta]^{-1} \quad (11)$$

Donde  $\Delta$  es la misma matriz de diferencias  $n \times n$  que en el método Denton;  $H(\rho)$  es una matriz  $n \times n$  con 1 en su diagonal principal,  $-\rho$  en su primera subdiagonal y 0 en el resto. Para el caso particular de Fernández, con el parámetro autoregresivo  $\rho = 0$ , la matriz de covarianzas resultado tendría la forma indicada en la Ecuación 12.

$$\Sigma_L(0) = \sigma_\epsilon^2 \cdot (\Delta \Delta')^{-1} = \sigma_{\epsilonpsilon}^2 \cdot \Sigma_D \quad (12)$$

No existe un método único para el cálculo del parámetro autorregresivo  $\rho$ . Para el método Chow-Lin (Chow and Lin 1971) se propone un procedimiento

iterativo, donde se infiere el parámetro de la autocorrelación observada de los residuos de baja frecuencia,  $u_t$ . En un enfoque diferente, (Paige 1979) sugiere la maximización de la probabilidad de la regresión generalizada GLS. Existe un último enfoque, sugerido por (Barbone, Bodo, and Visco 1981), basado en minimizar la suma ponderada de los cuadrados de los residuos según la Ecuación 13.

$$RSS(\rho, \sigma^2_\epsilon, \beta) = u' (C \Sigma C')^{-1} u \quad (13)$$

Al contrario del enfoque de máxima verosimilitud,  $\sigma^2$  no se cancela. Los resultados son, por tanto, sensibles a la especificación de  $\sigma$ , con diferentes implementaciones que conducen a estimaciones diferentes pero inconsistentes de  $\rho$ .

#### *Tratamiento con series encadenadas*

Es habitual encontrar índices de precios como series de índices de precios encadenadas, en particular como índices de Precios de Laspeyres encadenados (INE 2018), o de forma más ampliada en el manual de cuentas nacionales de Eurostat (Eurostat 2013). En estos casos, la literatura no es categórica acerca si la desagregación temporal deba hacerse antes o después de aplicar el encadenamiento. A este respecto la cuestión que se plantea es si el ajuste debe hacer antes o después del encadenamiento de las series (Eurostat 2015), el condicionante clave en la decisión es si las series de tiempo en el ejercicio de desagregación temporal o evaluación comparativa son consistentes. En el caso de que la series encadenadas puedan ser consideradas consistentes los métodos de desagregación temporal y evaluación comparativa pueden aplicarse directamente.

En los procesos estadísticos, la agregación de medidas de volumen Laspeyres encadenados implica desencadenar las medidas vinculadas en cadena para proponer series descritas como incluidas en los precios del año anterior, agregar los precios del año anterior en la estructura de agregación y luego volver a encadenar. En esta situación, puede ser importante considerar la etapa en la que se aplica la desagregación temporal o la evaluación comparativa y debe considerarse junto con la selección de la estrategia de desagregación (directa o indirecta). Una serie no encadenada en los precios de los años anteriores no es, en sentido estricto,

8

una serie temporal coherente y no debe desglosarse temporalmente o compararse directamente. El método de encadenamiento puede distorsionar las limitaciones temporales, por ejemplo, el método de superposición trimestral y, por lo tanto, es importante restaurar la coherencia temporal en estos casos mediante la evaluación comparativa tras el encadenamiento. Si se adopta un enfoque directo de la desagregación temporal o la evaluación comparativa benchmarking para un conjunto de series geográficas no se deben realizar otras técnicas de conciliación para restaurar sectorial o consistencia geográfica ya que las series encadenadas no son aditivas. En nuestro caso realizaremos todo el proceso sobre series no encadenadas, para ello las series de baja frecuencia que originalmente hemos calculado encadenadas las transformaremos a números índices con base 100 sobre los precios de 2011. En el caso de las series de alta frecuencia, por razones de coste computacional, se ha decidido decidido calcularla como un




índice de Laspeyres básico con base en noviembre de 2011.

*Criterios de evaluación del ajuste de las series desagregadas* La validez o calidad de las series de alta frecuencia generada por los modelos pueden evaluarse por un simple criterio de ajuste a los criterios impuestos en la desagregación o en el caso de los enfoques paramétricos basados en modelos también atendiendo a las métricas de ajuste de los modelos generados. En el caso particular de los modelos autorregresivos podríamos evaluar el  $R^2$  del modelo o las condiciones de normalidad de los residuos del modelo por ejemplo. En las diferentes referencias bibliográficas consultadas no hay criterio único para hacerlo, aunque (Chen 2007) establece cinco criterios que serán la base de la metodología que se detallan en el Epígrafe 4.2.

### 3. Conjunto de datos

Las series que manejamos son los índices de precios anuales del mercado inmobiliario de alquiler en la Comunidad de Madrid, que con 829,84 habitantes/km<sup>2</sup> y 6,6 millones de habitantes es una de las zonas más densamente pobladas de España, pero que concentra su población en la ciudad de Madrid con 3,22 millones de habitantes y su zona metropolitana cercana. A nivel inmobiliario, también es uno de los mercados más activos de Europa. Los índices de precios se han calculado a través de métodos de ajuste de precios hedónicos a partir de datos de portales inmobiliarios y registros oficiales. Se dispone además de un índice de precios con frecuencia mensual de datos de oferta de portales inmobiliarios, este índice también se ha calculado a través de un método de ajuste hedónico y que procede de un proceso distinto al de las series anuales. Se cuenta con tres series para cada una de las zonas de estudio que se muestran en la Figura 1 (dos anuales y una mensual), un total de 178 zonas, por tanto un total de 534 series temporales.

9



**Figura 1.** Zonas geográficas en la Comunidad de Madrid, cada una de las zonas tiene una serie con índices de precios de la vivienda en alquiler. Fuente: elaboración propia.


En la Figura 2 se muestran los datos para una de las zonas, el barrio Pacífico de la ciudad de Madrid, se puede observar como las series desagregadas no cumplen la condición de que la media de los valores mensuales se corresponden con el valor de la serie anual. Siendo esta discrepancia mayor en la serie de oferta que en la de alquiler.



**Figura 2.** Series originales (oferta y alquiler). Se incluyen las diferencias logarítmicas mensuales. Barrio Prosperidad, municipio de Madrid. Fuente: elaboración propia.


