



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



Departamento de Estadística
e Investigación Operativas Aplicadas
y Calidad

TESIS DOCTORAL

Predicción a corto plazo de la demanda horaria de
energía eléctrica en España mediante modelos
optimizados de Holt-Winters múltiple-estacionales

Programa de Doctorado en Estadística y Optimización



Presentada por:

Oscar Trull Domínguez

Dirigida por:

Juan Carlos García Díaz

Valencia, septiembre de 2019.

“La vida debe ser comprendida hacia atrás.
Pero debe ser vivida hacia delante”.

Kierkegaard.

A Marc, Clara, Amaya
A mis padres y hermana.

AGRADECIMIENTOS

Quiero agradecer a mi familia el apoyo dado durante todo este largo proceso. Sin lugar a dudas, no ha sido fácil convivir con esta tarea. Amaya, Marc y Clara. Muchas gracias.

Por supuesto, gracias a Juan Carlos. Amigo y Director. Ha habido momentos dulces y difíciles, pero este trabajo ha salido adelante gracias a ti.

Ángel, estoy en deuda contigo por el incansable apoyo que siempre me has dado. Muchas gracias, amigo.

Alicia, gracias por saber orientar algunas de mis ideas que me ayudó a saber publicar.

RESUMEN

La desregulación del sector de la electricidad producido por la Ley 54/1997 del Sector Eléctrico provocó un cambio radical en el sistema de gestión de la electricidad, tanto para los productores y distribuidores, como para los propios consumidores. España lideraba un cambio en la política energética buscando una liberalización del mercado en aplicación de la Directiva 96/92/CE del Parlamento Europeo y del Consejo. En este cambio, el Estado abandona la noción de servicio público para el sistema eléctrico y pasa a gestionarse mediante un mercado mayorista operado por sociedades mercantiles. Este cambio se traduce en que la gestión del sistema se realiza mediante un sistema de mercados de oferta y de demanda, y que el Estado únicamente establecerá la regulación pertinente.

Dentro del mismo cambio, se organiza el sistema de modo que aparece el transportista único del sistema, Red Eléctrica de España. Originalmente, este ente debe asegurar el suministro y realizar la panificación de la operativa del sistema, pero con la Ley 17/2007 de la adaptación del sector eléctrico se convierte en el transportista único del sistema. La Ley 24/2013, de 26 de diciembre, del Sector Eléctrico además le atribuye aún mayor responsabilidad, siendo el único operador del transporte y del sistema, adquiriendo la necesidad de realizar previsiones de demanda eléctrica que serán utilizadas en el mercado eléctrico, y, además, de precios de la energía. Estas previsiones se realizan habitualmente mediante la utilización de técnicas de series temporales, utilizando modelos de regresión, ARIMA, redes neuronales o de suavizado exponencial.

Debido a que la energía eléctrica no es fácilmente acumulable, la producción debe estar ajustada a la demanda. Cualquier desfase entre ambas provoca costes enormes que las empresas del sector eléctrico necesitan evitar. Para ello,

demandan predicciones del consumo lo más acertadas y fiables posibles.

Esta tesis se centra en el estudio de los modelos de Holt-Winters para ser utilizados en la previsión de demanda eléctrica en España. Estos modelos han demostrado ser sencillos de trabajar y robustos frente a variaciones no controladas y han sido adaptados para trabajar con múltiples estacionalidades. Con ello se han desarrollado nuevos modelos que han permitido mejorar las previsiones.

En primer lugar, se estudia la demanda eléctrica en España, como eje fundamental para el desarrollo de la tesis. Se observa cómo la serie dispone de unas características muy relevante: una frecuencia de 24 horas, con una media y varianza que no son constantes. Se observa la presencia de varias estacionalidades que se integran en el modelo, así como una enorme influencia de los días festivos y fines de semana. Por último, se detecta una alta volatilidad. Este análisis permite conocer el comportamiento de la serie e introducir los modelos múltiple-estacionales.

En segundo lugar, se presentan y analizan los modelos de Holt-Winters múltiple-estacionales, como eje vertebrador de la tesis. Estos modelos son los desarrollados en la tesis para conseguir sus objetivos: se presentan los modelos, se analizan los valores iniciales y la optimización de los parámetros, y finalmente se analizan los parámetros.

Finalmente se introducen nuevos elementos en los modelos que permiten mejorar las previsiones realizadas por los mismos. En este aspecto, se incluye la introducción de estacionalidades discretas que permiten modelizar los días festivos; se introducen indicadores turísticos que mejora la previsión en las zonas cuyo producto interior bruto depende altamente del turismo; finalmente, se introduce un modelo híbrido en el que las condiciones climáticas son consideradas y que aumenta la precisión de las previsiones.

Por último, esta tesis viene acompañada de un desarrollo de software específico para la explotación del modelo, desarrollado como Toolbox de MATLAB®.

En definitiva, se desarrollan e implantan nuevos modelos de Holt-Winters que proporcionan previsiones a corto plazo más acertadas, que permiten a los entes formantes del sistema eléctrico una mejor planificación y gestión del sistema eléctrico.

RESUM

La desregulació del sector de l'electricitat produït per la Llei 54/1997, del sector elèctric va provocar un canvi radical en el sistema de gestió de l'electricitat, tant per als productors i distribuïdors, com per als propis consumidors. Espanya liderava un canvi en la política energètica buscant una liberalització del mercat aplicant la Directiva 96/92/CE del Parlament Europeu i del Consell. En aquest canvi, l'Estat abandona la noció de servei públic per al sistema elèctric i passa a gestionar-se mitjançant un mercat majorista operat per societats mercantils. Aquest canvi es tradueix en que la gestió del sistema es realitza mitjançant un sistema de mercats d'oferta i de demanda, i que l'Estat únicament ha d'establir la regulació pertinent.

Dins el mateix canvi, s'organitza el sistema de manera que apareix el transportista únic del sistema, Red Eléctrica de España. Originalment, aquest ens ha d'assegurar el subministrament i realitzar la panificació de l'operativa del sistema, però amb la Llei 17/2007 de l'adaptació del sector elèctric es converteix en el transportista únic del sistema. La Llei 24/2013, de 26 de desembre, del sector elèctric a més li atribueix a REE ser l'operador únic del transport i del sistema, adquirint encara més gran responsabilitat i la necessitat de realitzar previsions de demanda elèctrica que seran utilitzades en el mercat elèctric, i, a més, de preus de l'energia. Aquestes previsions es fan habitualment mitjançant la utilització de tècniques de sèries temporals, utilitzant models de regressió, ARIMA, xarxes neuronals o de suavitzat exponencial.

A causa de que l'energia elèctrica no és fàcilment acumulable, la producció ha d'estar ajustada a la demanda. Qualsevol desfasament entre les dues provoca costos enormes que les empreses del sector elèctric necessiten evitar. Per a això,

demanen prediccions del consum el més encertades i fiables possibles.

Aquesta tesi se centra en l'estudi dels models de Holt-Winters per ser utilitzats en la previsió de demanda elèctrica a Espanya. Aquests models han demostrat ser senzills de treballar i robustos davant de variacions no controlades i han estat adaptats per treballar amb múltiples estacionalitats. Amb això s'han desenvolupat nous models que han permès millorar les previsions.

En primer lloc, s'estudia la demanda elèctrica a Espanya, com a eix fonamental per al desenvolupament de la tesi. S'observa com la sèrie disposa de característiques molt rellevants: una freqüència de 24 hores, amb una mitjana i variància que no són constants. S'observa la presència de diverses estacionalitats que s'integren en el model, així com una enorme influència dels dies festius i caps de setmana. Finalment, es detecta una alta volatilitat. Aquesta anàlisi permet conèixer el comportament de la sèrie i introduir els models múltiple estacionals.

En segon lloc, es presenten i s'analitzen els models de Holt-Winters múltiple estacionals, com a eix vertebrador de la tesi. Aquests models són els desenvolupats en la tesi per aconseguir els seus objectius: es presenten els models, s'analitzen els valors inicials i l'optimització dels paràmetres, i finalment s'analitzen els paràmetres.

Finalment s'introdueixen nous elements en els models que permeten millorar les previsions realitzades pels mateixos. En aquest aspecte, s'inclou la introducció de estacionalitats discretes que permeten modelitzar els dies festius; s'introdueixen indicadors turístics que millora la previsió en les zones el producte interior brut depèn altament del turisme; finalment, s'introdueix un model híbrid en el qual les condicions climàtiques són considerades i que augmenta la precisió de les previsions.

Addicionalment, aquesta tesi ve acompanyada d'un desenvolupament de programari específic per a l'explotació del model, desenvolupat com Toolbox de Matlab®.

En definitiva, es desenvolupen i implanten nous models de Holt-Winters que proporcionen previsions a curt termini més encertades, que permeten als ens formants del sistema elèctric una millor planificació i gestió del sistema elèctric.

ABSTRACT

The deregulation of the electricity sector produced by Law 54/1997 of the Electricity Sector caused a radical change in the electricity management system, both for producers and distributors, and for the consumers themselves. Spain was leading a change in energy policy seeking a liberalization of the market by applying Directive 96/92/EC of the European Parliament and the Council. In this change, the State abandons the notion of public service for the electrical system and it is managed through a wholesale market operated by mercantile companies. This change means that the management of the system is carried out through a system of supply and demand markets, and that the State will only establish the relevant regulation.

Within the same change, the system is organized so that the single transporter of the system, Red Eléctrica de España, appears. Originally, this entity must ensure the supply and carry out the baking of the operation of the system, but with the law 17/2007 of the adaptation of the electricity sector becomes the only carrier of the system. Law 24/2013, of December 26, of the Electricity Sector also gives it even greater responsibility, acquiring the need to make forecasts of electric demand that will be used in the electricity market, and, in addition, of energy prices. These forecasts are usually made through the use of time series techniques, using regression models, ARIMA, neural networks or exponential smoothing.

Because electric power is not easily accumulated, production must be adjusted to the demand. Any gap between the two causes huge costs that companies in the electricity sector need to avoid. For this, they demand predictions of consumption as accurate and reliable as possible.

This thesis focuses on the study of Holt-Winters models to be used in forecasting electricity demand in Spain. These

models have proven to be simple to work and robust against uncontrolled variations and have been adapted to work with multiple seasons. This new models have been developed that have improved forecasts.

In the first place, the electrical demand in Spain is studied, as a fundamental axis for the development of the thesis. It is observed how the series has very relevant characteristics: a frequency of 24 hours, with a mean and variance that are not constant. It is observed the presence of several seasons that are integrated into the model, as well as a huge influence of holidays and weekends. Finally, high volatility is detected. This analysis allows to know the behavior of the series and introduce the multiple seasonal models.

Secondly, seasonal multiple Holt-Winters models are presented and analyzed as the backbone of the thesis. These models are those developed in the thesis to achieve their objectives: the models are presented, the initial values and the optimization of the parameters are analyzed, and finally the parameters are analyzed.

Finally, new elements are introduced in the models that allow improving the forecasts made by them. In this aspect, the introduction of discrete seasonings that allow modeling holidays is included; Tourist indicators are introduced that improve forecasting in areas whose gross domestic product depends highly on tourism; finally, a hybrid model is introduced in which the climatic conditions are considered and which increases the accuracy of the forecasts.

Additionally, this thesis is accompanied by a development of specific software for the exploitation of the model, developed as MATLAB® Toolbox.

In short, new models of Holt-Winters are developed and implemented that provide more accurate short-term forecasts,

which allow the entities that form the electrical system to better plan and manage the electrical system.

INDICE GENERAL

1. Introducción.....	1
1.1. Justificación	1
1.2. Objetivos	4
1.3. Contribuciones	4
1.3.1. Congresos.....	5
1.3.2. Publicaciones	7
1.3.3. Software.....	9
2. Análisis de la demanda eléctrica en España	11
2.1. Introducción.....	11
2.2. Sistema eléctrico español.....	12
2.3. El operador del sistema de transmisión.....	17
2.4. Demanda agregada	18
2.5. Demanda Eléctrica a largo y medio plazo	21
2.5.1. Demanda eléctrica a medio plazo.....	24
2.5.2. Demanda a corto plazo	27
2.6. Análisis estacional de la serie	30
2.7. Singularidades de la serie	33
2.7.1. Cambio horario de verano e invierno	33
2.7.2. Efecto calendario	36
2.7.3. Efecto de la climatología.....	37
3. Estado del arte.....	39
3.1. Introducción.....	39
3.2. Análisis Bibliométrico.....	39
3.3. Modelos de previsión aplicados a la demanda eléctrica en España.....	42

3.4. Modelos de previsión de demanda basados en series temporales	47
3.4.1. Métodos fundamentales.....	51
3.4.2. Métodos Estadísticos.....	51
3.4.3. Modelos computacionales.....	62
3.5. Suavizado exponencial con modelos de Holt-Winters...	67
3.5.1. Tratamiento de valores faltantes y anómalos.....	74
3.5.2. Precisión y los intervalos de confianza.....	75
3.5.3. Temperatura.....	77
3.6. Competiciones	80
4. Modelos de Holt-Winters múltiple-estacionales	83
4.1. Introducción.....	83
4.2. Justificación.....	84
4.3. Demanda horaria de electricidad en España.....	84
4.4. Revisión bibliográfica.....	87
4.5. Modelos múltiple-estacionales.....	91
4.6. Explotación de los modelos.....	96
4.6.1. Optimización y predicción.....	96
4.7. Aplicación.....	97
4.7.1. Selección del modelo.....	98
4.8. Validación.....	102
4.9. Discusión de los resultados.....	104
5. Métodos de inicialización en los modelos de Holt-Winters múltiple-estacionales	107
5.1. Introducción.....	107
5.2. Justificación.....	108
5.3. Revisión bibliográfica.....	108
5.4. Modelos múltiple-estacionales y los métodos de inicialización.....	110
5.4.1. Métodos para el nivel.....	110
5.4.2. Métodos para la tendencia.....	111
5.4.3. Métodos mixtos.....	113
5.4.4. Métodos para la estacionalidad.....	114

5.5.	Análisis de los métodos propuestos	117
5.5.1.	Marco de trabajo	117
5.5.2.	Resultados.....	120
5.6.	Discusión de los resultados	130
6.	<i>Análisis de los parámetros</i>	<i>131</i>
6.1.	Introducción.....	131
6.2.	Justificación	132
6.3.	Análisis bibliográfico	132
6.4.	Marco de trabajo	134
6.5.	Resultados	137
6.5.1.	Conjunto de datos doble estacional (1998-2003).....	137
6.5.2.	Conjunto de datos doble estacional (2008-2017).....	143
6.5.3.	Conjunto de datos triple estacional	152
6.6.	Discusión de los resultados	154
7.	<i>Modelado de eventos especiales mediante el uso de estacionalidades móviles de intervalo discreto.</i>	<i>157</i>
7.1.	Introducción.....	157
7.2.	Justificación	158
7.3.	Revisión bibliográfica	160
7.4.	Modelos de Estacionalidad móvil de intervalos discretos (DIMS) 163	
7.5.	Método de trabajo con DIMS	167
7.5.1.	Obtención de los valores iniciales.....	167
7.5.2.	Optimización de los parámetros	170
7.6.	Aplicación	171
7.6.1.	Previsión de la demanda en una huelga	171
7.6.2.	Previsión de la demanda en fiestas de Pascua.....	173
7.6.3.	Previsión de la demanda en días festivos	180
7.7.	Discusión de los resultados	187
8.	<i>Modelos de Holt-Winters con indicadores turísticos</i>	<i>189</i>
8.1.	Introducción.....	189
8.2.	Justificación	189

8.3.	Revisión bibliográfica	190
8.4.	Demanda eléctrica en Mallorca y Menorca.....	192
8.5.	Indicador de presión humana	196
8.6.	Modelo	199
8.7.	Resultados	203
8.8.	Discusión de los resultados	205
9.	<i>Modelo híbrido Holt-Winters múltiple estacional con temperatura</i>	207
9.1.	Introducción.....	207
9.2.	Justificación	208
9.3.	Revisión bibliográfica	208
9.4.	Desarrollo del método de trabajo.....	213
9.5.	Aplicación a la demanda horaria en España	219
9.6.	Discusión de los resultados	222
10.	<i>Conclusiones</i>	223
10.1.	Introducción.....	223
10.2.	Resumen de los resultados.....	223
10.3.	Conclusiones	226
11.	<i>Bibliografía</i>	229
	Bibliografía referenciada	229
	Bibliografía complementaria	266
	<i>Anexo I: Software de implementación</i>	269
	<i>INDICE DE FIGURAS</i>	295
	<i>INDICE DE TABLAS</i>	303

1. Introducción

1

1.1. Justificación

El proceso de desregulación del sector energético español ha producido cambios sustanciales en la forma de gestión y comercialización de la energía eléctrica. Este proceso se remonta al año 1994, cuando se publicó la Ley de Ordenación del Sistema Eléctrico Nacional (Ley 40/1994 de 30 de diciembre, de Ordenación del Sistema Eléctrico Nacional). A partir de su entrada en vigor, el sector se disgregó en 4 funcionalidades distintas de acuerdo a los sectores de negocio establecidos: generación, transmisión, distribución y comercialización. El principal objetivo de esta regularización fue la minoración de los costes de explotación de las entidades, haciendo que cada una de las empresas que participen en uno de los sectores sean responsables de los costes de las mismas, y esperando obtener como consecuencia un mercado más competitivo, eliminando el cártel de la electricidad. Esta ley además otorgó a Red Eléctrica de España (REE) la asignación de la transmisión de la electricidad, siendo el coordinador y regulador del sistema. En Europa este tipo de empresas reciben el nombre de Gestor de la Red de Transporte, u Operador del Sistema de Transmisión, TSO de sus siglas en inglés.

Este proceso fue modificado posteriormente con la entrada en vigor de la Ley del Sector Eléctrico (Ley 54/1997, de 27 de noviembre, del Sector Eléctrico). En ella, se produjo una privatización total de todos los sectores, y REE pasó a ser un operador de transmisión, y las funciones de regulación y coordinación las asumió un nuevo ente denominado Operador del Mercado Eléctrico (OMEL). Las compañías eléctricas volvieron a tener el control sobre su gestión, mientras que REE pasó a ser privatizada y tuvo que adquirir las líneas de distribución de los anteriores propietarios para convertirse en la única propietaria de la red de distribución de alta tensión.