Dada la coherencia temporal de las series de alta y baja frecuencia, usaremos la serie de alta frecuencia correspondiente para realizar el proceso de reconstrucción de la serie de alta frecuencia, es decir que para la construcción de la serie de alquiler mensual usaremos como serie indicadora la serie de oferta mensual. Tras un análisis preliminar de las series, se identifica una correlación importante entre las dos series, aunque esta correlación tiene un desfase temporal como se puede comprobar en la Figura 3, donde se calculan las autocorrelaciones de las series anuales de oferta y alquiler junto con la correlación cruzada alquiler y oferta, dónde se percibe la correlación entre series con un rezago temporal. Desde un punto de vista económico, la oferta actúa de forma adelantada al mercado del alquiler, siempre y cuando el mercado exista un mínimo nivel de absorción de la oferta, cuestión que si se produce en el caso de la Comunidad de Madrid. Este nivel de absorción o liquidez del mercado se puede medir como tasa de reposición del stock en oferta o por su reflejo en la tensión de la demanda, en medidas como número de visitas o de contactos medio por anuncio por unidad de tiempo. La serie de alquiler muestra un retraso que depende de la zona es entre uno y dos años sobre la serie de alquiler<sup>6</sup>.

<sup>6</sup>Este fenómeno depende de la zona y de la capacidad de absorción y reposición del stock de viviendas de alquiler por nuevos contratos, se puede decir que el dinamismo del mercado



**Figura 3.** Correlación de series: autocorrelación series anuales de alquiler, de series en oferta y cruzada oferta y alquiler (Barrio Pacífico de Madrid). Fuente: elaboración propia.


En la Figura 4 se observa que las autocorrelaciones en las series mensuales son muy fuertes en meses contiguos, cuestión que es lógica debido a que el componente predominante de la serie es la tendencia. Observamos que los ciclos en oferta parecen algo más largos que los de alquiler. Se aprecia además en la correlación cruzada que la serie de oferta va aproximadamente un año delante de la de alquiler.



**Figura 4.** Correlación de series: autocorrelación series mensuales de alquiler, de series en oferta y cruzada oferta y alquiler (Barrio Pacífico de Madrid). Fuente: elaboración propia.

La intuición sobre la dinámica del mercado nos indica que los mercados menos activos tenderán a tener rezagos temporales, para contrastar esta hipótesis elegimos tres mercados ordenados por su actividad de forma creciente. Área de Fuente el Saz de Jarama (zona residencial de tipo rural), el municipio de Leganés (zona residencial urbana de tipo residencial del extraradio) y el barrio de Gaztambide de Madrid (zona residencial urbana de centro de ciudad). En la Figura 4, se observa que las las correlaciones cruzadas en la zona rural tienen un rango mucho más amplio que las zonas urbanas, y es la zona del centro de la ciudad la que tiene un rango de correlaciones cruzadas más estrecho, lo que significaría que el mercado de alquiler reacciona más rápidamente en base al comportamiento de la oferta. Podríamos por tanto establecer la hipótesis de que la longitud del rezago es inversamente proporcional al nivel de actividad del

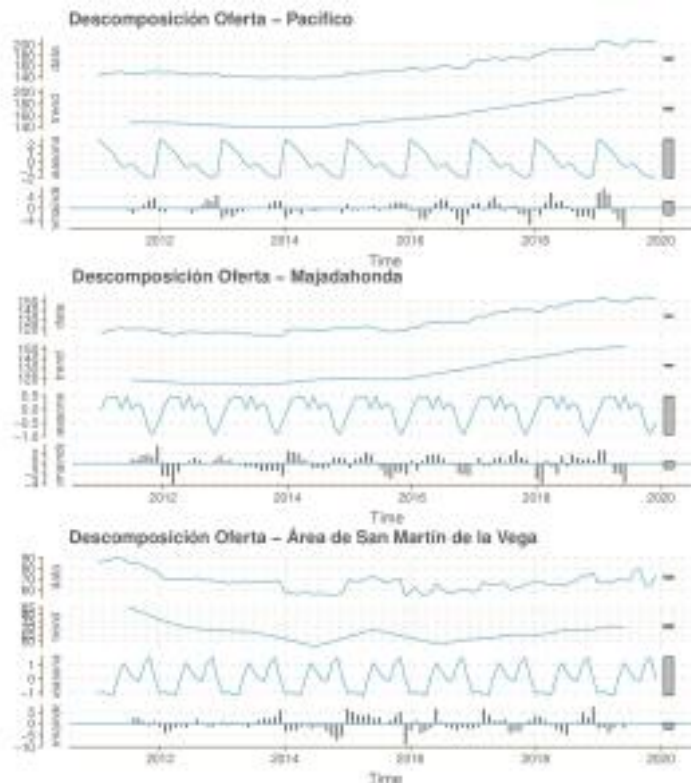
guarda una relación con el retraso entre series.



**Figura 5.** Correlación cruzada de series mensuales de oferta y alquiler: Zonas Fuente del Saz, Barrio Gaztambide y Leganés. Fuente: elaboración propia.

*¿Tienen las series componente estacional?*

Un elemento dirimir es si las series cuentan con un comportamiento estacional, la intuición de mercado puede indicar que sí, como puede ser del alquiler a estudiantes en zonas universitarias o en las zonas turísticas. En la Figura 6 se pueden observar los componentes (tendencia, estacionalidad y ciclo) de la serie temporal de oferta para encontrar comportamientos de estacionalidad anual dentro de las series, estudiando tres mercados muy diferentes en la comunidad de Madrid, centro de ciudad barrio Pacífico, residencial en area metropolitana: Majadahonda y zona rural de San Martín de la Vega. Observamos componentes estacionales en la serie. Existe una estacionalidad muy fuerte a inicios de cada año que atribuimos a un comportamiento espúreo del modelo hedónico de valoración (que se construye uno por año). Sin embargo dentro del año, donde no existe esta influencia, se observa un ligero patrón de estacionalidad.



**Figura 6.** Descomposición de las series mensuales de oferta: Pacifico, Majadahonda y San Martín de la Vega. Fuente: elaboración propia.

#### 4. Metodología propuesta

Las 178 localizaciones cuentan con dos series temporales de baja frecuencia (anual), una con el índice de precios de compra y otro con el precio del alquiler. Existe una gran diversidad de zonas ya que contamos tanto con barrios en el centro de la ciudad de Madrid como municipios de tipo rural de la comunidad de Madrid. Como a priori no conocemos cual es el mejor método que se puede aplicar a cada una de las series optaremos por un proceso de selección automática del método a aplicar. De tal forma que se calcularán, para cada una de las 356 series de tiempos, una serie de métodos de desagregación temporal. Para cada una de estas series seleccionaremos la serie que creemos que es más apropiada siguiendo un criterio de verosimilitud que le imponemos a la serie generada. Dicho criterio de verosimilitud atiende al comportamiento estructural de la serie, la validez de los datos, la consistencia entre serie de alta y baja frecuencia y la consistencia entre la serie generada y su serie indicadora.