Como consecuencia de esta regulación, actualmente el mercado de la electricidad consta de unos productores que realizan ofertas del precio de la generación de electricidad, donde los distribuidores y comercializadores acuden a comprar, estableciendo un sistema de subastas. Arocena, Kühn y Regibeau (1999) explican cómo esta regulación resultó insuficiente para poder liberalizar el sector, y sugieren una serie de políticas para poder aumentar mejorar el sistema, como promover la entrada de nuevos entes para aumentar la competitividad, aumentar la transparencia e independencia del gestor, regular la distribución y liberalizar las actividades de suministro.

Sin duda, la parte fundamental del sistema eléctrico español recae sobre las previsiones de consumo determinadas para la demanda eléctrica. Y esta actividad es responsabilidad de REE. La compañía está obligada a mostrar a nivel público la demanda eléctrica real y la previsión para las próximas horas. La entrada en vigor de la Ley 24/2013 del Sector Eléctrico, y en concreto el RD 216/2014 de 28 de marzo, determinó que REE debe publicar además el precio voluntario del pequeño consumidor (PVPC) del día siguiente.

El establecimiento de precios de la electricidad es determinado por OMEL a partir de las ofertas realizadas por los

productores, en base a la demanda prevista por REE. Los precios se establecen de forma diaria y semanal.

Dado que la energía eléctrica no es fácilmente acumulable, los procesos de generación y demanda deben casar lo más precisamente posible a fin de evitar diferencias, lo cual produce unas pérdidas económicas nada desdeñables. Hobbs (1999) determina cómo una desviación del 1% en la previsión puede suponer hasta 0,6M\$ y 1,6M€. Tao Hong (2015) profundiza en el cálculo de las pérdidas, y establece una relación de pérdidas de acuerdo a la falta de precisión en la previsión y el tamaño de la instalación. Así para instalaciones del tamaño de 1GW pico de demanda, una mejora de 1% en la precisión de previsión permite ahorrar 600.000\$ anuales.

Las técnicas utilizadas para la previsión de la demanda o del precio de la electricidad se basan en el uso de series temporales, que han demostrado ser eficaces a la hora de realizar la previsión. Estas técnicas vienen desarrollándose desde mediados del siglo pasado, aunque en los últimos años existe un interés creciente, debido entre otras, a las regulaciones ocurridas en los sectores como la anteriormente descrita. Dentro de la amplia gama de herramientas, los modelos ARIMA, los métodos basados en inteligencia artificial y los de suavizado exponencial son los más utilizados para este propósito. Los métodos de suavizado exponencial basados en modelos de Holt-Winters (Winters 1960) han demostrado ser muy apropiados para la previsión de demanda eléctrica (Taylor, de Menezes, y McSharry 2006), además de tener la característica de ser fácilmente manejables y entendibles por el usuario.

Sin embargo, las empresas están demandando herramientas más potentes y eficaces, de modo que mejoren sus previsiones. Ello ha llevado a la inclusión de diferentes comportamientos periódicos en los modelos, así como situaciones excepcionales y condiciones climáticas.

El objetivo principal de esta tesis doctoral es desarrollar modelos de Holt-Winters que permitan predecir, a corto plazo, la demanda horaria de la electricidad en España. El ámbito de aplicación es el mercado intradiario de la energía eléctrica, con un día de antelación, para desarrollar la estrategia óptima con el fin de maximizar los beneficios.

1.2. Objetivos

Para la consecución del objetivo principal se debe realizar un listado detallado de los objetivos a corto plazo que esta tesis desarrolla:

- El análisis de la demanda horaria pone de manifiesto la existencia de patrones estacionales diario, semanal y anual siendo de enorme utilidad, por su sencillez, los métodos de suavizado exponencial conocidos como modelos de Holt-Winters. El primer objetivo es desarrollar un modelo general de Holt-Winters que permita introducir cuantas estacionalidades observemos en la serie de estudio.
- Introducir mejoras en los modelos de modo que las situaciones de días especiales sean atendidas en los modelos.
- Introducir mejoras en los modelos que permitan reflejar la variación de la demanda debido a las variaciones de temperatura.

1.3. Contribuciones

El proceso de creación y difusión de conocimiento de los avances de esta tesis se han ido produciendo de forma gradual a lo largo de los años. Se han realizado una serie de publicaciones y de congresos que se enumeran a continuación.

1.3.1. Congresos

Se listan los congresos con participación y presentación oral de material, así como publicación de actas de congreso.

Congresos internacionales:

International work-conference on Time Series Analysis (ITISE), 2019. García-Díaz, J. C.; Trull, O.; “Double Seasonal Holt-Winters to forecast electricity consumption in a hot-dip galvanizing process”.

VIII Congreso Internacional: Turismo, Economía y Medio Ambiente, 2019. Trull, O.; García-Díaz, J.C. y Peiró-Signes, A.; “Electricity forecasting improvement in a destination using tourism indicators”

International work-conference on Time Series Analysis (ITISE), 2017. Trull, O. y García-Díaz, J. C.; “Multiple seasonal Holt-Winters improvement for the special events forecast using Discrete-Interval Multiple Seasonalities”.

VII Congreso Internacional de Turismo. Economía y medioambiente, 2017. Trull, O.; García-Díaz, J.C. y Peiró-Signes, A.; “Very-short-term Spanish electricity demand forecasting with simple multiple holt-winters methods”.

Mathematical Modelling in Engineering & Human Behaviour, 2017. García-Díaz, J. C. y Trull, O.; “General strike participation rate through electricity demand”.

International Conference of the ERCIM WG on Computational and Methodological Statistics (CMStatistics), 2016. García-Díaz, J. C. y Trull, O.; “Forecasting Spanish electricity demand: Calendar modelling, using discrete intervals mobile seasonalities”.

International work-conference on Time Series Analysis (ITISE), 2015. García-Díaz, J. C. y Trull, O.; “Competitive models for the Spanish Short-term electricity demand forecasting”.

International Conference on Business Management (ICBM), 2015. García-Díaz, J. C. y Trull, O.; “Multiple seasonal Holt-Winters methods Applied to one-day-ahead Spanish electricity demand forecasting”.

Mathematical Modelling in Engineering & Human Behaviour 2014. García-Díaz, J. C. y Trull, O.; “Multiple seasonal Holt-Winters applied to Spanish short-term electricity demand forecasting: an alternative to Red Eléctrica de España model”.

International work-conference on Time Series Analysis (ITISE), 2014. García-Díaz, J. C. y Trull, O.; “Short-term electricity demand forecasting with multiple seasonal patterns in the competitive Spanish daily market”.

Congresos nacionales:

VII Congreso I+D+i Campus de Alcoy “Creando sinergias”, 2019. García-Díaz, J. C. y Trull, O.; “Modelado del consumo eléctrico en una estación de galvanizado en caliente por inmersión en Zinc”.

Congreso Nacional de Estadística e Investigación Operativa (SEIO), 2019. García-Díaz, J. C. y Trull, O.; “Mejora de la previsión a corto plazo de la demanda eléctrica mediante el desarrollo de métodos de Holt-Winters utilizando Estacionalidades Múltiples de Intervalo Discreto (DIMS)”.

VI Congreso I+D+i Campus de Alcoy “Creando sinergias”, 2018. Trull, O. y García-Díaz, J. C.; “mshw: software de demanda eléctrica basado en Holt-Winters Múltiple estacional”.

V Congreso I+D+i Campus de Alcoy “Creando sinergias”, 2017. Trull, O. y García-Díaz, J. C.; “Análisis del efecto de las huelgas generales sobre la previsión de la demanda eléctrica en España”.

IV Congreso I+D+i Campus de Alcoy “Creando sinergias”, 2016. Trull, O. y García-Díaz, J. C.; “Previsión de la demanda eléctrica en España mediante métodos múltiple-estacionales de suavizado Exponencial”.

Congreso Nacional de Estadística e Investigación Operativa (SEIO), 2013. García-Díaz, J. C. y Trull, O.; “Previsión de la demanda eléctrica con patrones múltiple-estacionales: Una aplicación al sistema eléctrico español”.

1.3.2. Publicaciones

Se listan a continuación las publicaciones realizadas en editoriales.

Capítulos de Libro en editoriales destacadas:

García-Díaz, J.C. y Trull, O. “Competitive Models for the Spanish Short-Term Electricity Demand Forecasting” en *Time Series Analysis and Forecasting: Selected Contributions from the ITISE Conference*, 217–231. Editado por Rojas, I. y Pomares, H. Suiza: Springer International Publishing; 2016.

Capítulos de libro en editoriales secundarias:

Trull O.; García-Díaz J.C. y Peiró-Signes A. “Improvement using very-short term electricity demand forecasting with multiple seasonal Holt-Winters methods” en *Tourism, economy and environment new trends and research perspectives*, 181–190, UK: Chartridge Books Oxford, 2017.

Trull O. y García-Díaz J.C., “Multiple seasonal Holt-Winters improvement for the special events forecast using Discrete-Interval Multiple Seasonalities” en Godel Impresiones Digitales S.L., 2017.

Artículos en revistas destacadas (indexadas JCR):

Trull, O.; García-Díaz, J.C. y Troncoso, A; “Application of Discrete-Interval Moving Seasonalities to Spanish Electricity Demand Forecasting during Easter”. *Energies* 2019, 12 (6), 1083.

Trull, O.; Peiró-Signes, A. y García-Díaz, J.C. “Electricity forecasting improvement in a destination using tourism indicators”. *Sustainability* 2019, 11, 3656.

1.3.3. Software

En la actualidad se ha realizado una librería basada en MATLAB® (toolbox) para la realización de los análisis y cálculos de esta tesis. Esta librería no es de libre difusión y no se ha liberado su código.

2. Análisis de la demanda eléctrica en España

2

2.1. Introducción

La realización de previsiones en el mercado eléctrico español es una tarea compleja que requiere de un conocimiento profundo de la demanda eléctrica. Este capítulo estudia y analiza la demanda eléctrica en España, como paso previo al desarrollo de modelos y su explotación.

Primeramente, se presenta el sistema español de la electricidad, con su mercado, agentes participantes y el operador del sistema. Este mercado, pionero a nivel mundial debido a la desregularización llevada a cabo – con sus ventajas y desventajas–, es un modelo a seguir en otros países.

Posteriormente, se presenta al operador del sistema de transporte. Este agente es el elemento central del sistema eléctrico. Su importancia y relevancia adquiere cada día mayor importancia, y es el agente con el que esta tesis comparte objetivo.

Finalmente, se analiza la demanda agregada. La demanda agregada es la base de estudio de esta tesis, y para la cual se desarrollarán los modelos. Se estudia esta serie temporal, analizando sus componentes y comprendiendo su comportamiento.

2.2. Sistema eléctrico español

La generación, distribución y venta de la energía eléctrica en España está consolidada por la acción de diferentes entes que actúan en el mercado español de la Energía. La composición y organización del sistema ha variado desde la democracia, en pro de una mejora de la competitividad y servicio.

Esta reforma ha sido ampliamente criticada por su carácter más privatizador que liberalizador (Arocena, Kühn, y Regibeau 1999; Beato Blanco 2005). Este aspecto provocó que la liberalización perseguida no fuera aceptada de forma efectiva en el mercado, habiendo pocos cambios de comercializadores y unos precios no acordes a un mercado liberalizado (Bel, Calzada, y Fageda 2006; Fabra y Toro 2005). Como consecuencia de estas críticas, el mercado ha ido evolucionando en pro de una mayor competitividad.

Actualmente, el sistema eléctrico español forma parte del sistema ibérico, compartido con la República de Portugal, y denominado Mercado Ibérico de la Electricidad (MIBEL). El mercado ibérico está organizado en dos polos: Uno gestionado por la parte portuguesa (Operador del Mercado Ibérico, polo portugués, OMIP) y otro por la parte española (Operador del Mercado Ibérico, polo español, OMIE). Cada uno de estos polos están participados al 50% por los antiguos operadores del mercado eléctrico de ambos países, que son OMIP SGPS, S.A. por parte portuguesa y OMEL por parte española (Operador del Mercado Eléctrico). Ambas partes crearon en conjunto

OMIClear, una entidad de clearing¹ para la liquidación de operaciones entre ambos polos. Domínguez y Bernat (2007) explican cómo está organizado MIBEL y analizan la evolución del mercado hasta el 2007. Adicionalmente, presentan estudios sobre los tipos de demanda, precios, y los intercambios de energía entre España y Portugal.

En OMIE se determinan los precios mayoristas de la electricidad, denominados mercado SPOT² de la energía. Los precios se establecen mediante el sistema de subasta de la energía eléctrica, en el cual se realiza una casación entre la oferta y la demanda de energía y precios proporcionados por los agentes del mercado. Estos agentes del mercado son entidades físicas o jurídicas que tienen la capacidad de acceder al mercado para producir energía – denominados productores-, comercializarla – comercializadores-, o venderla a consumidores finales (consumidores directos y representantes).

Las subastas se componen de 24 mercados diarios, en los que se subasta la energía hora a hora. Además, existen 6 mercados intradiarios donde se pueden ajustar las ofertas.

El mercado español de la electricidad, OMEL, se organiza mediante un holding de empresas que lo gestionan. Este holding está formado en un 40% del accionariado por empresas del sector eléctrico español, un 60% formado por empresas externas al sector eléctrico. La composición empresarial que actualmente forman OMEL se muestran en la Tabla 2.1. La presencia de tantos agentes de inversión en esta denota el interés por el control de este mercado que reporta más de 15.000 M€ anuales (Omie 2018).

¹ Una entidad de clearing es una cámara de compensación y contraparte central. Estos organismos tienen la función de facilitar el comercio de acciones y derivados en los mercados internacionales.

² El mercado SPOT es aquél donde los activos que se negocian se transfieren de forma inmediata (a muy corto plazo) al precio del mercado en ese instante.

Tabla 2.1. Desglose accionarial de participación en OMEL holding.

SECTOR ELÉCTRICO	Porcentaje	Nº Acciones
ACCIONA ENERGÍA, S.A.U.	5,00%	333.333
ENDESA,S.A.	5,00%	333.333
VIESGO INFRAESTRUCTURAS ENERGÉTICAS S.L.U.	5,00%	333.333
HIDROELÉCTRICA DEL CANTÁBRICO,S.A.	5,00%	333.333
GAS NATURAL SDG,S.A.	5,00%	333.333
IBERDROLA GENERACIÓN ESPAÑA, S.A.U.	5,00%	333.333
SOCIEDAD ANÓNIMA MINERO CATALANA-ARAGONESA (SAMCA)	4,28%	285.620
ASOCIACIÓN ESPAÑOLA DE LA INDUSTRIA ELÉCTRICA (UNESA)	3,14%	209.658
REPSOL PETRÓLEO,S.A.	2,57%	171.420
SUBTOTAL	40,00%	2.666.696
SECTOR NO ELÉCTRICO	Porcentaje	Nº Acciones
REDES ENERGÉTICAS NACIONAIS SGPS,S.A.	10,00%	666.666
OMIP-OPERADOR DO MERCADO IBERICO (PORTUGAL) SGPS,S.A.	9,99%	666.660
BNP PARIBAS, Sucursal en España	5,65%	376.813
BOLSAS Y MERCADOS ESPAÑOLES INNOVA,S.A.	5,65%	376.813
ABENGOA,S.A.	5,31%	354.287
BANCO SANTANDER,S.A.	5,00%	333.333
IBERCAJA BANCO,S.A.U.	4,99%	333.320
ANALISTAS FINANCIEROS INTERNACIONALES, S.A.	4,99%	333.320
BANCO BILBAO VIZCAYA ARGENTARIA,S.A.	4,99%	333.320
PATMINA,S.L.	1,43%	95.320
KARTERA 1,S.L.	0,77%	51.298
SANTANDER INVESTMENT,S.A.	0,65%	43.480
ASOCIACIÓN ESPAÑOLA DE FABRICANTES DE AUTOMÓVILES Y CAMIONES (ANFAC)	0,53%	35.534
SUBTOTAL	60,00%	3.999.964
TOTAL	100,00%	6.666.660

Fuente: OMEL holding (junio de 2018).

Dentro de este sistema, los productores y otros agentes englobados en OMEL son los que ofertan los precios de

electricidad en el mercado OMIE, donde los diferentes agentes se encargan de determinar los precios de compra de la electricidad. Estos precios han subido en España desde el 2010 más de un 70% (Bajet, García, y Mundó 2018).

Para establecer los precios de la electricidad, se utilizan los datos de previsión de demanda proporcionados por el operador del sistema de transmisión, y, desde el año 2017, también la previsión de precios. A partir de esta información el operador del sistema se encarga de realizar la casación de oferta y demanda, partiendo de los precios más baratos hasta igualar a la demanda y así consecutivamente. El proceso es controlado por la Comisión Nacional de los Mercados y la Competencia, con el fin de regular en caso necesario el precio de la energía. Esta particularidad hace que la previsión de demanda eléctrica juegue un papel fundamental en la actividad del mercado.

En la Figura 2.1 se observa el funcionamiento de la casación de precios y demanda en el sistema. Los agentes productores y distribuidores ofertan cantidad y precio de energía tanto a vender como a comprar. OMIE construye la curva de oferta de forma creciente (precios más bajos primero) y la de demanda o venta decreciente (precios más altos primero). A partir de ahí se fija el precio de la electricidad para esta demanda cada hora.

Los productores proporcionan cantidades energéticas a producir con precios de producción, al igual que los distribuidores proponen precios de compra con cantidades energéticas. OMIE realiza las curvas de ofertas y demanda (venta). Para ello, la curva de oferta se construye de modo creciente, incluyendo primero los precios más bajos y sus cantidades. La curva de venta se realiza de modo contrario, decreciente. A partir de aquí, y teniendo en cuenta la demanda eléctrica prevista, se establece un precio de casación.

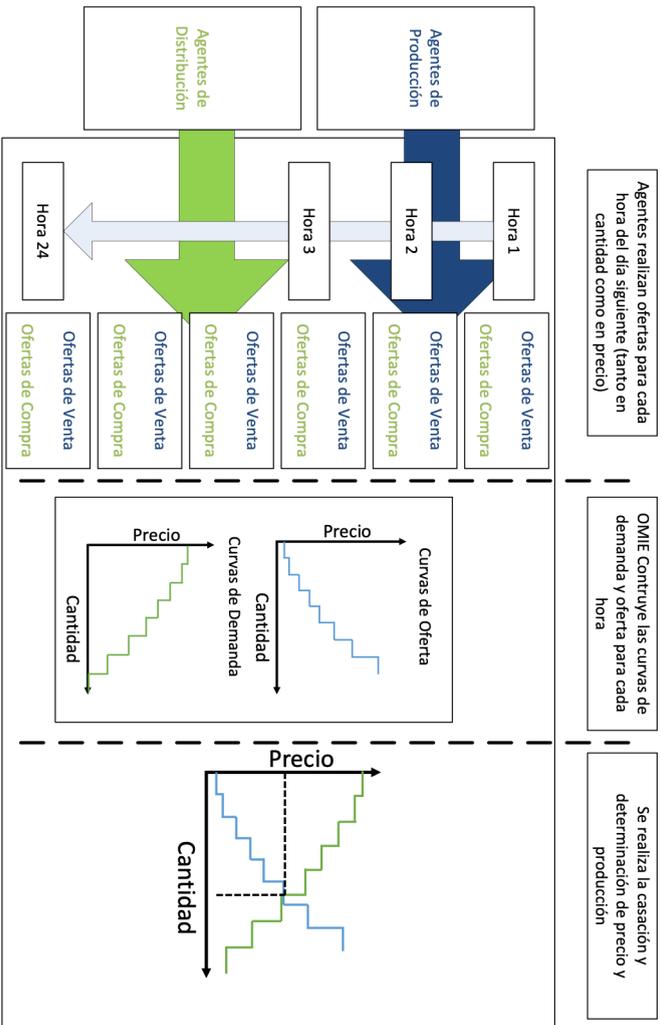


Figura 2.1. Esquema de funcionamiento de la determinación de los precios en función de la demanda por parte de OMIE.

2.3. El operador del sistema de transmisión

Dentro del sistema, existe el gestor de red de transporte u operador del sistema de transmisión, sociedad mercantil que tiene los objetivos de mantener las redes troncales de transporte del país, así como la instalación y expansión de las mismas. En España el operador es Red Eléctrica de España (REE), y que denominamos gestor de la red de transporte. La Tabla 2.2 indica los principales agentes inversores de REE. Se observa cómo el grueso principal del accionariado pertenece a empresas extranjeras.

Tabla 2.2. Datos financieros de Red Eléctrica de España.

Participación	Desglose	Capital Social
SEPI (20%)	SEPI (20%)	270.540.000€
Free Float (80%)	Instituciones	Accionariado
	Extranjeras (66%)	
	Instituciones	
	Nacionales (4%)	
	Minorista (10%)	541.080.000

Fuente: Red Eléctrica de España, Sept. 2019

La historia de REE ha evolucionado con el proceso de liberalización. Inicialmente, el cometido de REE desde su creación en 1985 fue gestionar la correcta transmisión de la electricidad, así como la planificación operacional de los sistemas de producción, teniendo como principal objetivo la fiabilidad del sistema. REE fue la primera empresa creada a tal efecto. Esta empresa pertenecía al SEPI (Sociedad Estatal de Participaciones Industriales).

Con la conversión del sector eléctrico en España, debido en parte a la Ley 54/1997 del Sector Eléctrico, REE se convierte en el Operador de sistema de transmisión, y aumenta sus responsabilidades. Además de gestionar la planificación y distribución de la electricidad en España, es responsable además de la previsión de la demanda que se utilizará en las subastas

energéticas para el establecimiento de precios. Esta reforma ha sufrido grandes críticas desde el comienzo y ha sido considerada con una mala reforma (Arocena, Kühn, y Regibeau 1999; Bazán Navarro 2004; Pérez-Arriaga 2005). Dentro de las críticas, a REE se le critica por no tener un papel y objetivo claro definido en este contexto, a pesar de las conversiones que ha sufrido (Garrués-Irurzun y López-García 2009).

Como contrapartida, en 2010 con la entrada en vigor de la Ley 17/2007 de la adaptación del sector eléctrico a la directiva marco europea, se consolida el papel de REE en el sistema cuando se convierte en el operador único del sistema.

Red Eléctrica de España juega un papel fundamental en la demanda eléctrica en España. Como se ha comentado con anterioridad, no sólo es la responsable del correcto funcionamiento de distribución, sino que además sus previsiones de demanda marcan las ofertas de coste de la electricidad y establece el precio de la misma a través del sistema del mercado OMEL. La información proporcionada por REE se puede disponer a través de la web www.ree.es. Adicionalmente, para el sistema de subastas y ofertas, REE dispone la plataforma e-sios (<https://www.esios.ree.es>) donde se establecen las condiciones operativas contractuales.

Las previsiones y datos proporcionados por REE serán utilizados en esta tesis como base de comparación en gran parte de las ocasiones.

2.4. Demanda agregada

La demanda agregada de electricidad peninsular corresponde a la demanda eléctrica total realizada en la península, incluyendo transacciones entre España y Portugal, Francia, Marruecos y las Islas Baleares. La demanda real se presenta de forma horaria y cada 10 minutos en la región peninsular. Recientemente es posible obtener la misma demanda para Baleares y Canarias, que proporciona incluso con mayor detalle, desagregando la

información por islas. Los datos obtenidos pertenecen a un rango desde julio de 2007 hasta enero de 2018. Estos datos se muestran en la Figura 2.2.

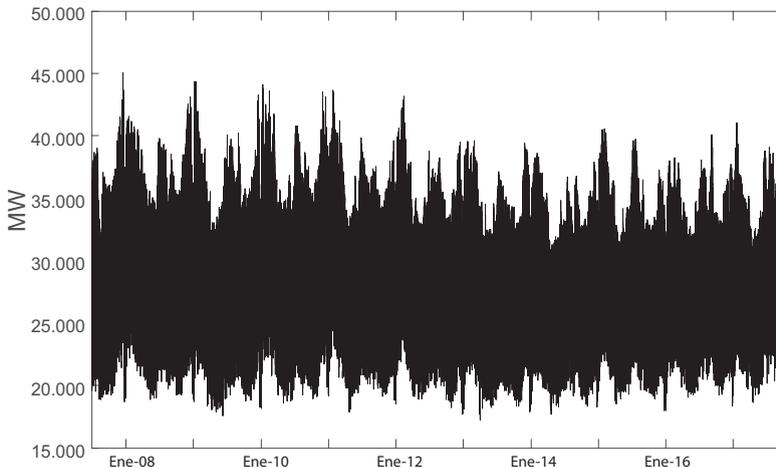


Figura 2.2. Demanda eléctrica horaria agregada en España. Periodo desde julio del 2007 hasta finales del 2017.

Esta forma de representación es habitual en los estudios de la demanda eléctrica. Sin embargo, la resolución de la gráfica no permite apreciar con detalle el comportamiento de la serie. Un análisis más detenido permite apreciar cómo la dispersión en la gráfica se reduce desde los primeros años - desde el 2008 hasta el 2012 - hasta los últimos. Esta situación se produce como consecuencia de la crisis económica del 2008, con una reducción del consumo y aumento de inestabilidad hasta el 2015, donde se aprecia un punto de inflexión.

Adicionalmente, se disponen de los datos horarios de electricidad desde enero de 1998 hasta marzo del 2004. Aunque este periodo queda alejado del presente trabajo, conviene su utilización para realizar comparaciones y comprender la situación actual. Este periodo queda reflejado en la Figura 2.3. Se puede apreciar como el periodo inicial pertenece a un periodo de alto

crecimiento y en la Figura 2.2 a un periodo de estancamiento y crisis.

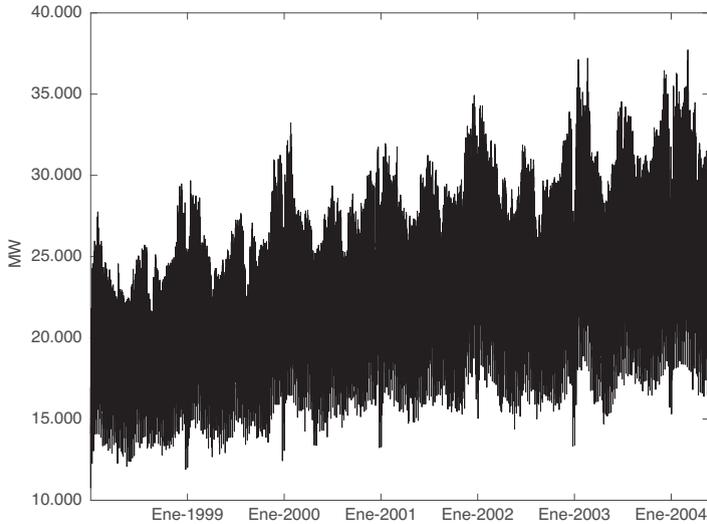


Figura 2.3. Demanda eléctrica horaria en España entre 1998 y mediados de 2004.

Para poder interpretar mejor las características de la serie temporal, se realizan en las siguientes secciones diferentes análisis. Por un lado, se introducen los horizontes de trabajo, y por otro, se analizan los valores desde el más largo plazo. Se entra cada vez más en el detalle, teniendo en cuenta que el objetivo de la tesis es la previsión a corto plazo.

Weron (2006) presenta una clasificación de corto plazo, medio y largo. Para ello utiliza las diferentes necesidades de las compañías eléctricas y cómo requiere la previsión para su gestión. Así pues, encontramos que el corto plazo se utiliza para la programación operacional de las unidades de generación, así como para la determinación de precios. El medio plazo se utiliza para previsiones a varios días vista, incluso semanas. Esta previsión ayuda a determinar riesgos de la previsión y del mercado, y ayuda a determinar precios en el mercado de

derivados, con los costes asociados. El largo plazo se utiliza para previsiones estratégicas en el que los datos utilizados suelen ser mensuales.

Otros autores (Greer 2011) establecen otros tres tipos de horizontes: Horario (previsión a un día), Corto (previsión de 1 a 3 años) y largo (previsiones de hasta 20 años). Esta clasificación tiene su aplicación en los modelos de contrato.

T. Hong y Fan (2016) analizan el problema de la falta de estandarización y establecen una serie de parámetros para poder determinar de qué tipo de horizonte se habla. El resultado se resume en la Tabla 2.3. En esta tabla, la resolución explica el método de obtener los datos, y la distancia entre dos datos. El horizonte determina su uso, y hasta dónde suele llegar la previsión realizada con esta metodología.

Tabla 2.3. Clasificación de los horizontes de previsión y sus características principales.

Plazo	Resolución	Horizonte máximo
Muy Corto	Minutos/Horas	1 día
Corto	Horas/Días	2 semanas
Medio	Días/Meses	3 años
Largo	Meses	Años/décadas

En las siguientes secciones se analiza la demanda eléctrica desde los diferentes puntos de vista del plazo. Esto permitirá entender el comportamiento de la serie y sus características principales.

2.5. Demanda Eléctrica a largo y medio plazo

Para comprobar el comportamiento a largo y medio plazo de la serie, se ha recurrido al análisis de la demanda mensual agregada. La construcción de esta serie a partir de la original obtenida de REE se realiza acumulando el consumo total habido durante el mes correspondiente. A partir de ahí, y siguiendo el mismo

proceso que anteriormente se ha realizado, se divide en dos periodos claramente diferenciados: la Figura 2.4 muestra los datos en el periodo de 1998 a 2004, mientras que la Figura 2.5 muestra los datos para el periodo desde el 2007 hasta 2017. Claramente se puede apreciar la diferencia de tendencia que existe en ambas gráficas.

Comparando estas series entre sí, se puede apreciar como la época de crecimiento trae consigo una tendencia creciente considerable, pero la variabilidad en la estacionalidad de la serie es menor. En la segunda época, como muestra la Figura 2.5, se produce un descenso del consumo, con una tendencia decreciente. La variabilidad en la serie ha aumentado y se muestra más irregular. Comparada con la serie trabajada por Canelo y Espasa situada en los años anteriores a la desregulación (Canelo y Espasa 1996), estas series han aumentado su variabilidad de forma drástica.

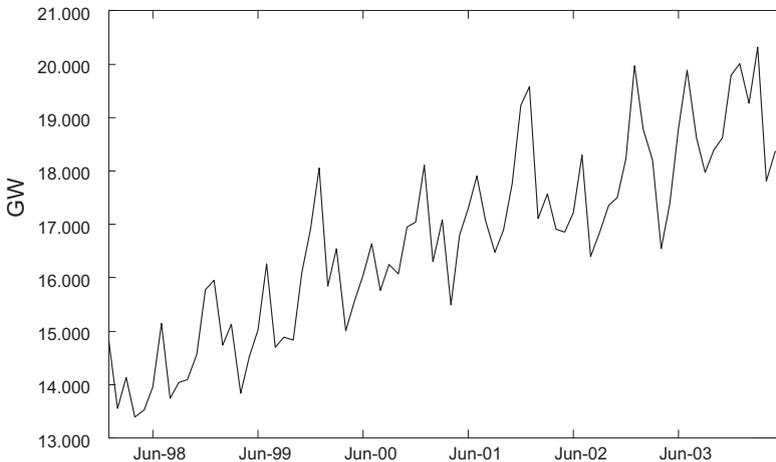


Figura 2.4. Demanda mensual de la electricidad en España. Los datos corresponden al periodo de 1998 a 2004.

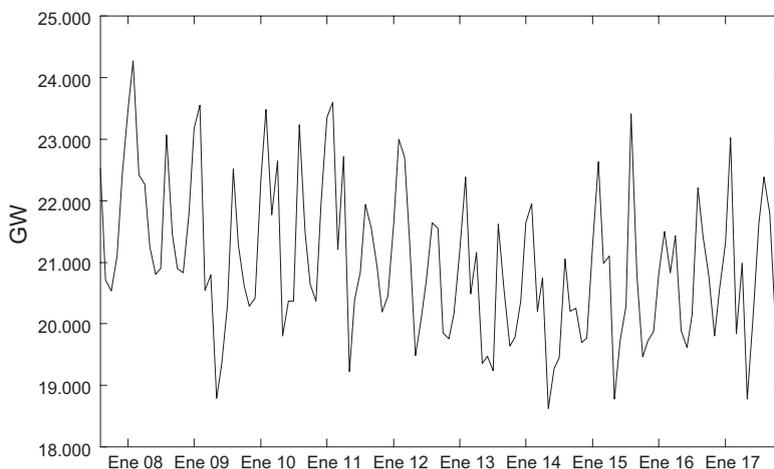


Figura 2.5. Demanda mensual de electricidad en España en el periodo de 2007 hasta 2017.

La utilización de este tipo de representación permite determinar claramente la tendencia del modelo (Cancelo, Espasa, y Grafe 2008). Generalmente se utiliza para la determinación de modelos de previsión a largo plazo (Hahn, Meyer-Nieberg, y Pickl 2009).

La desregulación del mercado provoca que la demanda sea mucho más variable, y perdiendo una estacionalidad que anteriormente se mostraba muy marcada. En concreto, desde 1998, se observa cómo la demanda fluctúa y no existen únicamente los picos de máxima demanda asociados a la época invernal. En el segundo ciclo, desde 2007 en adelante, esta situación se acentúa aún más. La explicación de estos cambios puede enfocarse desde dos puntos de vista: el primero es la introducción de nuevos elementos de climatización en la vida cotidiana (aire acondicionado) tanto para el trabajo, como para la vida particular; el segundo, y más importante, la adaptación del periodo de trabajo a Europa: antiguamente, España en agosto no se trabajaba, y el verano constituía una bajada de actividad. La progresiva adaptación al horario europeo ha provocado la no bajada de actividad en estos meses, y que además haya producido

un incremento de consumo debido a la necesidad de los elementos de climatización.

Pérez-García y Moral-Carcedo (2016) realizan un profundo análisis de la demanda a largo plazo. Analizan la demanda a largo plazo y desagregan la información, distinguiendo los sectores de consumo, y los factores que determinan el consumo. Se aprecia como los efectos de la macroeconomía influyen en el consumo a largo plazo.

2.5.1. Demanda eléctrica a medio plazo

Con el fin de asegurar el correcto funcionamiento de las instalaciones y controlar los costes a medio plazo, el sistema eléctrico utiliza datos de demanda eléctrica diarias. Aunque existen diferentes métodos de utilización.

La demanda eléctrica diaria se calcula como la suma total de demanda habida en un periodo de 24 horas desde las 00:00 horas de cada día. Entre otros aspectos, se muestra como el periodo de 1998 a 2004, representado en la Figura 2.3, presenta un comportamiento similar a la Figura 2.6.

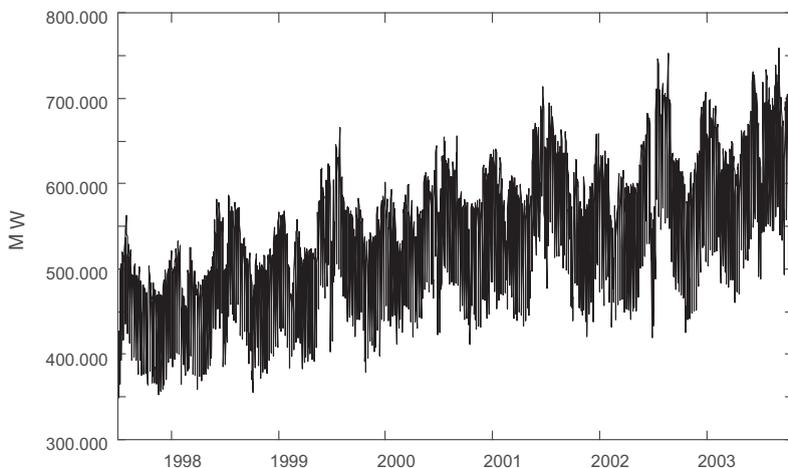


Figura 2.6. Demanda diaria en el periodo 1998-2004

Se observa cómo la tendencia creciente se mantiene a lo largo del periodo, y cómo se produce un incremento de la demanda en el verano que se repite de forma cíclica a lo largo de los años.

Para la realización de previsiones a medio plazo utilizando la demanda mensual, existen modelos basados en redes neuronales para la predicción de tendencia y aplicando una descomposición de Fourier para la componente estacional (González-Romera, Jaramillo-Morán, y Carmona-Fernández 2008). Bermúdez (2013) utiliza el concepto de las covariables para introducir en un modelo de suavizado exponencial los efectos de la temperatura y el calendario, realizando previsiones utilizando la demanda diaria. La resolución utilizada en estos trabajos es diaria, ya sea tanto para las previsiones a medio plazo, como incluso a corto plazo (Cancelo y Espasa 1996; Espasa, Revuelta, y Cancelo 1996; Pardo, Meneu, y Valor 2002; Moral-Carcedo y Vicéns-Otero 2005; Moral-Carcedo y Pérez-García 2015).