Cuando se inicia un ejercicio de desagregación temporal que involucra varias variables objetivo relacionadas baja frecuencia, relacionadas con otras auxiliares de alta frecuencia, para convertir las primeras en variables de alta frecuencia Eurostat (Eurostat 2015) recomienda considerar tres criterios. El primero es la calidad de los indicadores de baja frecuencia (en varios niveles de desagregación). El segundo es la disponibilidad y calidad de indicadores de alta frecuencia en varios niveles de desagregación. El último son los requisitos legales o las necesidades de los usuarios a nivel de desagregación. Adicionalmente, deben tenerse en cuenta las consideraciones estadísticas de la calidad del producto del ejercicio de desagregación temporal en diferentes niveles de desagregación.

La elección del nivel de desglose debe evaluarse periódicamente a la luz de los cambios en la legislación, los nuevos requisitos de los usuarios y la apreciación de los expertos de las experiencias pasadas, así como los cambios estructurales que afectan la calidad general de los datos estadísticos debido a revisiones importantes o eventos extraordinarios. Las opciones propuestas por el manual se centran en que el proceso debe intentar idealmente cumplir las necesidades del usuario y cumplir con los requerimientos legales, aplicando un análisis en profundidad de la calidad de las series de alta frecuencia producidas.

La estrategia de estimación está estrictamente relacionada con la identificación del mejor nivel de desagregación temporal, cuando se deben estimar múltiples series vinculadas por restricciones de agregación, existen varias alternativas posibles. El primero es estimar por separado la variable agregada y sus componentes individuales (método directo). En este caso, no se garantiza el cumplimiento de las restricciones de agregación contemporáneas. El segundo es el uso del método directo complementado con técnicas de reconciliación para asegurar el cumplimiento de las limitaciones contemporáneas. La última posibilidad es estimar los componentes individuales de un agregado y derivar el agregado temporalmente desagregado agregando los componentes estimados (método indirecto).

No existe un razonamiento teórico ni evidencia empírica a favor de un enfoque en particular, pero las decisiones deben tomarse caso por caso con criterios de evaluación claramente definidos. El método directo parece ser el preferido cuando hay co-movimientos entre agregados y componentes y cuando la calidad de los componentes no es homogénea, lo que puede ocurrir especialmente a un nivel muy desagregado. El enfoque indirecto, parece mejor opción cuando la calidad de los componentes es lo suficientemente alta como para asegurar que la estimación del agregado también cuente con un alto nivel de calidad.

Por último, no se debe olvidar el impacto de los valores atípicos, también referidos como outliers, por que pueden reducir la calidad general en los ejercicios de desagregación temporal, evaluación comparativa y conciliación. Es importante estudiar el origen y causas de los valores atípicos, para poder decidir el mejor tratamiento a aplicar. Si los valores atípicos aparecen en la serie de indicadores solo como un único valor extremo (valores atípicos aditivos) y parecen ser un error en lugar de explicarse por razones estadísticas o económicas,

deben corregirse antes de ejecutar procedimientos de desagregación temporal, evaluación comparativa o conciliación. Si aparecen tanto en el indicador de alta frecuencia como en la variable objetivo de baja frecuencia y son explicables estadística o económicamente, deben modelarse durante el proceso

de estimación o eliminarse antes de su inicio y reintroducirse al final. Finalmente, si aparece más de un valor atípico estructural en unos pocos indicadores que reflejan cambios en el proceso de producción que no se reflejan en la variable objetivo de baja frecuencia, se debe evaluar la posibilidad de eliminar dichos indicadores de alta frecuencia del conjunto de variables candidatas. Como medidas de mitigación de estos inconvenientes podemos manejar la eliminación de los valores atípicos, ignorarlos entre otras estrategias.

Establecemos el supuesto de que existe una variable aleatoria que representa el comportamiento general de las diferencias logarítmicas mensuales, y ésta será la variable que tomaremos como referencia para evaluar el buen comportamiento de las series a generar. Extraemos algunas medidas de las diferencias logarítmicas de las series, en este caso media, desviación típica y coeficiente de variación de Pearson<sup>7</sup>, asumimos que todas las series mantienen la estacionalidad y seleccionaremos aquella con menor variabilidad relativa, es decir menor coeficiente de variación de Pearson.

#### 4.2 Criterios de evaluación de la calidad de las series

Para validar la calidad del método usaremos cuatro métricas sobre las series generadas, basándonos en cinco criterios de evaluación seguidos por (Chen 2007):

- **Se deben cumplir los requisitos de agregación**, en nuestro caso impondremos que la media de las series desagregadas se deben coincidir con el valor de la serie agregada, el nivel de discrepancia lo trataremos en términos de error cuadrático (cuadrado de la diferencia entre el valor de la serie agregada menos el valor de la media de las series desagregadas).
- **Los movimientos de corto plazo del indicador deberían mantenerse lo máximo posible**, en nuestro caso optamos por comparar la discrepancia entre las diferencias logarítmicas de la serie indicadora versus la serie generada en forma de error cuadrático medio.
- **No se deben observar cambios bruscos entre año y año**, en el estudio comparativo de procesos de benchmarking (Hood 2005) no es homogéneo a lo largo del año, en algunos métodos esta distorsión puede ser importante. Para medir este cambio (Chen 2007) opta por medir la media de los cambios entre noviembre y febrero y compararla con la media de los cambios entre marzo y octubre.
- **La serie estimada no debe mostrar cambios bruscos al inicio o fin de la serie**, esta situación se produce con algunos métodos por ejemplo con el Denton original.

<sup>7</sup>Calculado como:  $\sigma/\mu$  de los valores.

Definiremos cuatro métricas para evaluar el cumplimiento de los criterios anteriores por cada serie y método, recogidas en la Tabla 1. Las diferencias entre periodos se calculan como diferencias o retornos logarítmicos sobre los valores de las series, que permite comparar los valores de cambio entre diferentes



zonas. Siendo  $\hat{I}_{y,t}^z$  el precio medio estimado<sup>8</sup> por el modelo de una zona  $z$  para un año  $y$  y un mes  $t$ , y la variación o retorno logarítmica  $LR(\hat{I}_{t,t-1}) = \ln(\hat{I}_{t,t-1} / \hat{I}_{t-1})$ . Las métricas utilizadas serán las siguientes:

**Tabla 1.** Métricas de evaluación de series.

Requisito Métrica

Agregación RMSPE

Cambios bruscos anuales Variación máxima frontera anual Movimientos a corto plazo indicador RSME sobre las diferencias Cambios bruscos inicio y fin Ratio variación periodos extremos / variación mediana Discrepancia con la serie indicadora RSME entre la serie indicadora y la serie desagregada

Las distintas métricas de error se calculan de la siguiente forma:

- *RMSPE*, error cuadrático medio en porcentaje de la media anual de alquiler y la serie. Utilizamos el valor en porcentaje para poder comparar distintas zonas calculado según la Ecuación 14.
- *Máxima variación de frontera anual*, medida como la máxima variación logarítmica en valor absoluto entre el mes de diciembre y el mes de enero del año siguiente, definido para una serie temporal de valores mensuales  $I$  según la Ecuación 16.
- *Variación media* calculada como la media de los retornos logarítmicos de la serie.
- *Discrepancia* o *RSME* sobre las series de alta frecuencia (indicadora y final), se calcula, según la Ecuación 16, como el error cuadrático medio de cada uno de las observaciones  $I_t$  y la serie estimada de alta frecuencia  $H_t$ .

$$RMSPE = [\mu(\hat{I}^z) - \mu(Iz)]^2 \quad (14)$$

$$VF(I) = \max_{t=1}^N [\ln(\hat{I}_{y,12}^z / \hat{I}_{y+1,1}^z)] \quad (15)$$

$$Discrepancia(H, I) = (I_t - H_t)^2 \quad (16)$$

<sup>8</sup> $I$  representa el precio real del alquiler y  $\hat{I}$  el estimado por el modelo.

#### 4.3 Métodos de desagregación temporal

Para este estudio usaremos un enfoque univariante de desagregación temporal, para ejecutar el proceso se usará el paquete R *tempdisagg* (Sax and

Steiner 2013), y se usarán los métodos mostrados en la Tabla 2. Para ello compararemos los resultados obtenidos de aplicar los seis métodos de desagregación temporal de la serie de alquiler anual tomando como serie indicadora los precios de alquiler sin tendencia (modo univariante). En el caso del método Chow-Lin, la librería ofrece una variante sobre el método Chow-Lin propuesta por (Silva and Cardoso 2001). En el caso de los métodos de desagregación basados en modelos autorregresivos utilizamos la propia librería para la selección del parámetro  $\rho$ . Se descarta el método Denton original, porque se observa una alta inestabilidad en los primeros valores de las series en algunas áreas geográficas y a los que hace referencia los autores del método (Cholette and Dagum 1994).

**Tabla 2.** Métodos de desagregación temporal de series temporales.

Método Tipo Notas

Chow-Lin Max Log Regresión Basado en Chow-Lin Litterman Max Log Regresión Basado en Litterman Dynamic Regresión Basado en Litterman Denton-Cholette Denton Implementación Denton-Cholette Causey-Trager No paramétrico Basado en el método Causey-Trager

*3.4 Criterio de selección de modelos*

La adecuación de cada método depende de la naturaleza de las series, si bien es posible refinar la parametrización de cada método para conseguir el ajuste óptimo en cada caso. En los manuales desarrollados por los institutos de estadísticas no ofrecen un criterio objetivo o cuantitativo para decidir la selección del método más adecuado, y en la literatura no hemos encontrado ninguna referencia de un método que pudiera ser considerado general. En nuestra experiencia hemos comprobado que la gran mayoría de los casos la decisión termina en manos del criterio de un experto. Este criterio no es planteable en los que hay un gran número de series a desagregar que representan situaciones distintas unas con respecto a otras, por tanto no podemos utilizar un único método, ni tampoco podríamos efectuar esta labor de forma manual porque sería excesivamente costosa.

No obstante pensamos que sí podríamos disponer de un método cuantitativo más objetivo, cuyo proceso de decisión guardara un paralelismo con el criterio de selección experto de selección de la mejor serie. Este se basaría en general seleccionar la serie que se comporte lo más parecido a una serie de referencia (desde el punto de vista del humano, aquella con mayor verosimilitud según su experiencia). Al menos en las cuestiones estructurales clave de la serie en las que detectamos las principales incidencias, en particular en nuestro caso las diferencias mes a mes.

Se podría seguir algún otro enfoque no paramétrico, pero proponemos que se tome la serie según una medida de verosimilitud  $L$  de la serie según definida en la Ecuación 17.

$$L[\hat{r}_{combined}] = L[\hat{r}_{lr}] \cap L[\hat{r}_{f\ rontera}] \cap L[\hat{r}_{f\ id}] \quad (17) \text{ Dicha}$$

verosimilitud sería en realidad el resultado de la verosimilitud agregada de todos los puntos de la serie, asumiendo que todos los puntos son independientes, por lo tanto la verosimilitud para un parámetro  $\Theta$  de la serie se se puede definir según la Ecuación 18.

$$L(\Theta) = \prod_{i=1}^n f(X_i|\Theta) \quad (18)$$

Por consiguiente, en una estimación de máxima verosimilitud el objetivo es elegir los valores de los parámetros  $\Theta$  que maximicen la función de verosimilitud  $L$ , siendo  $\hat{\Theta}$  la mejor selección de nuestros parámetros tal y como expresa la Ecuación 19.


$$\hat{\Theta} = \underset{\Theta}{\operatorname{argmax}} L(\Theta) \quad (19)$$

Se parte de que es que puesto el el logaritmo es una función monótona, el *argmax* del logaritmo de la función es igual al *argmax* de la función original. Esto resulta una ventaja de cara al cálculo de verosimilitud usaremos la verosimilitud logarítmica (log-likelihood), dicha magnitud  $LL$  se expresa en la Ecuación 20 como una suma de verosimilitudes logarítmicas.

$$LL(\Theta) = \log \prod_{i=1}^n f(X_i|\Theta) = \sum_{i=1}^n \log f(X_i|\Theta) \quad (20)$$

Tomaremos como parámetros cada una de las distribuciones de las diferencias logarítmicas de los precios  $P_t$  mensuales resultado del proceso estimadas como  $\log \text{diff}_{t-1,t} = \log(P_t/P_{t-1}) = \log(P_t) - \log(P_{t-1})$ , y estimaremos la verosimilitud con respecto a las diferencias de la serie de oferta. Esperamos que la probabilidad de una variación igual o menos extrema que este valor (usamos una función normal), calculamos los parámetros desviación estándar y media para la distribución de los retornos logarítmicos al cuadrado, para estimar los parámetros de la distribución normal que la representaría usamos el paquete R (Delignette-Muller, Dutang, and others 2015).

La distribución original de alquiler es simétrica como muestra la la Figura 7, y distribución normal obtenida aproxima bien la frecuencia de retornos original, con parámetros desviación típica 0.065 y media 0.



**Figura 7.** Función de densidad de las diferencia logaritmicas en las series mensuales de oferta.  
Fuente: elaboración propia.

En nuestro caso se establece la verosimilitud de la serie final como una verosimilitud combinada de varios sucesos:

- *Verosimilitud de que la variación frontera* medida como diferencia logaritmica del índice entre diciembre y enero sea creible (tomando como referencia la distribución de la diferencia logaritmicas de la serie indicadora).
- *Verosimilitud de la distribución* de las diferencias logaritmicas.
- *Verosimilitud de las discrepancias* entre la serie generada y la serie indicadora.
- *Verosimilitud de la serie en términos de positividad*, dado que algunos métodos de regresión pueden ofrecer valores negativos, ante la aparición de un número negativo asociaremos a la serie una verosimilitud muy baja,  $10^9$ , de forma que la serie se descartará por este motivo.