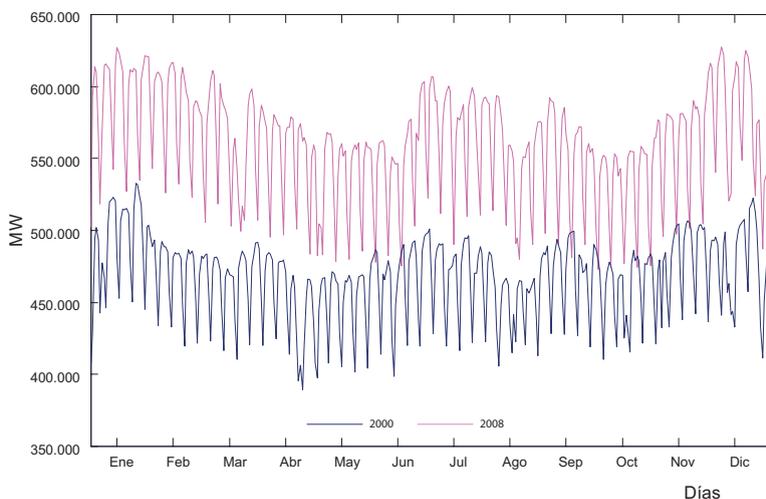


Figura 2.7. Demanda eléctrica diaria en España. Se presentan los años 2000 y 2008, como parte de dos ciclos económicos diferentes.

Para comparar la demanda con valores más actuales, la Figura 2.7 presenta la demanda diaria agregada en los años 2000 y 2008.

Se observa como la demanda en general ha aumentado de forma considerable, pasando de unos 450 GW diarios a más de 550 GW. Un aspecto importante a resaltar es la influencia de la temperatura sobre la serie. Como destacan los autores anteriormente mencionados, existe una relación directa entre la temperatura del aire y la serie de demanda. En concreto, la relación viene determinada por las curvas denominadas de “enfriamiento” y de “calentamiento”. Estas curvas, que determinan la variación sobre una temperatura límites (establecida en alrededor de 20 grados) y la relación que existe sobre el consumo de electricidad.

Se puede observar como la gráfica tiene un patrón que se repite a lo largo de las semanas. Esto responde a que la serie de demanda eléctrica tiene una fuerte componente estacional, de periodo intrasemanal. Este patrón se rompe en algunos momentos de la serie, como en la Pascua de 2008, o en el periodo vacacional de agosto en el 2000. También se percibe como en el 2000, agosto era un mes prácticamente vacacional y que este comportamiento ha variado, reduciéndose únicamente a dos semanas.

Algo más interesante se puede distinguir en el patrón que siguen ambas curvas. A pesar de existir 8 años de diferencia, ambas comparten un patrón que se repite a lo largo de los años, y que se repite prácticamente todos los años. Las series de demanda eléctrica tienen una fuerte componente estacional.

Existen otras metodologías, como es tomar el valor máximo o mínimo de cada día. Otras valoran la demanda a las 12:00, a mediodía. La Figura 2.8 muestra un ejemplo de máximos de demanda eléctrica diaria. Por norma general, el análisis utilizando estos valores busca determinar los precios máximos de la electricidad (Red Eléctrica de España 2015; Ortiz et al. 2016)

o buscar relación de los máximos de demanda con algún factor externo.

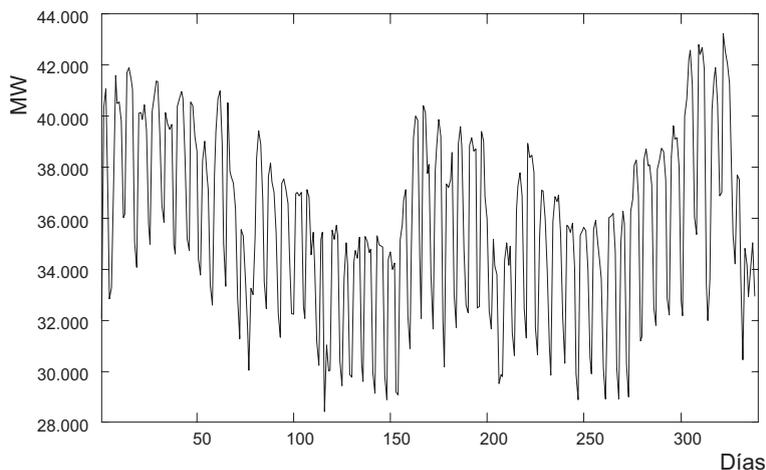


Figura 2.8. Demanda máxima diaria en el año 2008.

2.5.2. Demanda a corto plazo

La desregulación del sector eléctrico ha motivado un considerable interés en la previsión a corto y muy corto plazo. Estas previsiones buscan determinar el consumo día a día. De este modo, las compañías obtienen las previsiones de demanda a una o varias semanas vista. El mercado utiliza estas previsiones para el establecimiento de los precios de la electricidad, tanto diarios, como intradiarios.

La demanda eléctrica a muy corto plazo se trabaja en un rango de tiempo de horas, medias-horas e incluso 10 minutos. Por norma general, la demanda en España es suministrada en horas, y es la resolución que se trabajará en esta tesis.

Esta resolución provoca que existan movimientos relevantes de alta frecuencia, que complican los modelos de previsión (Martín-Rodríguez y Cáceres-Hernández 2005), y es

necesario analizar las variaciones estacionales : diaria, semanal y anual, si es necesario.

La temperatura del aire provocan una influencia sobre la serie de demanda eléctrica, que se refleja en forma de diferentes estacionalidades (Cancelo, Espasa, y Grafe 2008). Esta influencia se materializa en el medio plazo. En el corto plazo, dependiendo del horizonte de previsión puede ser influyente o no. Esto es visible en la Figura 2.7 donde dependiendo de la época del año, se puede apreciar como la curva de la demanda siguen un comportamiento determinado, que, a pesar de todo, se repite todos los años.

Siguiendo las técnicas mostradas en estos trabajos, con el fin de analizar el efecto de las estaciones, se analiza por separado la distribución de la demanda eléctrica horaria por estaciones en el segundo periodo, desde 2007 hasta 2017. La serie no necesita de una eliminación de tendencia, puesto que se puede observar en la Figura 2.5 que la tendencia no es pronunciada, y su efecto sobre el estudio es mínimo. El resultado se ha representado en las gráficas de la Figura 2.9. Para la obtención de esta distribución, se ha obtenido la media y desviación típica de las demandas, utilizando los periodos desde el año 2007 hasta el 2017, y organizado los datos de modo que los periodos de cada año coincidan. La gráfica representa en el sombreado el 95% de la variabilidad y la línea central negra la media de los valores para cada momento.

El primer análisis sobre la demanda en primavera refleja la existencia de una tendencia que disminuye en el primer mes y que luego se mantiene a lo largo de la estación. Es un periodo de pocos cambios climáticos, aunque la primera mitad de la gráfica revela una variabilidad muy elevada. Sin duda, esta variabilidad viene provocada por el efecto calendario, periodo en el que se producen la Pascua y otras fiestas primaverales. La demanda veraniega en sus primeras semanas revela una gran variabilidad que puede ser relacionada directamente con la temperatura.

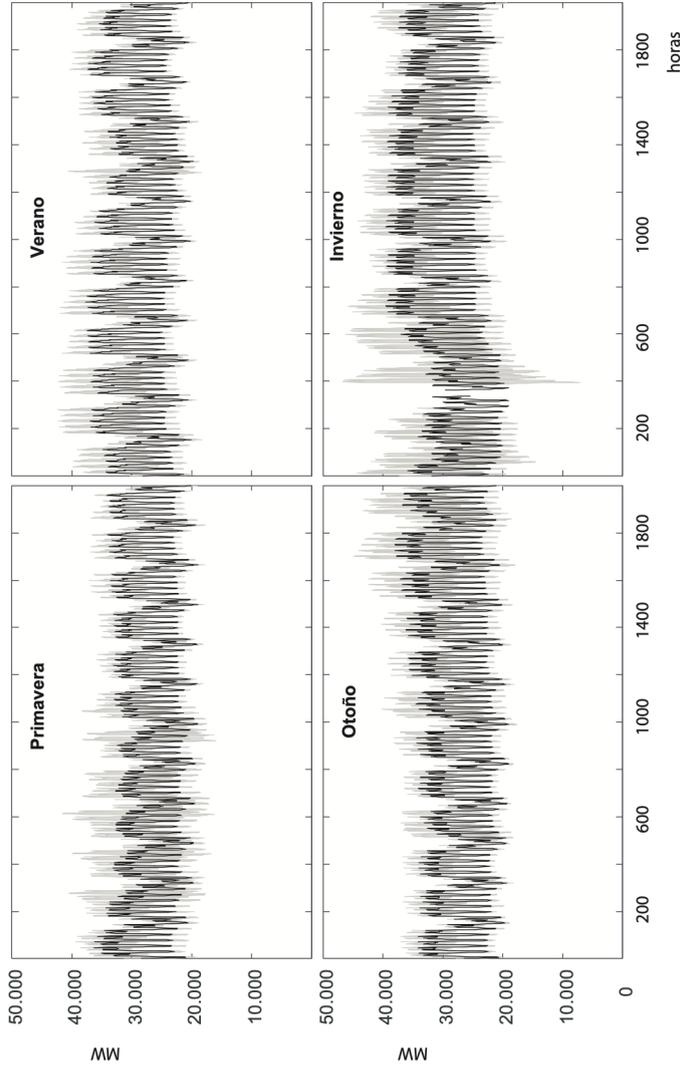


Figura 2.9. Demanda eléctrica horaria en las diferentes estaciones del año. La media es la línea central, mientras que la variabilidad se expresa en la zona sombreada. Las abscisas reflejan las horas desde el inicio de la estación y las ordenadas la demanda horaria en MW.

Durante estas fechas no se producen cambios significativos debido a ninguna festividad, y sin embargo se produce una gran variabilidad. A medida que avanza el verano la variabilidad se reduce, teniendo en cuenta que las temperaturas vuelven a ser más suaves. Existe una zona central donde la festividad de la Asunción (15 de agosto) provoca también variabilidad por efecto calendario. En el periodo otoñal se aprecia una disminución en la variación de la tendencia, aunque a finales de la temporada empieza a aumentar la demanda.

Es destacable como al final de la serie, la variabilidad aumenta. El efecto calendario es pronunciado en su caso. Los festivos de la Constitución y la Inmaculada, que cada año caen en las mismas fechas, pero en días de la semana distintos. De la misma forma, en el periodo invernal los comienzos con las Navidades y Reyes adquieren mucha variabilidad. Posteriormente esta variabilidad disminuye a valores semejantes a la primavera. El tramo discontinuo en la gráfica de invierno sirve para adaptar la fecha del 31 de diciembre y el 1 de enero continuos, pero de años diferentes, por ello no refleja ninguna variabilidad.

2.6. Análisis estacional de la serie

En general, las series temporales que incluyen demanda suelen tener una serie de fluctuaciones cíclicas muy marcadas que se repiten a lo largo del tiempo. Estas fluctuaciones son predecibles y reciben comúnmente el nombre de estacionalidades. Montgomery, Jennings y Kulahci (2008) las describen como la componente del comportamiento de la serie temporal que se repite en una base regular. Estas variaciones no pueden ser modelizadas por un modelo lineal, y por eso requieren de un estudio específico. Las características principales que podemos encontrar en un patrón estacional son las siguientes (Naumova 2006):

- Existe un punto en el patrón que representa el máximo.

- Hay una amplitud desde el máximo hasta el nadir (punto opuesto al máximo).
- La duración del incremento estacional según la forma de la curva. Ello determina el comportamiento del ciclo.

Realizando un acercamiento a las gráficas anteriores, tal y como se muestra en la Figura 2.10, se observa que el comportamiento anteriormente mencionado se produce cada 24 horas, siendo esta la primera estacionalidad.

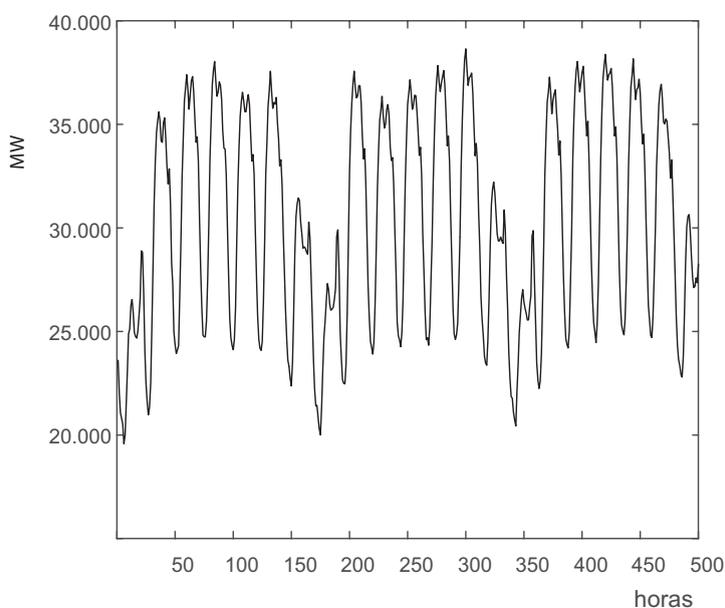


Figura 2.10. Evolución de la demanda eléctrica horaria en tres semanas del año 2008. Se aprecia una componente que se repite los días laborables, y en menor medida los fines de semana. Esta componente es la estacionalidad intradiaria, mientras que el patrón que se repite todas las semanas es la estacionalidad intrasemanal.

Si se observa con detenimiento la figura, se percibe como este comportamiento se reproduce cada semana, cada 168 horas. Esta se trata de una segunda estacionalidad que va relacionada con la primera, de modo que claramente los fines de semana se reduce la actividad, pero además es capaz de asimilar las

variaciones producidas durante la semana, de modo que los miércoles es el día de mayor actividad con respecto al resto.

Siguiendo la misma metodología, se puede destacar como existe una tercera estacionalidad que corresponde con el periodo de un año. Esta tercera estacionalidad, sin embargo, no está tan clara. La definición propia de año tiene sus propios cálculos de tiempo, dependiendo del punto de referencia utilizado. Los años pueden contener 365,25 días (8766 horas) tomando como referencia el año sideral solar, mientras que, si se utiliza el año de calendario, basado en el calendario gregoriano, tenemos años de 365 días y los años bisiestos de 366.

Para determinar la longitud de otros patrones estacionales resulta inefectivo utilizar la misma técnica. Para ello, la metodología de Box y Jenkins (Box et al. 1994) y analizando la función de autocorrelación simple y parcial, puede ayudar con mayor precisión. Otra forma de trabajarlo es analizando el espectro de la serie, utilizando tanto el periodograma basado en la descomposición de Fourier como el anteriormente mencionado.

La Figura 2.11 muestra el análisis espectral de la serie basado en los modelos autoregresivos. Claramente se aprecia como el máximo se produce en el periodo 24. Está muy relacionada con la estacionalidad de 12 horas, pero esta estacionalidad es un reflejo de la misma. Eliminando esta estacionalidad y siguiendo el mismo procedimiento, podemos observar como la siguiente estacionalidad destacada es la intrasemanal, cada 168 horas.

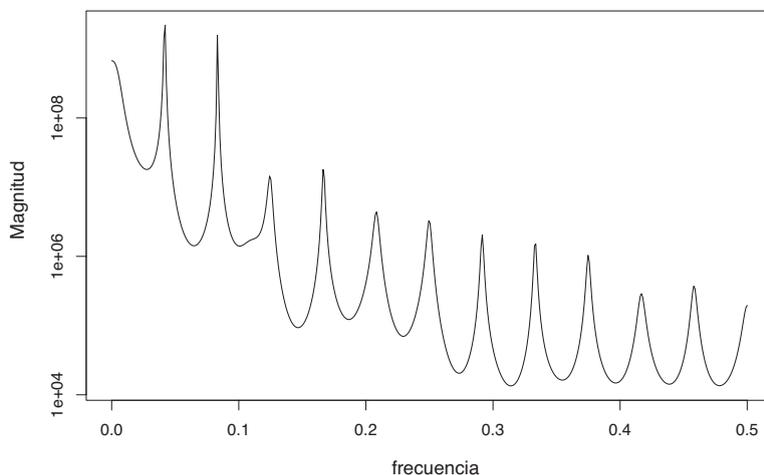


Figura 2.11. Análisis espectral de la serie basado en un modelo AR(48).

2.7. Singularidades de la serie

En este apartado se estudian situaciones en que la serie de demanda eléctrica horaria tiene un comportamiento diferenciado a la situación regular, y cómo se trata en esta tesis.

2.7.1. Cambio horario de verano e invierno

España utiliza el horario de la Comunidad Europea, donde se producen los cambios horarios de verano e invierno según el criterio establecido. Estos cambios se conocen popularmente como DST (Daylight Saving Time). Ello hace que esta irregularidad se transmita a la serie eléctrica, y que, en los días de retraso horario, la periodicidad de 24 horas no se cumple, existiendo un día de 23 horas. Lo contrario ocurre en el periodo de adelanto horario, en el cual el día tiene 25 horas. Esto se aprecia en la Figura 2.12, donde se muestra las horas de sol de acuerdo al cambio horario de verano e invierno. Esto afecta también a la demanda, y aunque el cambio pueda parecer sutil, produce un gran efecto sobre la serie.

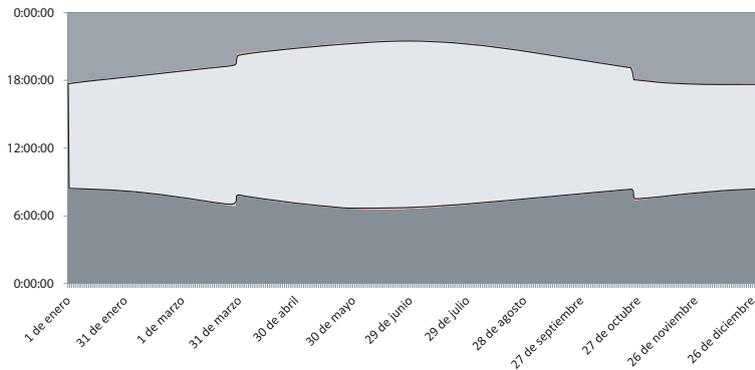


Figura 2.12. Distribución de la luz solar según el calendario de verano e invierno. En azul las horas de oscuridad, y en rojo las de luz. Se aprecia cómo el cambio del horario supone un salto en la continuidad de las evoluciones de la salida y puesta de sol.