La verosimilitud combinada se calcula como la suma de las verosimilitudes en escala logaritmica, que es equivalente al producto entre las probabilidades de todas las verosimilitudes.

#### 4.4 Métodos de desagregación temporal

El proceso se describe en el Algoritmo 1, donde  $Lik_c(Serie'_{output,M})$  se refiere a la función de verosimilitud sobre la serie  $Serie'_{output,M}$  con el criterio  $c$ . La serie  $Serie'_{output,M}$  representa la serie generada a partir con el método *Método*. Finalmente el resultado para cada zona  $Z$  se almacena en la serie  $Serie[Z]_{output}$ .

**for**  $Z \in Zonas$  **do**

$Serie_{indicadora} = Serie[Z]_{oferta,mensual}$

$Serie_{input} = Serie[Z]_{oferta,anual}$

**for**  $M \in Metodos$  **do**

$Serie'_{output,M} =$

$desagregación\ temporal(M, Serie_{indicadora}, Serie_{input})$

$LogLik_M = P_{Criterios}$

$clog\ Lik_c(Serie'_{output,M})$

**end**

$M_{output} = argmax_M Lik_{output,M}$

$Serie[Z]_{output} = Serie'_{output,M_{output}}$

**end**

**Algorithm 1:** Algoritmo de cálculo de selección de series por máxima verosimilitud

## 5. Análisis de resultados

Se ha aplicado la metodología las series desagregadas temporalmente con los cinco métodos candidatos de la 2 para las series de alquiler y oferta de 147 zonas de la Comunidad de Madrid. Para cada una de las zonas de análisis se obtienen cinco nuevas series de frecuencia mensual de alquiler a partir en la serie anual original, como observamos en Figura 8 para el caso del barrio de Numancia en la ciudad de Madrid, de las cuales se selecciona una de ellas como la más

verosímilsegún los principios de calidad del Epígrafe 4.3.



**Figura 8.** Desagregación mensual del precio del alquiler. Zona: Numancia (Madrid). Fuente: elaboración propia.

En la Tabla 3 se muestran los valores medios de las tres de las métricas principales de calidad de la desagregación temporal. Se observa como las series seleccionadas como de máxima verosimilitud ofrece unos valores cercanos a las medias más reducidas en los tres criterios. Sin embargo también se aprecia como existen métodos que ofrecen mejores medidas en criterios individuales. Por ejemplo las aproximaciones autorregresivas ofrecen un buen comportamiento en el criterio de frontera anual, siendo el método Litterman Maxlog el que menores cambios máximos muestra. Por otro lado es el método Causey Trager el que muestra un menor nivel de discrepancia. En general podemos observar como no existe ningún método de los cinco que sea claramente superior y el de máxima verosimilitud ofrece un valor bajo en todos los criterios. Además se observa como los métodos autorregresivos incurren en valores negativos en las series.

**Tabla 3.** Métricas de calidad principales por cada método. Serie índice de precios de alquiler desagregadas.

**Método Media frontera Máximo frontera Media discrepancia**

Causey Tragger 0.058 0.141 0.027 Chow Lin Maxlog 0.055 0.135 0.028 Denton Cholette 0.061 0.152 0.028  
Dynamic Maxlog 0.047 0.140 0.031 Litterman Maxlog 0.047 0.119 0.029

Max. verosimilitud 0.050 0.124 0.028 21

Si estudiamos los rangos intercuartílicos de los distintos métodos para las tres medidas, observamos en la Figura 9 se observa como los métodos autorregresivos Litterman y Dynamic maxlog ofrecen un nivel de variabilidad ligeramente mayor con una tendencia a producir valores extremos. Un elemento a destacar de las series seleccionadas como de máxima verosimilitud es que el número de puntos atípicos (marcados como círculos en el diagrama) es menor en esta técnica.




Figura 9. Comparación de métricas clave según los diferentes métodos. Fuente: elaboración propia.

Si se realiza un desglose sobre cual es la distribución de métodos seleccionados por tipo de índice de precios: oferta, alquiler y combinada, para el caso combinado observamos en la Tabla 4 que las series candidatas basadas en métodos autoregresivos representan un 85%, también se observa que cuando los métodos ganadores no son autoregresivos los valores frontera tienden a ser altos pero con discrepancias bajas.

Tabla 4. Métodos seleccionados para todas las series, índices de precios de alquiler y oferta.

Método	% casos	Media frontera	Discrepancia mensual
Dynamic Maxlog	39%	0.025	0.033
Litterman Maxlog	30%	0.035	0.036
Chow Lin Maxlog	15%	0.048	0.027
Causey Tragger	9%	0.051	0.023
Denton Cholette	6%	0.057	0.025

En la Tabla 5 vemos los resultados para las series de oferta, de la misma manera que en el caso anterior vemos como los métodos candidatos siguen el mismo orden concentrándose mucho más los métodos en los autorregresivos con un 94% de los casos. Y por otro lado se observa que también que Denton

y Causey Trager se seleccionan cuando la media frontera son altas.

**Tabla 5.** Métodos seleccionados para todas las series, índice de precios de oferta.

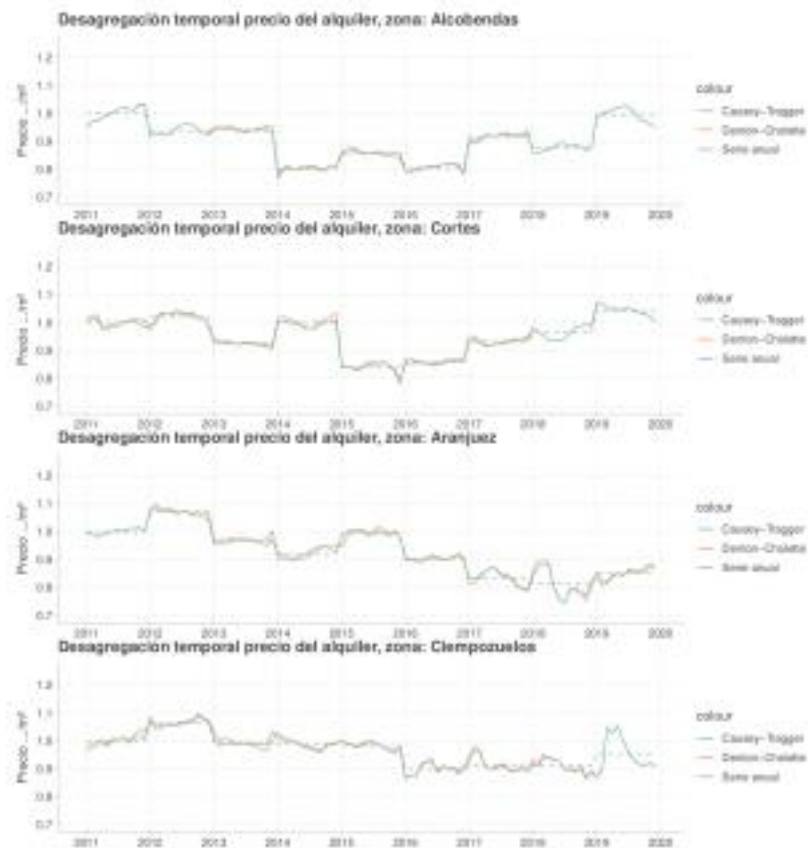
<b>Método</b>	<b>% casos</b>	<b>Media frontera</b>	<b>Discrepancia mensual</b>
Dynamic Maxlog	51%	0.020 0.035	Litterman Maxlog 39% 0.028 0.034
Chow Lin			
Maxlog	3%	0.035 0.032	Causey Trager 3% 0.047 0.027
Denton Cholette	3%	0.035 0.023	

Finalmente para el caso de la desagregación solamente de las series de alquiler, se observa en la Tabla 6 que existe una mayor dispersión entre métodos y los métodos autoregresivos logran un 70% de los casos. La principal diferencia con el caso de oferta y combinado es que Chow-Lin es el método más utilizado y el método no paramétrico Causey Trager logra actuar en un 21% de los casos.

**Tabla 6.** Métodos seleccionados para todas las series, índice de precios de alquiler.

<b>Método</b>	<b>% casos</b>	<b>Media frontera</b>	<b>Discrepancia mensual</b>
Chow Lin	33%	0.050 0.026	Dynamic Maxlog 24% 0.039 0.028
Causey Trager	21%	0.052 0.023	Litterman Maxlog 15% 0.056 0.042
Denton Cholette	9%	0.067 0.026	

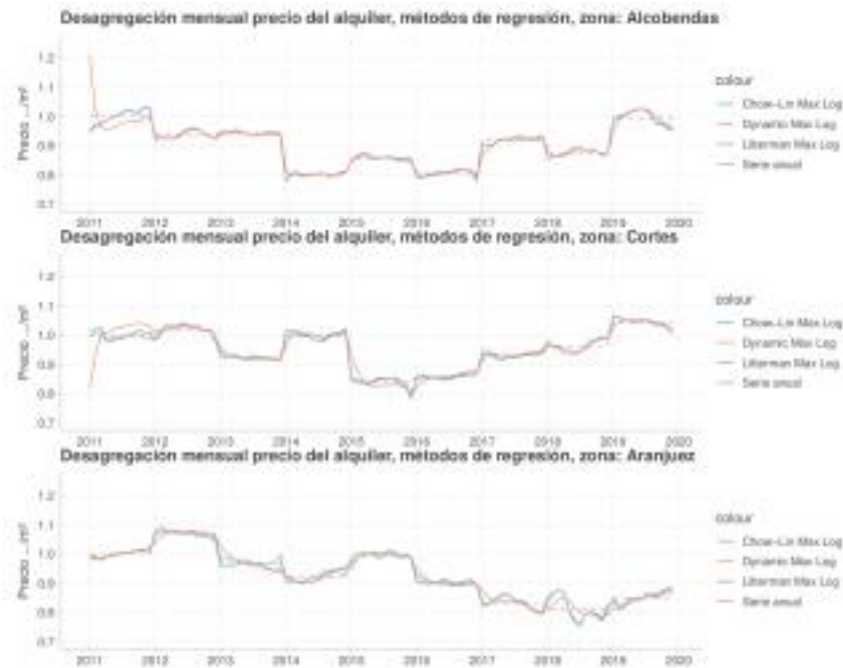
En un análisis detallado de los métodos no autorregresivos, observamos como series generadas por los métodos Causey-Trager y Denton-Cholette muestran problemas para suavizar las transiciones en el cambio de año, como vemos en la Figura 10.



**Figura 10.** Modelos de desagregación no paramétricos: Denton y Causey-Trager. Fuente: elaboración propia.

Los resultados de los métodos de regresión muestran una mayor capacidad de suavizar las transiciones anuales, como se observa en la Figura 11. En el caso del método Dynamic Maxlog no es infrecuente encontrar valores extremos al inicio de las series, no con la misma frecuencia que el método Denton original, y que nos hizo descartar el método, en cambio muestra transiciones suaves entre los meses de diciembre y enero, aunque como veíamos en la Tabla 3 no es el método que peores valores muestra en las medidas de frontera.





**Figura 11.** Modelos de desagregación temporal basados en regresión. Fuente: elaboración propia.

Una ventaja de los métodos paramétricos, es la posibilidad de estudiar la bondad del ajuste a través del  $R^2$  del modelo y la complejidad del modelo a través del AIC<sup>9</sup>, en la Tabla 7 se observa que Dynamic y Chow-Lin ofrecen los niveles de ajuste mejores para las dos series, al contrario que Litterman que muestra un comportamiento peor tanto en términos de  $R^2$  y AIC. Sin embargo Litterman es un método menos seleccionado que Chow-Lin en el cómputo global como veíamos en la Tabla 4, pero que se debe la mayor capacidad de Litterman de gestionar las transiciones entre años, a pesar de tener peores niveles de ajuste.