En concreto, el cambio horario siempre se produce en la madrugada del sábado al domingo. Los estudios del efecto sobre el consumo y el ahorro no aportan realmente conclusiones certeras sobre la idoneidad de realizar este tipo de horario (Aries y Newsham 2008; Rock 1997; Kotchen y Grant 2010; Hill et al. 2010). Sin embargo, este cambio horario tiene influencia sobre la serie de demanda que hay que tratar.

La adaptación al horario de verano se produce el último sábado de marzo, donde los relojes a las 2:00 pasan a marcar las 3:00. La adaptación al horario de invierno se produce el último sábado de octubre. En esta ocasión, cuando son las 3:00 el reloj vuelve a marcar las 2:00, repitiendo el horario. La base del cambio horario se produce en verano, donde el horario se adelanta. La serie se ve truncada debido a que faltan o sobran horas. Esto se transmite en la serie a lo largo de todo el periodo de verano. Si tomamos valores intermedios, no es grave, aunque si tomamos valores que incluyan este salto en la serie, se verán distorsionados los datos. Esto se puede apreciar en la Figura 2.13.

En ella se muestra la representación de la serie real frente a la que debería producirse si no hubiera el cambio de hora debido al DST.

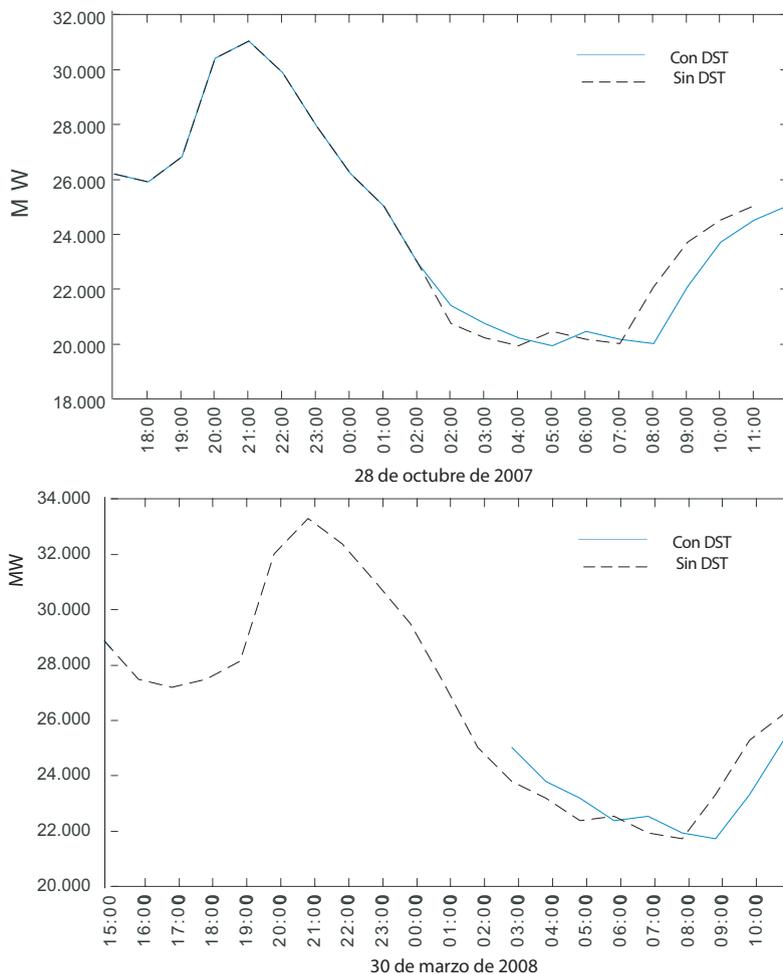


Figura 2.13. Efecto del adelanto y retraso horario en el calendario (DST) sobre la serie de demanda eléctrica.

Martín-Rodríguez y Cáceres-Hernández (2005) proponen trabajar la serie, de modo que en los momentos de adelanto horario, se elimine la segunda medida repetida (a las 2:00). En el caso del retraso horario, se propone utilizar la última medida (1:00) para establecer la del momento que se ha eliminado de la

serie (2:00). De este modo se consigue que estos días sean de 24 horas. Taylor (2010b) por su parte, trabaja con periodos del año de diferentes longitudes con el fin de incluir este efecto. En esta tesis se ha optado por recodificar la serie, de modo que se han seguido las directrices marcadas por Martín-Rodríguez y Cáceres-Hernández. Sin embargo, para rellenar la serie con el hueco dejado por el retraso horario, en lugar de repetir el último valor, se ha interpolado el valor entre los valores de la 1:00 y las 3:00. De este modo se consigue eliminar la de la serie esta irregularidad.

2.7.2. Efecto calendario

Los días festivos provocan una irregularidad en la serie de demanda que generalmente se conoce como efecto calendario. Estas irregularidades se tratan con más detenimiento en el apartado de los modelos de Holt-Winters con estacionalidades móviles de intervalo discreto. Este tipo de eventos recibe el nombre de efecto calendario.

La Figura 2.14 muestra el efecto calendario sobre un día festivo. En este caso en concreto se ha elegido la festividad de la Asunción, el 15 de agosto. Esta fecha es festiva en toda España, y, por lo tanto, cuando se produce en un día laboral, la demanda eléctrica disminuye, en comparación a la que existiría si ese día no fuera festivo.

Esta irregularidad se produce a lo largo de la serie, y de forma arbitraria. Además de esta festividad, se encuentra otras fechas señaladas como el día de la hispanidad, la Constitución, etc. Dentro de estas irregularidades, cabe destacar la Pascua y las Navidades, ya que su comportamiento provoca mayor irregularidad.

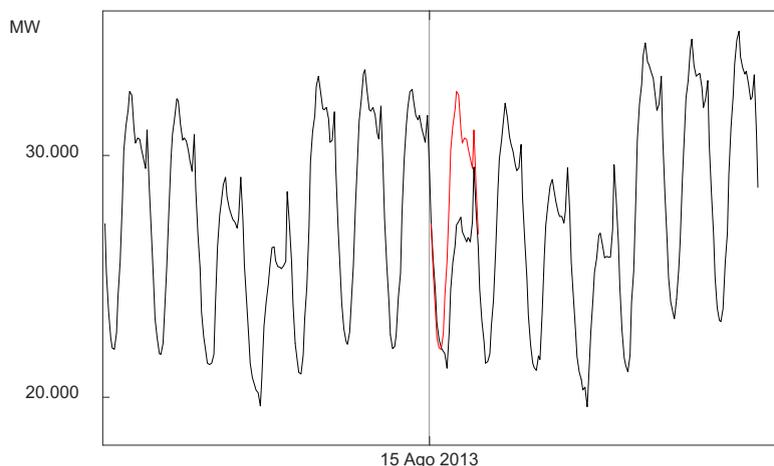


Figura 2.14. Efecto que se produce en la demanda cuando ocurre un día festivo. Se muestra el ejemplo de la Asunción. El día 15 de agosto es festivo en toda España. Se aprecia como la línea negra – demanda real - tiene una irregularidad ese día comparado con lo que sería un día normal (línea roja). Esta irregularidad se denomina efecto calendario.

2.7.3. Efecto de la climatología

Las condiciones climáticas son un factor exógeno a la serie de demanda eléctrica que tiene gran influencia sobre ella. La serie observada muestra un comportamiento en el que se puede identificar de forma sencilla cómo las estaciones del año influyen sobre el consumo. Sin embargo, dado que la serie es agregada, ésta se construye como la suma de todas las demandas habidas en España, sumando la de todas las regiones. La climatología en cada región es muy dispar, y, por lo tanto, no es fácil de relacionar con la serie de demanda. Las variables climatológicas recopiladas son la temperatura del aire, la humedad, vientos, lluvia, etc. Pero de todas ellas, únicamente la temperatura del aire suele aportar información útil para ser relacionada con la demanda eléctrica. Se busca de forma general establecer una única temperatura con la demanda, incluso si se

calcula de forma ponderada sobre los puntos de mayor consumo en la península.

Valor, Meneu y Caselles (2001) trabajan con indicadores de estacionalidad mensual y diaria para comprobar como la estacionalidad está directamente relacionada con las condiciones climáticas, y estas a la vez con la demanda eléctrica (Valor, Meneu, y Caselles 2001; Pardo, Meneu, y Valor 2002). Sin embargo, todos los trabajos van dirigidos a la demanda eléctrica diaria o de periodo mayor. Cuando se trata de trabajar la demanda eléctrica horaria, resulta difícil esta aplicación, puesto que la propia estacionalidad diaria recoge la variabilidad diaria de la temperatura. Por otro lado, las previsiones climáticas suelen tener menor precisión que las propias dadas por la demanda eléctrica, lo que en ocasiones supone introducir una variabilidad artificial no necesaria.

En el corto plazo, este efecto de la climatología no es tan fácil de determinar, puesto que la serie muestra una estacionalidad diaria muy marcada y que se relaciona directamente con el comportamiento humano. Este comportamiento está directamente relacionado con las horas solares y con la temperatura del día, con lo que es muy difícil establecer un modelo que sea capaz de interpretar esa relación.

3. Estado del arte

3

3.1. Introducción

Este capítulo presenta el análisis sobre el estado del arte para la presente tesis. Se ha organizado en 3 partes, de acuerdo a los grandes temas a tratar de forma diferenciada: primeramente, se analiza la literatura relativa a los modelos utilizados para la previsión de demanda en España; seguidamente, los métodos de series temporales utilizados para la previsión de demanda en general; y, por último, y concretando, se analiza la literatura correspondiente a los modelos de Holt-Winters.

3.2. Análisis Bibliométrico

La previsión de demanda eléctrica supone un reto para las compañías de distribución eléctricas y para aquellas asociadas al mercado eléctrico, puesto que hay en juego unos costes de producción y pérdidas de enorme envergadura. Un análisis bibliométrico en *Web of Science* permite comprobar el interés a través de las publicaciones realizadas en los últimos tiempos.

Existen reportadas un total de 1607 publicaciones (artículos en revista o libros) en la fecha de revisión (junio de 2019) referentes a las previsiones relacionadas con la

electricidad, que incluyen estos elementos en el título. De todos ellos, 711 hacen referencia o tienen como objetivo la previsión de demanda. Como se puede apreciar en la Figura 3.1, los artículos objeto de este tema han crecido de forma exponencial. La literatura se concentra mayoritariamente en los trabajos relacionados con la previsión. En los últimos años empieza de nuevo un repunte sobre los trabajos dedicados a la previsión de precios de la electricidad.

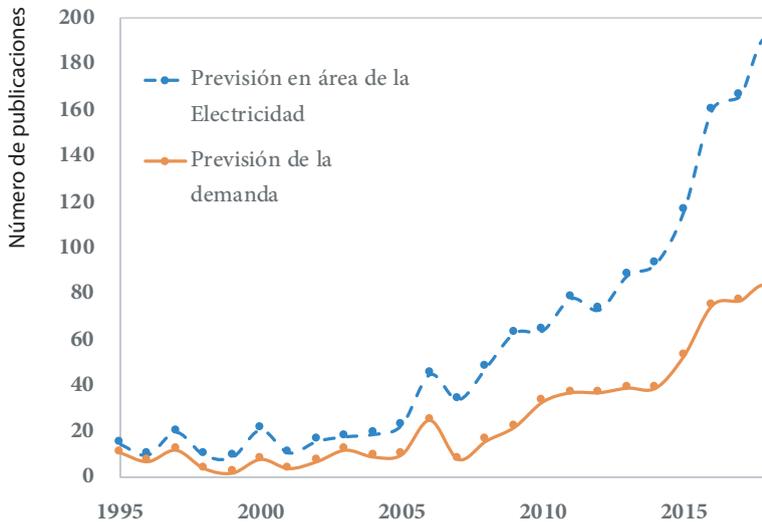


Figura 3.1. Evolución de los artículos publicados relacionados con la previsión de electricidad. La línea de puntos representa las publicaciones en general, y la línea continua representa los trabajos específicos para la previsión de demanda eléctrica.

Las publicaciones realizadas con referencia a nuestro país se reducen a 73, de lo cuales 16 están directamente relacionados con la previsión de demanda. La Figura 3.2 muestra cómo las publicaciones en España al respecto sufren un comportamiento desigual, habiendo más interés en la previsión de los precios que no de la demanda. En cualquier caso, son pocos los autores que publican.

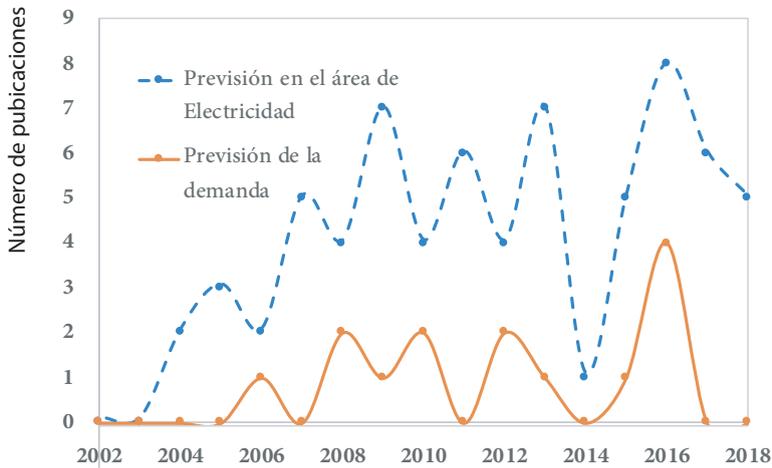


Figura 3.2. Evolución de las publicaciones relacionadas con la previsión eléctrica en España.

Del mismo modo, en la Figura 3.3 se puede observar la cantidad de artículos publicados cuyo tema de trabajo son los modelos de suavizado exponencial, y de ellos los que se dedican al modelo de Holt-Winters.

Aunque el número de publicaciones crece, las publicaciones dedicadas a la previsión de demanda eléctrica basadas en los modelos de Holt-Winters siguen siendo muy pocas. Comparadas con otras técnicas, el interés despertado no parece ser suficiente, a pesar de proporcionar buenos resultados (Taylor 2010b).

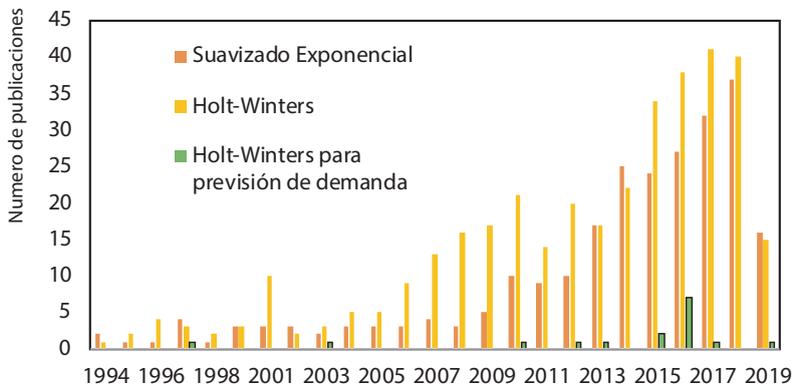


Figura 3.3. Artículos publicados en WoS relacionados con el suavizado exponencial, modelos de Holt-Winters y HW para previsión de demanda.

3.3. Modelos de previsión aplicados a la demanda eléctrica en España

Los primeros trabajos de previsión de demanda eléctrica en España considerados datan de los años 90, tras la reestructuración del mercado de la electricidad. Canelo y Espasa (1995,1996) proponen un modelo ARIMA en el que se tiene en cuenta los efectos de la temperatura y los días especiales mediante funciones de transferencia. Valor, Meneu y Caselles (2001) proponen utilizar como única variable climática la temperatura del aire, tal y como reflejan otros autores (Engle, Mustafa, y Rice 1992; Valor et al. 2002) y proponen la utilización de la temperatura de España ponderada de acuerdo a la población, utilizando el índice de temperatura definido como en (3.1).

$$TI_t = \sum_{i=1}^4 \bar{T}_{ti} w_{ti}; \text{ con } w_{ti} = \frac{P_{ti}}{\sum_{i=1}^4 P_{ti}} \quad (3.1)$$

siendo P_{t_i} la población en una de las zonas marcadas. Se divide la extensión de España en cuatro zonas (Madrid, Valencia, Sevilla y Bilbao). Además, introduce el uso de las curvas de enfriamiento y calentamiento, ecuaciones (3.2) a (3.3).

$$CDD = \max(TI - TI^*; 0) \quad (3.2)$$

$$HDD = \max(TI^{**} - TI; 0) \quad (3.3)$$

Donde TI^* y TI^{**} son denominadas temperaturas base, con $TI^* = 21^\circ\text{C}$ y $TI^{**} = 15^\circ\text{C}$.

Los mismos autores (Pardo, Meneu, y Valor 2002) desarrollan un modelo basado en regresión para la demanda, como en (3.4)-(3.5).

$$\begin{aligned} Dem_t = & c_3 + \alpha_3 t + \beta_3(B)HDD_t + \gamma_3(B)CDD_t + \\ & + \sum_{i=2}^7 \delta_{3i} W_{it} + \omega_3 H_t + \kappa_3 H_{t-1} + \theta_3 G_t + \\ & + \sum_{j=2}^{12} \lambda_{3j} M_{jt} + \varepsilon_{3t} \end{aligned} \quad (3.4)$$

$$\xi_{3t} = (1 - \phi B - \phi_2 B^2 - \dots - \phi_9 B^9) \varepsilon_{3t} \quad (3.5)$$

Donde Dem_t es la demanda para un instante t , mientras que M_{jt} es una variable ficticia para señalar el mes del año, H_t señala si el día t es festivo o no y G_t es otra variable ficticia para indicar si se trata de Pascua. El resto, c_3 , α_3 , δ_{3i} , ω_3 , κ_3 , θ_3 , λ_{3j} son parámetros del modelo que se ajustan minimizando el error de la previsión. $\beta_3(B)$ y $\gamma_3(B)$ son polinomios de grado 5 para considerar el efecto del retardo en las condiciones climáticas. El término ξ_{3t} es un polinomio AR de noveno orden cuyos parámetros son ϕ_i y que contribuye a reducir el error de

previsión. W_{it} es una variable ficticia que indica el día de la semana, con base en lunes.

Moral-Carcedo y Vicéns-Otero (2005) filtran la demanda a partir de incluir variables ficticias, como, por ejemplo, el mes de agosto y efectos semanales. Esta demanda filtrada es relacionada con la temperatura, utilizando la curva V de temperatura-demanda. Sin embargo, encuentran que el método tradicional de separar en dos curvas (HDD y CDD) no es lo más adecuado, proponiendo el LSTR (logistic smooth transition).

Cancelo, Espasa y Grafe (2008) desarrollan el modelo utilizado en REE, donde la demanda se divide en lo que se denomina demanda básica y contribuciones por efecto calendario y climatología.

$$\ln Dem_t = p_t + s_t + CSD_t + CWEA_t + U_t \quad (3.6)$$

La demanda se descompone en $p_t + s_t$ (denominada demanda básica), que se modela mediante métodos ARIMA, y el resto para las contribuciones de los distintos efectos. Dentro de CSD_t se modelizan los efectos del calendario, mientras que $CWEA_t$ modeliza el efecto de las variables climáticas.

Para eliminar el efecto calendario, algunos autores prefieren suavizar la serie y eliminar dichos efectos (Taylor, de Menezes, y McSharry 2006) y otros prefieren utilizar la técnica de días similares, donde se buscan días similares para realizar las previsiones (Hippert, Bunn, y Souza 2005).

La contribución de la climatología se expresa mediante la temperatura del aire, ponderada a partir de las regiones de España de acuerdo a las indicaciones proporcionadas por el Ministerio de Industria de España. Para la aplicación de la temperatura, utilizan las curvas de calentamiento y enfriamiento, con límites (TR, threshold regression) estableciendo en el caso del enfriamiento un modelo de temperatura con referente de 9°C y dependiendo de

la hora del día, mientras que para el calentamiento se utiliza simplemente la temperatura de 24°C y 33°C.

Uno de los aspectos más importantes que destacan los autores es la utilización de 24 modelos horarios para la previsión de hasta 3 días en adelante, y uno diario para previsiones de hasta 10 días. Estas técnicas conocidas como de combinación con buenos resultados, descritas en estudios anteriores como el propuesto en Ramanathan et al. (1997).

Otras vertientes diferenciadas proponen la utilización de splines para modelizar la componente estacional (Martín-Rodríguez y Cáceres-Hernández 2005). Presentan un modelo compuesto de dos submodelos según se trate de un año bisiesto o no. Consideran un polinomio de grado 3 común, con una longitud de periodo de 8760 horas. Para el caso de años bisiestos, este polinomio es válido para las primeras 1416 horas y las últimas horas a partir de 1440 horas, modelizando esa franja de 24 horas para el 29 de febrero con un spline propio. También ajusta el modelo según el DST (Daylight saving time).

También es extenso el uso de redes neuronales. González-Romera, Jaramillo-Morán y Carmona Fernández (2006) utilizan redes neuronales multilayer perceptron, realizando una descomposición de Fourier previa. De esta forma simplifica la red y permite utilizar únicamente dos neuronas, con un MAPE reportado de 1.7%. La utilización de métodos semiparamétricos, modelos funcionales, denominados SPLM (semiparametric partial linear model) mejoran la precisión con respecto modelos tradicionales, como el ARIMA (Aneiros, Vilar, y Raña 2016a; Vilar, Aneiros, y Raña 2018).

Muñoz et al. (2010) describen cómo realizar las previsiones en demanda eléctrica a corto plazo y destacan los resultados empíricos obtenidos: en la predicción a corto plazo suele prescindirse del ciclo anual, el PIB está relacionado en el largo plazo, los modelos mayormente utilizados son los ARIMA doble estacionales y los modelos de Holt-Winters doble

estacionales, en las condiciones climáticas se utiliza únicamente la temperatura del aire. Una de las afirmaciones que emite es que los modelos ARIMA univariados quedan relegados al puro benchmarking.

La utilización de modelos de Holt-Winters doble y triple estacionales para la previsión de demanda proporciona unos resultados excepcionales (Taylor y McSharry 2007), aunque generalmente los modelos con doble estacionalidad proporcionan mejores resultados que los triple estacionales si la serie no ha sido filtrada, ya que el efecto calendario provoca que la estacionalidad anual no sea estable (García-Díaz y Trull 2016).

Moral-Carcedo y Pérez-García (2015,2016) analizan la demanda eléctrica española y consiguen determinar diferentes sectores económicos y su peso en el consumo de energía en España. Así pues, determinan factores a tener en cuenta para el crecimiento de la demanda, como crecimiento de la densidad demográfica o el crecimiento económico del país, y así predice que en el 2020 el PIB habrá crecido un 1,7% y el consumo energético un 0,6%. Además, destacan que se producen incrementos en la demanda de forma puntual debido a incrementos de temperatura o descensos bruscos, pero que afecta únicamente al sector de servicios, y no al industrial. Finalmente, en verano, el sector turístico tiene influencia sobre la demanda, debido a la calidad de vida que se ofrece.

Para poder modelizar el efecto calendario utilizando modelos de Holt-Winters múltiple-estacionales, se introduce el concepto de estacionalidad discreta con intervalo móvil, y se aplica a la demanda en España en las fechas de Pascua (Trull, García-Díaz, y Troncoso 2019).

En otros países, como en Francia, EDF (Electricité de France) utiliza modelos generalizados de regresión (Pierrot y Goude 2014) aunque también hay propuestas de utilizar espacios de estado (Dordonnat et al. 2008).

La previsión para la demanda eléctrica en Italia se realiza mediante modelos generalizados de regresión, donde se aprecia una independencia del consumo frente al precio de la electricidad (Bianco, Manca, y Nardini 2009). También la propuesta de utilizar modelos ARIMAX con un preprocesamiento de los datos de temperatura (De Felice, Alessandri, y Ruti 2013). Para poder introducir los datos de temperatura, algunos autores utilizan las curvas de temperatura de donde extraen las componentes principales y las introducen en el modelo (De Felice, Alessandri, y Catalano 2015).

Taylor (2008) describe cómo en la National Grid de Reino Unido, la previsión se realiza mediante el cálculo de Scaling Ratios relacionados con la temperatura aplicados en ciertos puntos de la serie, y a partir de los cuales se desarrolla el modelo para la demanda básica.

Recientemente, López junto con otros autores introducen un nuevo modelo de previsión en REE, basado en el uso de redes neuronales combinadas con modelos autoregresivos, en los que se incluye la temperatura y los casos de los días especiales (López et al. 2017; 2018; 2019). El uso de la combinación permite a los autores reportar un MAPE de valores inferiores al 2% en las previsiones.

3.4. Modelos de previsión de demanda basados en series temporales

Las herramientas para la explotación y uso de series temporales son muy variadas. Con el tiempo, los métodos y técnicas han ido evolucionando y diversificándose, de modo que en la actualidad existe un gran número de ellas. Para su explotación, las empresas suelen recurrir a varias de ellas, o a generar un modelo híbrido basado en estas herramientas.

Gross y Galiana (1987) clasifican los métodos de previsión de la demanda a corto plazo según se busca obtener el pico máximo o la curva de demanda. En el primer caso describe métodos explícitos de series de tiempo y descomposición espectral, mientras que para el segundo caso expone los modelos dinámicos como ARMA y espacios de estado. Jebaraj y Iniyan (2006) recopilan los métodos de previsión energética y de demanda diseñados para su explotación comercial. Analizan los modelos de suministro de energía, y tratan los modelos de previsión de demanda para las estaciones solares, eólicas y de biomasa, concentrando la búsqueda en modelos de inteligencia artificial.

Un análisis realizado sobre la bibliografía y los modelos trabajados hasta el 2001 (Alfares y Nazeeruddin 2002), desprende que los modelos de regresión siguen siendo desarrollados de modo habitual, así como los modelos estocásticos. También se muestra un auge de los modelos basados en la computación, como redes neuronales. Hippert, Pedreira y Souza (2001) confirman esta información, y constata un incremento sustancial en la dedicación de los estudios al uso de las técnicas con redes neuronales, en detrimento de los demás métodos.

Los estudios, tal y como ya se ve en (Makridakis y Hibon 2000), se dirigen más a estudiar cómo mejorar las metodologías en la práctica, que no a desarrollar nuevos modelos. No hay interés por tratar las diferentes estacionalidades, y de forma generalizada, se desestacionalizan los modelos.

Weron (2006, 2014) recopila los métodos más comúnmente utilizados para la previsión, destacando una primera clasificación:

1. Métodos basados en inteligencia artificial.
 - 1.1. Redes neuronales artificiales.
 - 1.2. Sistemas expertos.
 - 1.3. Lógica difusa.
 - 1.4. Máquinas de vector soporte.

2. Métodos estadísticos.
 - 2.1. Días similares.
 - 2.2. Suavizado exponencial.
 - 2.3. Regresión.
 - 2.4. Modelos autoregresivos y ARIMA.

Suganthi y Samuel (2012) proponen otra clasificación en la que los modelos de demanda energéticos tienen una estructura más plana, sin distinguir entre métodos estadísticos o de inteligencia artificial. Dan especial importancia a los métodos basados en el cálculo como algoritmos genéticos y lógica difusa, redes neuronales, algoritmos de colonización de hormigas, etc. Concluye que la aparición de estos nuevos métodos sofisticados está adquiriendo relevancia en la literatura.

La Figura 3.4 muestra una estructura simplificada de esta clasificación, en la que se han incluido las técnicas más influyentes.

Métodos fundamentales

Estos modelos reciben también el nombre de estructurales, entre otras cosas porque fundamentan su previsión mediante el estudio de magnitudes físicas influyentes en la demanda, y estableciendo modelos que relacionen todos los datos disponibles. Generalmente se trata de modelos que combinan todos los otros tipos de metodologías, y que suelen ser propiedad de las empresas.

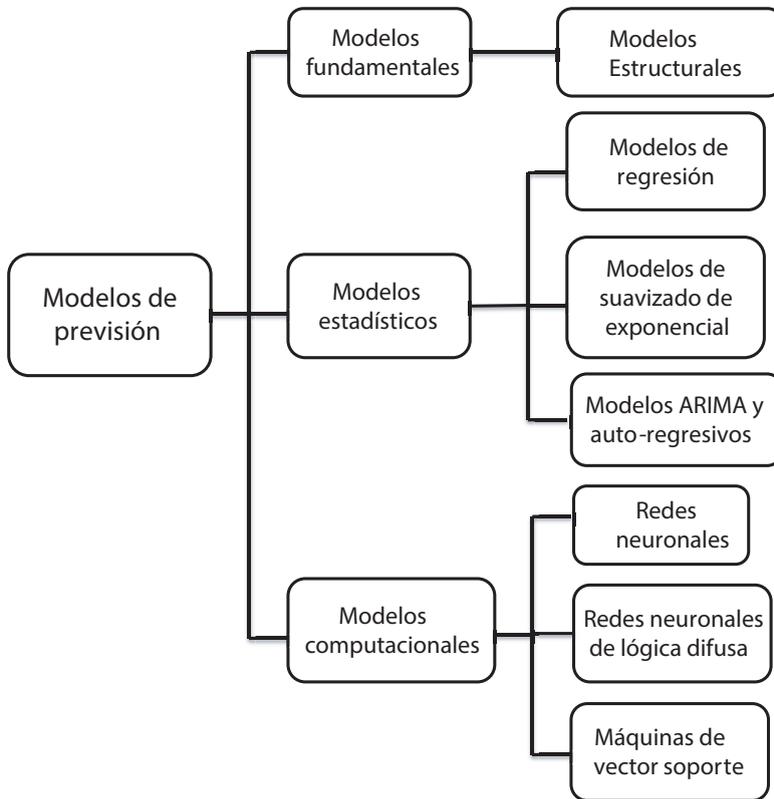


Figura 3.4. Estructura propuesta para la clasificación de las técnicas de previsión de demanda eléctrica.

Métodos estadísticos

Fundamentalmente utilizan herramientas econométricas para determinar las previsiones. Con la experiencia de los datos observados y modelos matemáticos de mayor o menor complejidad se infieren previsiones. Se subclasifican en: días similares, suavizado exponencial, modelos de regresión, modelos auto regresivos, etc.

Métodos computacionales

Los métodos basados en inteligencia artificial son métodos ampliamente utilizados. Basan su funcionamiento en realizar cálculos matemáticos utilizando la inteligencia artificial o métodos evolutivos y de ciencia difusa que permiten establecer la previsión. Existe también una subclasificación atendiendo a los métodos que utilice: redes neuronales artificiales, tanto de alimentación evolutiva como recurrente, redes neuronales de ciencia difusa, y, por último, modelos de vector de soporte. Existen más técnicas, como los modelos multiagente y de forma reducida, aunque de momento no son de gran aplicación en la previsión de la demanda.

3.4.1. Métodos fundamentales

Los modelos fundamentales engloban aquellos que incluyen en su modelización parámetros fundamentales para establecer relaciones entre diferentes variables y la demanda. Cada uno de los parámetros se analiza de forma separada y se realizan previsiones de forma separada. Posteriormente, se asocian de forma funcional para establecer la previsión. Aunque generalmente se utilizan para la previsión de precios, también encuentran su aplicación en la previsión de demanda (González, Contreras, y Bunn 2012; Liebl 2013). También se ha utilizado para la demanda eléctrica en Turquía (Dilaver y Hunt 2011) y para las series de demanda eléctrica en Río de Janeiro y en Gran Bretaña (Rendon-Sanchez y de Menezes 2019).

3.4.2. Métodos Estadísticos

Los modelos estadísticos basan su fundamento en análisis estadísticos de la demanda previa para realizar y establecer modelos para realizar previsiones a futuro. Estos modelos resultan de gran utilidad porque tienen un fundamento matemático y suelen ir acompañados de una valoración de la incertidumbre. A continuación, se detalla el análisis de los

métodos expuestos en la Figura 3.4 a excepción de los modelos de suavizado exponencial, que se disponen en una sección aparte.

Modelos de regresión

Los modelos de regresión son de amplio uso dentro de la estadística, utilizándose generalmente modelos lineales. En el área de la previsión de demanda eléctrica, los modelos de regresión son ampliamente utilizados, formando parte de otros modelos, y rara vez se utilizan de forma individual. Dentro de este tipo de modelos, se encuentran los denominados modelos generales periódicos dinámicos, de factores dinámicos, de simple factor dinámico. Una variante que goza de mucha utilizad son los denominados modelos de regresión con parámetros variables en el tiempo, (TVR, Time-Varying regression).

Los modelos de regresión tienen su fundamento en utilizar la carga eléctrica como variable dependiente, y la utilización de variables explicativas independientes para determinar el modelo. Un modelo general puede ser el mostrado en (3.7).

$$y_t = \mu_t + \sum_{k=1}^K B_t^k x_t^k + \varepsilon_t \quad (3.7)$$

donde μ_t representa una serie de vectores de tendencia, expresado como $\mu_t = (\mu_{1,t}, \dots, \mu_{S,t})$, siendo S la longitud del periodo estacional utilizado y ε_t se considera ruido blanco siendo $\varepsilon_t = (\varepsilon_{1,t} \dots \varepsilon_{S,t})$. Los vectores x_t^k son variables explicativas utilizadas para los modelos, construidos a modo de $x_t^k = (x_{1,t}^k, x_{2,t}^k \dots x_{S,t}^k)$ con $k=1 \dots K$, indicando las transformaciones necesarias sobre la variable original. La matriz B_t^k contiene los coeficientes para el modelo $B_t^k = \text{diag}(\beta_t^k)$ con los vectores $\beta_t^k = (\beta_{1,t}^k \dots \beta_{S,t}^k)$ y de nuevo $k=1 \dots K$, para cada una de las transformaciones. El modelo se ajusta utilizando algún criterio de optimización minimizando el error. Este modelo general es la base del resto de modelos de regresión.

Los primeros trabajos encontrados son en la década de los 60-70 (Latham et al. 1968; Theil 1958). Estos autores utilizan los modelos de regresión para predecir la demanda eléctrica, proponiendo varios modelos (lineales, cuadráticos, exponenciales, etc.). La inclusión de características climáticas prácticamente es constante en estos modelos. Stanton y Gupta (1970) relacionan las temperaturas con la demanda eléctrica, utilizando las curvas V de demanda-temperatura, procedimiento que siguen muchos autores (Asbury 1975; Cancelo y Espasa 1996; Bunn y Farmer 1985; Lakhani y Bumb 1978). Gran parte de los trabajos tratan de relacionar la sensibilidad en este tipo de modelos frente a las temperaturas (Corpening, Reppen, y Ringlee 1973; Ernoult et al. 1983; Karanta y Ruusunen 1992; Peirson y Henley 1994). De este modo, se utilizan estos modelos utilizando variables exógenas de temperatura para el ESB irlandés (responsable de la distribución en Irlanda), mediante un sistema automático (Hyde y Hodnett 1997), o utilizando simulaciones de Monte Carlo para realizar previsiones (Smith 2000).

Los modelos de regresión también se utilizan a menudo en conjunto con splines. Harvey y Koopman (1993) presentan un modelo basado en splines para la demanda intradiaria e intrasemanal, donde los efectos producidos por la temperatura del aire pueden modelizarse como un spline a incluir en el modelo. Este método es para la previsión de la demanda eléctrica en Cerdeña (Antoch et al. 2008). Estos modelos evolucionan incluyendo modelos condicionales de splines de acuerdo al tiempo y meteorología (Temporal and Weather conditional EPI-splines, TWE) y se aplica a la zona ISO-NE con buen resultado (Feng y Ryan 2016).

Cooper (1973) aplica la estimación de los coeficientes variables con el tiempo mediante un método aproximado. Analiza la demanda pico para periodos diarios y semanales utilizando los métodos de regresión, mientras que otros autores (Adams, Allen, y Morzuch 1991) desarrollan 3 modelos de regresión, uno para los picos semanales dependientes de la climatología, otro para los

picos semanales dependiendo de la situación socioeconómica, y otro que es la versión diaria de este último. El uso de esta técnica de regresión también se utiliza muy ampliamente para la previsión de precios (Karakatsani y Bunn 2008; Mount, Ning, y Cai 2006; Papalexopoulos y Hesterberg 1990).

Para el ajuste de los modelos, existe la posibilidad de utilizar ventanas para realizar previsiones locales (Zivanovic 2002).