**Tabla 7.** Parámetros principales de las diferencias logarítmicas.

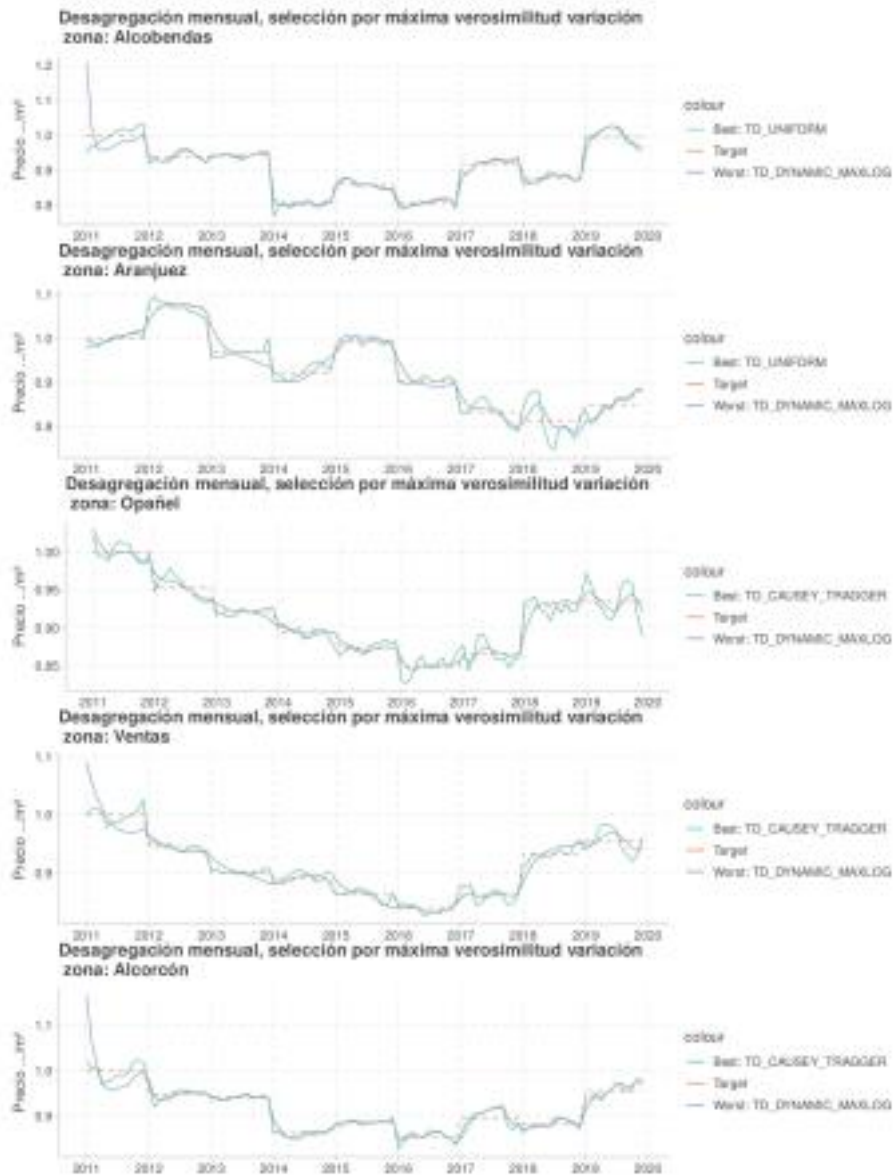
**Variable Método R2 AIC**

Índice de Alquiler Dynamic Maxlog 0.880 -6.140 Índice de Alquiler Chow Lin Maxlog 0.848 -6.279  
 Índice de Alquiler Litterman Maxlog 0.694 -10.299 Índice de Oferta Dynamic Maxlog 0.946 -6.583  
 Índice de Oferta Chow Lin Maxlog 0.922 -6.738

<sup>9</sup>Criterio de información de Akaike.

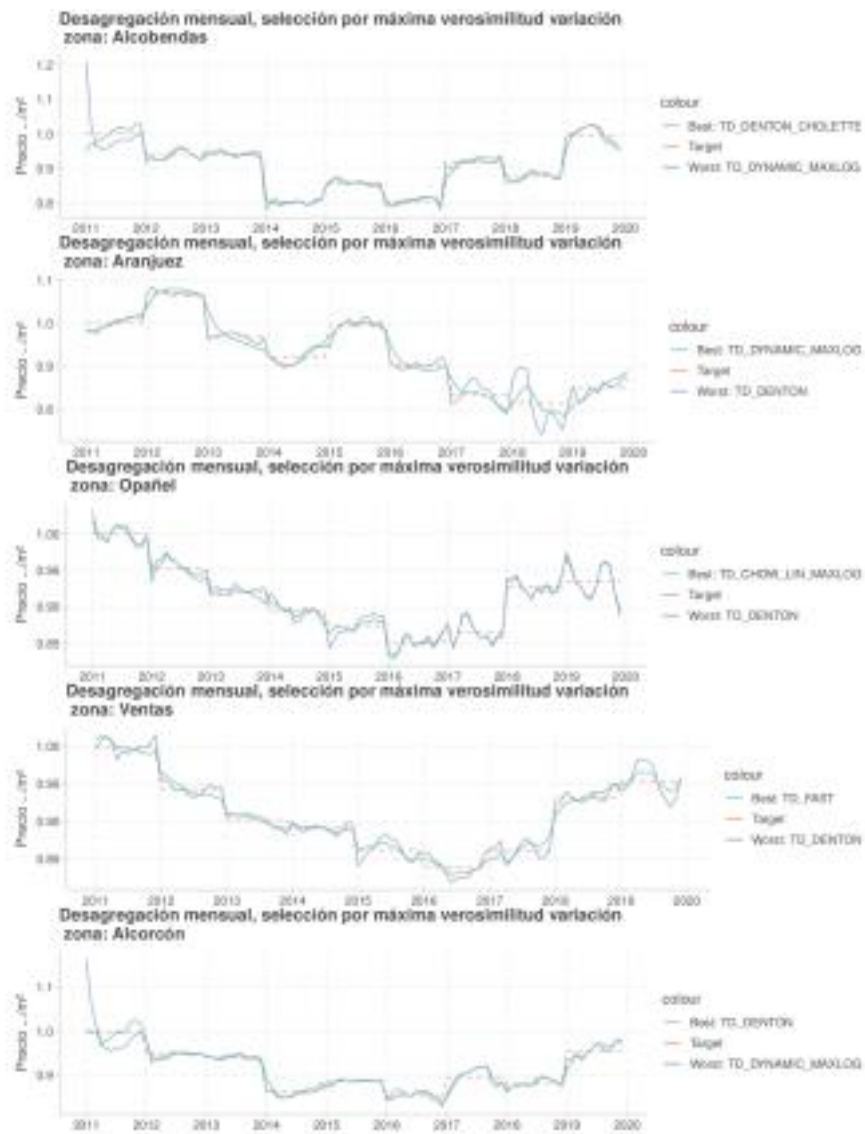
La decisión de seleccionar una serie u otra está condicionada a la verosimilitud

de la serie según una combinación de criterios. Para analizar la influencia de cada criterio, a continuación comparamos de forma visual el comportamiento de las series generadas si hubieramos seleccionado alguno de los distintos criterios. En la Figura 12 se representa el peor y el mejor método usando el criterio combinado.



**Figura 12.** Comparativa selección series por criterio de verosimilitud, mejor y peor serie por zona, cambio de año. Fuente: elaboración propia.

La Figura 13 selecciona la mejor y peor serie usando el criterio de discrepancia de valores mensuales.



**Figura 13.** enchart selección series por criterio de verosimilitud, mejor y peor serie por zona, cambio de año. Fuente: elaboración propia.

Y finalmente en la Figura 14 se muestra el gráfico de la mejor serie seleccionada usando un criterio de diferencia frontera.