La utilización de las componentes principales (PCA) para encontrar patrones semejantes en la demanda es una de las técnicas que podemos encontrar. Taylor, de Menezes y McSharry (2006) utilizan esta técnica en un modelo de regresión (separando cada hora en el modelo) para capturar la estacionalidad intradiaria, y encontrar similitudes entre diferentes horas. Hyndman y Shang (2009) utilizan la misma metodología, denominada FPC (Hyndman y Ullah 2007), introduciendo el FPLSR (Functional Partial Least Squares Regression) en la previsión de mortalidad y fertilidad en Australia. Estos modelos son posteriormente utilizados para la demanda eléctrica en España (Aneiros et al. 2013; Aneiros, Vilar, y Raña 2016b; Vilar, Aneiros, y Raña 2018; Vilar, Cao, y Aneiros 2012) y para la predicción a muy corto plazo, con series de resolución de hasta el minuto (Shang 2013).

Como se puede apreciar, existe un número elevado y creciente de técnicas basadas en estos modelos.

Modelos de suavizado exponencial

La metodología de suavizado exponencial está basada en desarrollar modelos que utilizan la información de los datos observados, ponderando de alguna forma la información, de modo que se asigne mayor o menor importancia a los últimos datos adquiridos. A partir de esta concepción, son muchas las metodologías desarrolladas. Aquí se muestran las mas comunes y que tengan relevancia en la previsión de demanda eléctrica.

Días similares

La técnica de utilizar días similares para la previsión de demanda ha sido utilizada continuamente. El método, aunque sencillo (en ocasiones recibe el nombre de naïve), resulta ser eficaz. En los últimos años, ha surgido una corriente que se centra en la utilización de este método, en conjunto con otras técnicas. Como ejemplo, Rahman y Hazim (1993) determinan el conjunto de días similares para realizar un modelo de regresión, frente a la utilización de técnicas de I.A. para el establecimiento de días con condiciones similares tanto de demanda como de condiciones climáticas (Tranchita y Torres 2004), o la utilización de algoritmos de búsqueda para patrones similares para poder realizar previsiones (Martínez-Álvarez et al. 2011; Dudek 2015a; 2015b).

Taylor y Snyder (2012) introducen los métodos denominados parsimoniales. Estos métodos buscan utilizar una reducción de términos y parámetros en el modelo mediante el análisis de los ciclos intradiarios, y que denominan suavizado exponencial de ciclos intradiarios. Basados en el trabajo de estados de espacios con múltiples estacionalidades (Gould et al. 2008), Así pues, lo que hacen es separar los ciclos de acuerdo a si se trata de un domingo, sábado, entre semana a partir del lunes a las 8:30 hasta el viernes a las 11:00, y si se trata de lunes antes de las 8:30 o viernes después de las 11:00.

Otro punto de vista del mismo autor, pero centrándose en los métodos basados en cuantiles, donde el suavizado exponencial se realiza de forma total para la semana, y posteriormente se modifica de forma parcial de acuerdo a las características de la estacionalidad intrasemanal e intradiaria (Taylor 2007).

Modelos de Holt-Winters

Los modelos de Holt-Winters consisten en una forma estructurada de ecuaciones (compuesta por una ecuación de nivel, una de tendencia y otra de estacionalidad) que descomponen la información de la serie temporal, y que, mediante una última ecuación de previsión, permite proponer pronósticos a futuro. Como son la parte principal de la tesis, se describen en un apartado posterior con detalle.

Espacios de Estado

Los espacios de estado se presentan como una alternativa dentro del suavizado exponencial a los modelos de Holt-Winters tradicionales, incluyendo matrices de transición e innovación. La idea surge de los lazos de control utilizados en automática. Se puede decir que Moore (1981) desarrolla los primeros trabajos con los modelos (Moore 1981; Aoki 1989; Otter 1984). Estos modelos están directamente relacionados con los modelos de Holt-Winters, ya que parten de una misma formulación, aunque con características diferentes. Una de las ventajas que aportan estos modelos es la capacidad de permitir la obtención de intervalos de confianza en las predicciones para los métodos de suavizado exponencial (Koehler, Snyder, y Ord 2001; Hyndman et al. 2005), lo cual anteriormente no se podía desarrollar. Los espacios de estado se pueden representar como una variación de los modelos anteriores, en los que la representación del modelo parte de su forma de error, teniendo, por tanto, las ecuaciones de doble suavizado exponencial (3.8) a (3.10).

$$\hat{X}_t(h) = S_t + hT_t + \varepsilon_t \quad (3.8)$$

$$S_t = S_{t-1} + T_{t-1} + \alpha\varepsilon_t \quad (3.9)$$

$$T_t = T_{t-1} + \alpha\gamma\varepsilon_t \quad (3.10)$$

S_t representa el nivel, y T_t la tendencia. Estas ecuaciones van acompañadas de los parámetros de suavizado α y γ . $\hat{X}_t(h)$ es

la previsión realizada para h instantes de tiempo futuros. ε_t se considera ruido blanco. La versión para el triple suavizado exponencial, Holt-Winters (3.11) a (3.14).

$$\hat{X}_t(h) = S_t + hT_t + I_{t-s+h} + \varepsilon_t \quad (3.11)$$

$$S_t = S_{t-1} + T_{t-1} + \alpha\varepsilon_t \quad (3.12)$$

$$T_t = T_{t-1} + \alpha\gamma\varepsilon_t \quad (3.13)$$

$$I_t = I_{t-s} + \delta\varepsilon_t \quad (3.14)$$

En esta ocasión se introduce la ecuación para determinar los índices estacionales I_t con un parámetro de suavizado δ . A partir de aquí se puede realizar un desarrollo de las ecuaciones hasta llegar al punto inicial, donde agrupado por ecuaciones, podríamos obtener la siguiente formulación:

$$X_t = w'x_{t-1} + \varepsilon_t \quad (3.15)$$

$$x_t = Fx_{t-1} + g\varepsilon_t I_t = I_{t-s} + \delta\varepsilon_t \quad (3.16)$$

Donde X_t son los valores predichos (observados en el proceso de optimización), y ε_t es ruido blanco. En estas ecuaciones, la primera es la denominada ecuación de medición, mientras que la segunda se denomina ecuación de transición. El vector x_t es el denominado vector de estado, que incluye el nivel, tendencia y estacionalidad cuando se trata de suavizado exponencial. La matriz F es denominada la matriz de transición, mientras que los vectores w y g son vectores de parámetros a estimar. I_t sigue representando los índices estacionales.

Ord, Köhler y Snyder (1997) realizan una clasificación de los métodos de espacios de estado. El uso cada vez más extendido de estos modelos lleva a desarrollar un procedimiento automático para el uso de los espacios de estado (Hyndman et al. 2002; Snyder et al. 2004). Hyndman et al. (2005) desarrollan los intervalos de predicción para los modelos de suavizado

exponencial. Estos estudios se plasman con la presentación de la librería ‘forecast’ para el software R, en la que implementan el código para la utilización de estas herramientas (Hyndman y Khandakar 2008).

Posteriormente, Hyndman et al. (2008) presentan un texto refundido para la utilización y explotación de los modelos de espacios de estado .

La introducción de los modelos múltiple-estacionales en los espacios de estado (Gould et al. 2008) y la utilización de variables exógenas para modelar estacionalidades complejas (De Livera, Hyndman, y Snyder 2011) permite a los espacios de estado adquirir peso en la previsión de la demanda eléctrica. En este último trabajo se incluye la descomposición de Fourier para eliminar la estacionalidad intraanual y se presentan los modelos de espacios de estado con componente de tendencia y estacionalidad, transformación de Box-Cox y corrección del error mediante modelos ARMA (BATS), y la variante con modificadores trigonométricos (TBATS).

Hyndman y Fan (2010) analizan la demanda a largo y medio plazo utilizando espacios de estado en Australia. Además, relacionan los picos con elementos diversos como el calendario, la población, la temperatura, etc. Dordonnat, Koopman y Ooms (2012) aplican estos modelos a la demanda eléctrica horaria francesa.

Modelos autorregresivos y ARIMA

Los modelos autorregresivos tienen su fundamento en la utilización de la información anterior de modo que se establece una combinación lineal de los propios valores ordenados en el tiempo. Estos modelos se expresan de acuerdo a (3.17):

$$\phi(B)X_t = \varepsilon_t \tag{3.17}$$

Sin embargo, la utilización de estos modelos se ha generalizado acompañada de una parte de media móvil, que se identifican como modelos ARMA, donde incluye además de una parte autorregresiva, una de media móvil, como se expresa en (3.18).

$$\phi(B)X_t = \theta(B)\varepsilon_t \quad (3.18)$$

Donde el operador B es el operador de retardo, y en la parte izquierda de la ecuación, $\phi(B)$ es una forma de representar un polinomio que se expresaría como $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ y representa la parte autorregresiva del modelo. Por su parte, $\theta(B)$ es, de igual modo, la representación de un polinomio $\theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q$. P y q representan el orden del polinomio, mientras que ϕ_i y θ_i son los coeficientes del mismo. ε_t es ruido blanco, que se define como el error cometido que sigue una distribución normal $N(0, \sigma)$.

Uno de los requerimientos para poder trabajar con estos modelos es la necesidad de que la serie sea estacionaria. Este requisito es poco habitual en las series reales, pero gracias a la metodología de Box-Jenkins (Box y Jenkins 1976) estos modelos se pueden trabajar de modo relativamente sencillo. Box y Jenkins proponen los modelos ARIMA, y la versión con estacionalidad SARIMA. Estos modelos se expresan según (3.19).

$$\phi(B)\Phi(B^S)\nabla^d\nabla^D X_t = \theta(B)\Theta(B^S)\varepsilon_t \quad (3.19)$$

Aquí $\Phi(B^S)$ y $\Theta(B^S)$ son polinomios que se expresan de igual modo que en el caso anterior, pero que corresponden a la parte estacional, cuya longitud de periodo es S. Los operadores ∇^d y ∇^D son operadores diferencia.

Estos modelos gozan de gran popularidad debido a la relativa sencillez, aunque no son los más eficientes (Brockwell y

Davis 1991; 2002). El hecho de poder obtener los parámetros máximo-verosímiles, además de proporcionar unos intervalos de confianza, le otorgan mucho interés en las predicciones con series temporales.

Además, la introducción de los filtros Kalman (Kalman 1960; Welch y Bishop 2006) o el algoritmo de Durbin-Levinson (Durbin 1960) favorece la obtención de los parámetros.

Contreras et al. (2003) por otro lado desarrollan un modelo ARIMA doble estacional para la previsión de los precios, incluyendo estacionalidad diaria y semanal, que luego extienden a la demanda eléctrica (Contreras y Santos 2006). En el mismo año Taylor (2003b) propone un modelos doble estacional, similar al de Holt-Winters en el que varias estacionalidades son utilizadas en el modelo de forma anidada. Los modelos DSARIMA se expresan como $ARIMA(p, d, q) \times (P_1, D_1, Q_1)_{s_1} \times (P_2, D_2, Q_2)_{s_2}$ como en la ecuación (3.20):

$$\begin{aligned} \Phi_p(B)\Phi_{P_1}(B^{s_1})\Omega_{P_2}(B^{s_2})\nabla^d \nabla_{s_1}^{D_1} \nabla_{s_2}^{D_2} X_t = \\ \theta_q(B)\theta_{Q_1}(B^{s_1})\Psi_{Q_2}(B^{s_2})\varepsilon_t \end{aligned} \quad (3.20)$$

Donde s_1 y s_2 son las longitudes de las estacionalidades intradiaria e intrasemanal. Φ_{P_1} y θ_{Q_1} son los polinomios de orden P_1 y Q_1 asociados a s_1 , Ω_{P_2} y Ψ_{Q_2} son los polinomios de orden P_2 , Q_2 asociados a s_2 . D_1 y D_2 son los órdenes de diferenciación en cada periodo estacional. B es el operador retardo.

Esto ha llevado a otros autores (Mohamed et al. 2010; Suhartono y Endharta 2009; Mohamed, Ahmad, y Ismail 2011; Kim 2013) a utilizar los modelos SARIMA doble estacionales en el pronóstico de demanda de varios países. De hecho, (Muñoz et al. 2010) lo utilizan para realizar el modelo de previsión de REE para la demanda en España.

Arora y Taylor (2018b). aplican los métodos basados en reglas dentro de los modelos ARIMA para introducir eventos

especiales, de forma similar a lo realizado con los modelos de Holt-Winters.

Espasa y Peña son referentes en el uso de los modelos AIRMA en España (Espasa 1980; Caiado, Crato, y Peña 2006; V. Gómez, Maravall, y Peña 1999). Gómez y Maravall destacan por sus trabajos en la automatización de los modelos, desarrollando el software TRAMO y su posterior versión para el gobierno estadounidense SEATS (Gómez y Maravall 1994; 1998; 1997; Victor Gómez y Maravall 2011).

Su utilización en el mercado de la energía eléctrica en España es reciente, aunque es el principal método utilizado. Gross y Galiana (1987) introducen los modelos ARIMA para la predicción de la demanda eléctrica en España. Concretando para la demanda eléctrica en España, Cancelo y Espasa (1996) descomponen la curva de la demanda en diferentes componentes, la parte regular denominada demanda base y que se modela mediante modelos ARIMA (24 modelos para cada hora), y componentes que se suman con variables dicotómicas para modelar el efecto de la temperatura, los días festivos, etc. Para tratar el tema del efecto temperatura, también se introducen el análisis de intervención (Juberias et al. 1999).

El desarrollo de los modelos ARIMA para la determinación de precios en España es más habitual (Espínola et al. 2002; Nogales et al. 2002; Contreras et al. 2003). En ellos presentan modelos ARIMA modelos que incluyen función de transferencia (Conejo et al. 2005; Nogales y Conejo 2006).

Estos modelos son adoptados por REE para su explotación (Cancelo, Espasa, y Grafe 2008). Fuera de España, también es común el uso de los modelos ARIMA para la previsión de demanda en Grecia (Pappas et al. 2008; 2010) y Japón (Ohtsuka, Oga, y Kakamu 2010).

Son de especial mención los modelos AR condicionales heterocedásticos, presentados por Engle y Mustafa (1992). Los

modelos ARCH y GARCH son modelos que consiguen trabajar dentro de la heterocedasticidad. Estos modelos se han aplicado generalmente para la previsión de precios, pero también se han hecho modelos para previsión en España y en California (García et al. 2005).

Existe una creciente tendencia a utilizar modelos híbridos. Tan et al. (2010) introducen modelos mixtos GARCH-ARIMA para la previsión. Requieren primero de una descomposición wavelet, y posteriormente componen un modelo para los precios. No hay muchos casos de aplicación para la demanda eléctrica. Otros autores también optan por la realización de modelos híbridos ARIMA-GARCH (Hor, Watson, y Majithia 2006; Sigauke y Chikobvu 2011; Hickey, Loomis, y Mohammadi 2012; Cifter 2013) en los cuales se realiza un modelo ARMA y los residuos se modelizan mediante modelos GARCH, o incluso la utilización de modelos ARIMAX-GARCH (Zolfaghari y Sahabi 2019).

3.4.3. Modelos computacionales

Los modelos computacionales basan su fundamento en la utilización de modelos matemáticos desarrollados a partir de la emulación de comportamientos naturales, generando así conceptos como lógica difusa, modelos de aprendizaje, algoritmos de evolución, etc. Generalmente se los conoce como modelos de inteligencia artificial (IA). Una magnífica descripción de las redes neuronales puede encontrarse en (Haykin y Simon 1994). Los modelos IA son muchos, pero destacan los modelos basados en redes neuronales artificiales (ANN) y los modelos de lógica difusa.

Los modelos de redes neuronales, aunque empiezan su andadura en los años 40, no tuvieron auge hasta el 1975, cuando Paul Werbos desarrolla el método de entrenamiento por retropropagación. A partir de aquí el uso de las redes neuronales se extiende, y se crean los denominados máquina de vector soporte (SVM). En la actualidad se está produciendo un

incremento notable en la posibilidad de trabajar con redes neuronales recurrentes, otro tipo de redes que resultan ser muy indicadas para las series temporales. Una buena descripción de las redes neuronales puede encontrarse en (Baliyan, Gaurav, y Kumar Mishra 2015).

Redes neuronales

Los modelos de redes neuronales se basan en generar una serie de nodos (denominados neuronas), que pueden obtener valores de 1 o 0. Estas neuronas se organizan en redes y capas, de modo que, mediante una fase de entrenamiento, se puede asignar valores y ajustar este modelo. De este modo, las neuronas capturan la información de los datos en el pasado y conforman la red. La Figura 3.4 muestra el diagrama habitual de una red neuronal.

Estos métodos encuentran su aplicación en modelos poco lineales, y se utilizan en gran medida para la estimación de precios. El uso de redes neuronales para el consumo eléctrico se remonta a finales de los años 80 y principios de los 90. Damborg, Peng, Hubele y otros autores utilizan las redes neuronales para el control y planificación de sistemas de potencia (Damborg et al. 1990; Peng, Hubele, y Karadi 1992). Todos ellos comparan los métodos ARIMA y la metodología de Box-Jenkins con la introducción de las redes neuronales (Czernichow et al. 1996) y (Faraway y Chatfield 1995; 1998). Advierten que el uso de las redes neuronales se prodiga, pero que se ejecuta de forma errónea, e indican algunas de las principales causas.

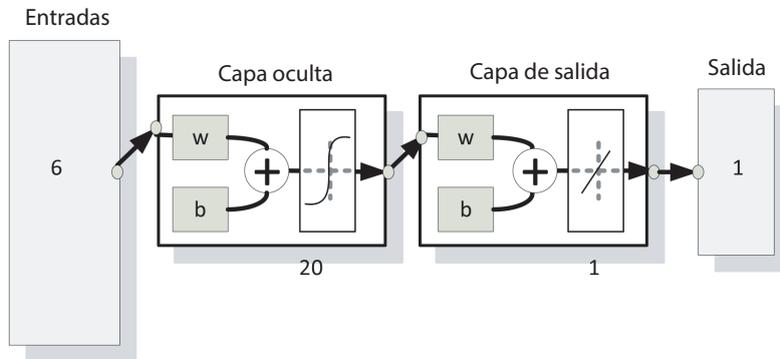


Figura 3.5. Diagrama de una red neuronal. Las entradas (6 en este caso) se conectan con una red de neuronas en una capa oculta (de 20 neuronas), y una capa de salida (1 neurona).