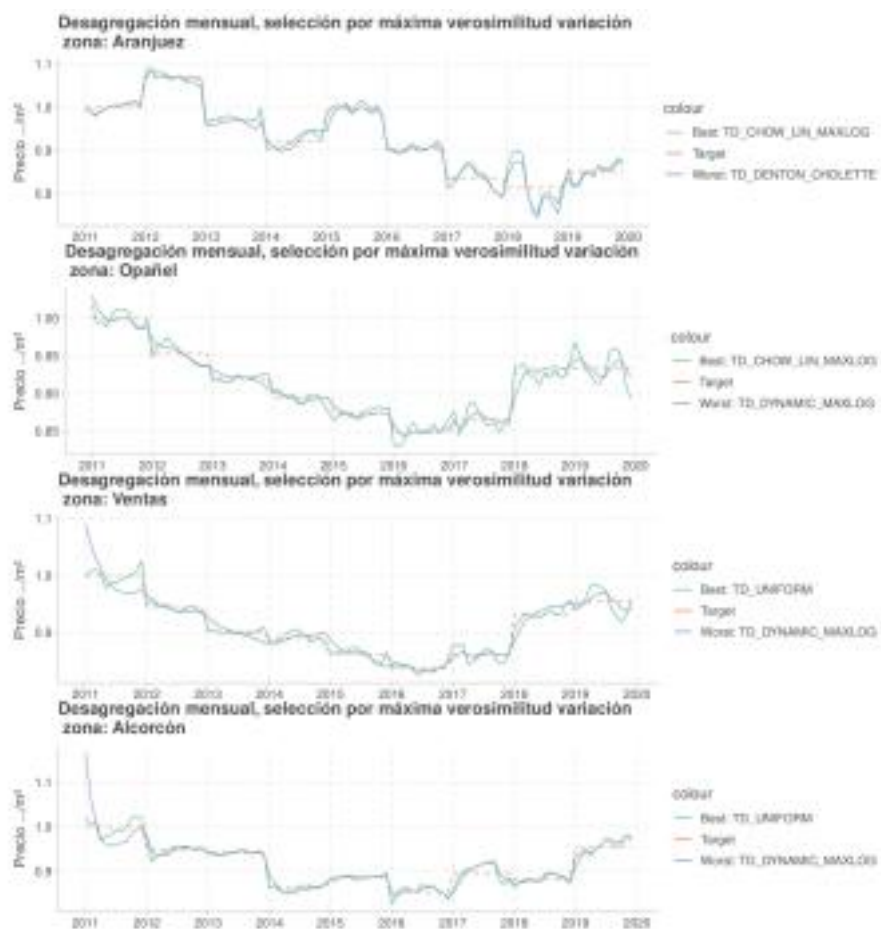


Figura 14. enchmark selección series por criterio de verosimilitud, mejor y peor serie por zona, criteri frontiera. Fuente: elaboración propia.

## 6. Conclusiones y siguientes pasos

La metodología propuesta ofrece un método eficiente para seleccionar la técnica de desagregación de series temporales de series temporales univariantes de baja frecuencia, es especialmente interesante para aquellas situaciones, como la del caso de estudio, el número de series a desagregar es muy alto y la alternativa de hacerlo manualmente, caso por caso, tendría un coste en tiempo y personal muy elevado. El método intenta seleccionar un método que garantice que el conjunto indicadores de calidad de la serie sean los favorables posible, y el método de verosimilitud ofrece una forma de combinar de forma sencilla criterios de diferente naturaleza. Sin embargo, el inconveniente principal de esta primera aproximación, es trata de la misma manera todos los criterios y es probable que algunos puedan tener un impacto mayor en la calidad.

Por consiguiente, una primera línea de investigación posterior se centrará en mejorar el proceso combinando los distintos criterios de verosimilitud, de forma que pueda tomar en cuenta distintos pesos según el criterio y naturaleza de la

serie de entrada. La segunda línea de trabajo estará centrada en extender este método a modelos de desagregación temporal multivariante.

## 7. Referencias

- Barbone, Luca, Giorgio Bodo, and Ignazio Visco. 1981. "Costi e Profitti Nell'industria in Senso Stretto: Un'analisi Su Serie Trimestrali, 1970-1980." *Bollettino Della Banca d'Italia* 36: 465–510.
- Chen, Baoline. 2007. "An Empirical Comparison of Methods for Temporal Disaggregation at the National Accounts." *Office of Directors Bureau of Economic Analysis, Washington, DC*.
- Cholette, Pierre A, and Estela Bee Dagum. 1994. "Benchmarking Time Series with Autocorrelated Survey Errors." *International Statistical Review/Revue Internationale de Statistique*, 365–77.
- Chow, Gregory C, and An-loh Lin. 1971. "Best Linear Unbiased Interpolation, Distribution, and Extrapolation of Time Series by Related Series." *The Review of Economics and Statistics*, 372–75.
- Dagum, Estela Bee, and Pierre A Cholette. 2006. *Benchmarking, Temporal Distribution, and Reconciliation Methods for Time Series*. Vol. 186. Springer Science & Business Media.
- Delignette-Muller, Marie Laure, Christophe Dutang, and others. 2015. "Fitdistr plus: An r Package for Fitting Distributions." *Journal of Statistical Software* 64 (4): 1–34.
- Denton, Frank T. 1971. "Adjustment of Monthly or Quarterly Series to Annual Totals: An Approach Based on Quadratic Minimization." *Journal of the American Statistical Association* 66 (333): 99–102.
- Eurostat. 2013. "Handbook on Quarterly National Accounts." ———. 2015. *ESS Guidelines on Temporal Disaggregation : Benchmarking and Reconciliation*.
- Fernandez, Roque B. 1981. "A Methodological Note on the Estimation of Time Series." *The Review of Economics and Statistics* 63 (3): 471–76.
- Hood, Catherine C Harvill. 2005. "An Empirical Comparison of Methods for Benchmarking Seasonally Adjusted Series to Annual Totals." *Proceedings of the American Statistical Association, Business and Economic Statistics Section.[CD-ROM]* [Http://Www. Census. Gov/Ts/Papers/Chood\\_asa2005. Pdf](http://www.census.gov/ts/papers/chood_asa2005.pdf).
- INE. 2018. "Instituto Nacional de Estadística <http://www.ine.es>." Litterman, Robert B. 1983. "A Random Walk, Markov Model for the Distribution of Time Series." *Journal of Business & Economic Statistics* 1 (2): 169–73.
- Moauero, Filippo, and Giovanni Savio. 2005. "Temporal disaggregation using multivariate structural time series models." *The Econometrics Journal* 8 (2): 214–34. <https://doi.org/10.1111/j.1368-423x.2005.00161.x>.

- Paige, Christopher C. 1979. "Fast Numerically Stable Computations for Generalized Linear Least Squares Problems." *SIAM Journal on Numerical Analysis* 16 (1): 165–71.
- Sax, Christoph, and Peter Steiner. 2013. "Temporal disaggregation of time series." *R Journal* 5 (2): 80–87. <https://doi.org/10.32614/rj-2013-028>.
- Silva, JMC Santos, and FN Cardoso. 2001. "The Chow-Lin Method Using Dynamic Models." *Economic Modelling* 18 (2): 269–80.