Darbellay y Slama (2000) concluyen la necesidad de establecer primeramente un estudio y determinar si el modelo es lineal o no, y la necesidad de utilizar redes neuronales.

Hippert, Pedreira y Souza (2001) realizan una extensa revisión de los métodos de previsión con redes neuronales hasta la fecha. Destacan que la modelización usando las redes neuronales siguen siendo poco explicativas, y que no demuestran realizar mejores previsiones que el resto de métodos. Comprueban que las redes están sobreparametrizadas y dudan de los resultados.

Baliyan, Gaurav y Mishra (2015) revisan los trabajos relativos al uso de redes neuronales para la previsión de la demanda eléctrica. Destacan la utilización de combinada de modelos de I.A. Redes neuronales, ANN, con Back Propagation, con lógica difusa, algoritmos genéticos con PSO (Particle swarm optimisation).

Fallah et al. (2019) recopilan los métodos habituales de inteligencia artificial aplicados a la previsión de demanda eléctrica en el corto plazo. Existen las técnicas de patrones

similares, las de selección de variables, jerarquizadas y de selección de la estación del año.

La utilización de patrones similares permite que se repiten en la serie son utilizados para luego predecir previsiones de demanda futuras (Troncoso et al. 2004; Martínez-Álvarez et al. 2011; Koprinska et al. 2013). La introducción de redes neuronales iterativas (INN) consigue la mejora de las previsiones realizadas por estas redes neuronales (Rana, Koprinska, y Troncoso 2014).

El uso de funciones no-paramétricas permite a las redes neuronales realizar previsiones incluyendo variables climatológicas. Un ejemplo de aplicación a los datos de demanda en EEUU utilizando esta técnica se puede obtener en (Aneiros-Pérez y Vieu 2008; Aneiros-Pérez, Cao, y Vilar-Fernández 2011; Vilar, Cao, y Aneiros 2012).

Estos métodos se han utilizado para prever la demanda en Malasia con resolución medio-horaria (Mohamed et al. 2012).

Redes neuronales de lógica difusa

La lógica difusa aplicada a las redes neuronales consiste en asimilar que las neuronas admiten valores cualitativos, que no únicamente 0 o 1. Esto es lo que se denomina redes neuronales de lógica difusa, o FNN, y que consiguen reunir en una sola técnica las redes neuronales y la lógica difusa.

El modelo generalizado se utiliza para la previsión de la demanda, partiendo de los modelos de redes neuronales y aplicando criterios cualitativos como si de un operador se tratase (Rahman y Hazim 1993), que incluyen un análisis sobre la temperatura y como incluirla en el modelo. Mitra y Hayashi (2000) recopilan la información habida del uso de estas técnicas, y analizan la clasificación (no existente) de este tipo de herramientas. Abraham y Nath (1996) comparan el uso de las FNN frente a los modelos ARIMA en la previsión de demanda de

la Victorian Power Exchange en Australia. Concluyen que los resultados obtenidos mediante las técnicas FNN mejoran los obtenidos por los ARIMA.

La aplicación de estas técnicas a los precios de la electricidad en España se pueden observar en (Amjady 2006) pero no hay literatura referente a la demanda eléctrica en España.

Maquina de vector soporte

Las máquinas de vector soporte (SVM) fueron desarrolladas por Cortés y Vapnik (1995). Esta herramienta tiene como objetivo realizar una clasificación en el espacio, dividiendo los datos observados según patrones, y realizando modelos de regresión simples dentro de cada uno de ellos. Las primeras propuestas de aplicación a demanda eléctrica se encuentran a principios de los años 2000 (Mohandes 2002; Chen, Chang, y Lin 2004). La aplicación de los SVM suele ser híbrida, en conjunto con otras técnicas, como realizar una descomposición wavelet y luego aplicar los modelos SVM para realizar los pronósticos (Pahasa y Theera-Umporn 2007).

Ahmad et al. (2014) recopilan los trabajos relacionados con el SVM aplicados al consumo energético. Destacan que son pocos los artículos publicados entre otras cosas por la carga computacional que requieren estos modelos.

Estos modelos no son de gran aplicación en la demanda eléctrica. Su utilidad está más indicada con modelos poco lineales. Los intentos realizados han dado buenos resultados, pero como se ha comentado antes, la gran carga computacional provoca rechazo entre los agentes que pudieran utilizarlo. Se ha aplicado para poder prever el consumo de demanda en Italia, incluyendo temperaturas (De Felice, Alessandri, y Catalano 2015). Otras soluciones se proponen, como la utilización de las SVM con optimización por algoritmo de saltamontes (SVM-GAO) (Barman, Dev Choudhury, y Sutradhar 2018) y por luciérniaga (SVM-FA) (Barman y Dev Choudhury 2019).

En la actualidad, los trabajos más recientes con el uso de estas técnicas y que se relacionen con la demanda eléctrica pueden verse en modelos híbridos que se desarrollan en conjunto con las metodologías SVM (máquinas de vector de soporte), generando modelos conocidos como SVR, (vectores de soporte en regresión).

Los trabajos son abundantes y con combinaciones de todo tipo. Podemos encontrar modelos donde se introduce un modelo SVR con submuestras agrupadas (SSVRE) y se aplica a la demanda eléctrica en Jiangxi (China) y Nueva Gales del Sur (Australia) (Li, Che, y Yang 2018). También se utiliza mediante la aplicación de splines multivariado y adaptivos de regresión (MARS) con modelos ARIMA y lo aplica a Queensland (Australia) (Al-Musaylh et al. 2018) que también se aplica a la demanda eléctrica en Irlanda (Vrablecová et al. 2018). W.C. Hong y Fan (2019) introducen los modelos H-EMD-SVR-PSO, aplicados a la demanda eléctrica australiana. Basan sus trabajos en (Romero, Dorronsoro, y Díaz 2018), y en los modelos propuestos en (W. C. Hong et al. 2013). El proceso de la utilización del SVR para la demanda eléctrica en Australia se describe en (Setiawan, Koprinska, y Agelidis 2009); estas técnicas para la previsión en la demanda eléctrica se aplican para el Reino Unido (Bordignon et al. 2013). Dudek (2016) utiliza los modelos de regresión para agrupar en patrones de días similares y proceder a la previsión.

3.5. Suavizado exponencial con modelos de Holt-Winters

En esta sección se desarrolla en profundidad el estado del arte para los modelos de Holt-Winters. Se sigue un orden cronológico, y posteriormente se desarrollan aspectos fundamentales de los modelos.

La utilización del término suavizado exponencial fue acuñado por primera vez por Muth (Muth 1960). Holt (1957)

publica su modelos de suavizado simple, Brown (1959) el suavizado doble, incluyendo la tendencia, y Winters (1960) el suavizado triple, que hoy comúnmente se conoce como Holt-Winters.

Los modelos de suavizado exponencial basan su funcionamiento en utilizar la información obtenida en el pasado y actualizarla con las nuevas observaciones, de modo que se asignan para dar más importancia a los nuevos valores de la serie, o a los anteriores. De este modo, mediante la combinación de una serie de ecuaciones, denominadas ecuaciones de amortiguamiento o ecuaciones de transición, se puede modelar las características de los datos observados que, finalmente, una ecuación de previsión utilizará para dar predicciones futuras en base a la serie observada.

La contribución de cada uno de los anteriores autores se centra en añadir nuevas ecuaciones para capturar cada uno de los efectos de la serie, y así se puede tratar de simple, doble y triple suavizado exponencial. A partir de ahí, se construye una ecuación de previsión que depende de las denominadas ecuaciones de transición.

Suavizado exponencial simple, con una única ecuación de nivel (3.21) con un parámetro de suavizado α .

$$S_t = \alpha X_t + (1 - \alpha)S_{t-1} \quad (3.21)$$

Suavizado exponencial doble, que incluye la tendencia (variación a largo plazo de la serie temporal). Se muestra en (3.22) a (3.24).

$$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (3.22)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (3.23)$$

$$\hat{X}_t(h) = S_t + hT_t \quad (3.24)$$

En este modelo se incluye la tendencia T_t y su parámetro de suavizado γ además de la ecuación de previsión $\hat{X}_t(h)$ para realizar previsiones h instantes de tiempo posteriores.

Y por último el suavizado exponencial triple, que incluye el factor estacional, se presenta en (3.25) a (3.28).

$$S_t = \alpha(X_t - I_{t-s}) + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (3.25)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (3.26)$$

$$I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-s} \quad (3.27)$$

$$\hat{X}_t(h) = S_t + hT_t + I_{t-s+h} \quad (3.28)$$

En este modelo la ecuación S_t es la ecuación de nivel, amortiguada con el parámetro α . La ecuación T_t es la ecuación para la tendencia, con el parámetro de suavizado γ . La ecuación I_t es la ecuación con los índices para la estacionalidad, de longitud s , y parámetro de suavizado δ . Todas estas son las denominadas ecuaciones de transición. La información de ellas se utiliza en $\hat{X}_t(h)$ para realizar previsiones a h instantes de tiempo en el futuro.

Los valores de los parámetros se obtienen resolviendo un problema no lineal, en el cual se trata de minimizar el error ε_t del ajuste del modelo frente a los datos observados, variando los parámetros de suavizado, que se limitan a valores entre 0 y 1. Los modelos de Holt-Winters son recurrentes, y por lo tanto deben ser iniciados con unos valores iniciales. En la siguiente sección se describe con mayor profundidad estos modelos.

La inclusión de las estacionalidades en los modelos implica una mejora de las previsiones (Makridakis, Wheelwright, y Hyndman 1998), aunque es necesario que la serie muestra claramente una estacionalidad marcada, en caso contrario las previsiones serán menos ajustadas (Groff 1973). Además, por norma general, se prefiere desestacionalizar la serie o aplicar

transformadas de Fourier y trabajar con una única estacionalidad (Christiaanse 1971).

Gardner Jr. (1985) realiza la primera recopilación de los modelos existentes, donde se analizan los modelos existentes y los resultados obtenidos. Destaca la lucha existente en la bibliografía entre los modelos de suavizado exponencial y los modelos ARIMA. Además, cómo se buscan opciones para minimizar el número de parámetros, incluyendo modelos como los modelos generales de suavizado exponencial, que incluyen series de Fourier. Pero los resultados de estos modelos no mejoran en precisión los de los modelos Holt-Winters estándar (Reid 1975). También encuentra que los modelos están siendo mal utilizados para realizar comparativas (Gardner Jr. y McKenzie 1988).

Los trabajos que se desarrollan en ese momento se focalizan en el estudio de las propiedades empíricas en los modelos, los métodos de evaluación de la efectividad y los indicadores para establecer las características de los modelos. Estos trabajos tienen como referente a Makridakis e Hibon (1991) y se realizan diferentes competiciones para comprobar la eficiencia de los modelos (Makridakis et al. 1982; 1993; Makridakis y Hibon 2000). Se desarrollan metodologías heurísticas para poder realizar previsiones, un ejemplo de ellas serían las conocidas como “Focus forecasting” (Flores y Whybark 1986) que no demuestran tener mejor precisión que los modelos de Holt-Winters (Gardner Jr., Anderson-Fletcher, y Wicks 2001).

Gardner Jr. Y McKenzie (1985) presentan modelos que incluyen en la tendencia el factor de amortiguamiento. Posteriormente, se muestran ejemplos y la eficiencia de los modelos que utilizan el factor de amortiguamiento (Gardner Jr. y McKenzie 1989; 2011), a pesar de que no consigue mucha difusión en la bibliografía. Taylor (2003a) presenta los modelos de suavizado exponencial con tendencia multiplicativa amortiguada.

El 2003 supone un cambio de tendencia y los modelos de Holt-Winters vuelven a tener interés entre la comunidad científica con la utilización de varias estacionalidades. Los modelos múltiple-estacionales nacen como un requerimiento para mejorar la precisión en la demanda y suponen un punto de inflexión para las herramientas de previsión. Taylor (2003b) presenta de modo anidado la inclusión de una estacionalidad dentro de otra. En el mismo trabajo se presentará el modelo ARIMA doble estacional, además incluye en el modelo la utilización del error de autoregresión de primer orden, basado en Gilchrist (1976) y en Reid (1975). El modelo se muestra en las ecuaciones (3.29)-(3.33).

$$S_t = \alpha \frac{X_t}{d_{t-24}w_{t-168}} + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (3.29)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (3.30)$$

$$d_t = \delta \frac{X_t}{S_t w_{t-168}} + (1 - \delta)d_{t-24} \quad (3.31)$$

$$w_t = \omega \frac{X_t}{S_t d_{t-24}} + (1 - \omega)w_{t-168} \quad (3.32)$$

$$\begin{aligned} \hat{X}_t(h) &= \\ &= (S_t + hT_t)d_{t-24+h}w_{t-168+h} + \varphi_{AR}^h \varepsilon_t \end{aligned} \quad (3.33)$$

Donde la estacionalidad se desdobra en d_t para la estacionalidad diaria y w_t para la estacionalidad semanal, con parámetros de suavizado δ y ω . Para incluir el ajuste mediante la corrección del error de autocorrelación de primer orden, se incluye el factor φ_{AR} que se debe ajustar en el mismo momento que se obtienen los parámetros.

Gardner Jr. (2006) amplia el trabajo expuesto en Gardner Jr. (1985) donde se aprecia que la entrada de los espacios de estado abre un nuevo camino en el desarrollo de los modelos de Holt-Winters. Además encuentra que en muchos de los trabajos con los modelos se evita entrar en la selección modelos, lo cual menoscaba la oportunidad de ver variaciones entre modelos. Destaca que el indicador que debería utilizarse para la selección de modelos es el AIC, a pesar de nuevos indicadores que aparecen (Billah, Hyndman, y Koehler 2005; Billah et al. 2006).

Taylor (2008) analiza el efecto del periodo de predicción cuando se produce el ajuste (generalmente, el ajuste se realiza mediante la minimización del error a un instante de tiempo posterior, y Taylor analiza desde un instante, hasta 30 posteriores). Los parámetros varían mínimamente. Describe cómo en la National Grid (es un gestor del sistema en Gran Bretaña) se utiliza, además, la temperatura para escalar el factor de la demanda base, basado en los datos proporcionados por el European Centre for Medium-range Weather Forecasts (Taylor y Buizza 2003).

Taylor y McSharry (2007) describen como la utilización de modelos que incluyen temperatura en los métodos de suavizado exponencial para la previsión a corto plazo resulta impracticable. Está claro que es influyente, pero no utilizable.

Taylor (2010b) presenta el modelo triple estacional, aditivo y sin tendencia. Este modelo incluye una tercera estacionalidad anual, que se incluye en el modelo. El modelo presentado se muestra en (3.34)-(3.38).

$$S_t = \alpha(X_t - d_{t-24} - w_{t-168} - a_{t-8760}) + (1 - \alpha)(S_{t-1}) \quad (3.34)$$

$$d_t = \delta(X_t - S_t - w_{t-168} - a_{t-8760}) + (1 - \delta)d_{t-24} \quad (3.35)$$

$$w_t = \omega(X_t - s_t - d_{t-24} - a_{t-8760}) + (1 - \omega)w_{t-168} \quad (3.36)$$

$$a_t = \tau(X_t - s_t - d_{t-24} - w_{t-168}) + (1 - \tau)a_{t-8760} \quad (3.37)$$

$$\hat{X}_t(h) = s_t + d_{t-24+h}w_{t-168+h} + a_{t-8760+h} + \varphi_{AR}^h \varepsilon_t \quad (3.38)$$

Gardner Jr. Y McKenzie (2011) denuncian el poco interés de la literatura en promover los métodos con tendencia amortiguada, confirmando, y justificando los buenos resultados que consiguen.

Taylor y Snyder (2012) utilizan los modelos doble estacionales junto a la búsqueda de patrones cíclicos para modelizar el patrón intradiario. García-Díaz y Trull (2016) generalizan los modelos y determinan cómo los modelos doble estacionales ofrecen mejores resultados que los triple estacionales si los datos no se filtran.

Taylor (2010a) propone 5 modelos de suavizado exponencial basado en Holt-Winters, híbridos con los métodos de ciclos intradiarios (Intra-day cycle, IC). Propone los métodos parsimoniales de suavizado exponencial con estacionalidades divididas (Total and Split exponential smoothing), métodos de suavizado exponencial basados en splines, y los métodos de suavizado exponencial con descomposición de valor único (SVD - exponential smoothing). Todos estos modelos se desarrollan de modo experimental.

En los últimos años se trabaja sobre la ecuación de nivel, con el fin de reducir el ruido que proporciona la serie, y que se incluye en el mismo (Tratar 2014; Tratar, Mojškerc, y Toman 2016; Tratar 2015). Tenemos lo que denominan el MoHW (Holt-

Winters modificado), pero está en fases iniciales. La ecuación de nivel se expresa en estos modelos como indica (3.39), que modifica la ecuación (3.25).

$$S_t = \alpha X_t - I_{t-s} + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (3.39)$$

El tratamiento de valores anómalos puede considerarse como una situación especial por ser un día vacacional. Este nuevo caso supone el tratamiento de la serie para trabajar con días especiales. En la literatura suele utilizarse variables ficticias para gestionar esta situación. Sin embargo, nuevos puntos de vista, como los aportados por Bermúdez (Bermúdez 2013) permiten tratar esta situación como covariables. Arora y Taylor (2013, 2018a) utilizan métodos basados en reglas para modificar la tercera estacionalidad y adaptarla en los casos que exista una situación especial. Se modifica la recursividad para que la fecha coincida con un día cuya situación sea similar. Trull, Troncoso y García-Díaz (2019) crean estacionalidades discretas para poder trabajar esta situación.

3.5.1. Tratamiento de valores faltantes y anómalos

Los trabajos relacionados con los datos faltantes y anómalos en los modelos de Holt-Winters, tienen su principal referencia en Cipra (Cipra 1989; Cipra, Trujillo, y Robio 1995). Cipra propone un modelo modificado robusto frente a los valores faltantes, que posteriormente se aplica al cálculo de demanda eléctrica (Castaño 2007). Bermúdez, Corberán-Vallet y Vercher (2009b) aplican métodos bayesianos para realizar las previsiones, y utilizando el algoritmo de esperanza-maximización (EM) en conjunto con la máximo-verosimilitud, es capaz de realizar previsiones incluso con valores faltantes.

La aplicación de métodos robustos para la obtención de previsiones en los modelos de Holt-Winters se basa en la

utilización de estimadores M (Croux, Gelper, y Fried 2008; Gelper, Fried, y Croux 2010).

Es un método diferente del utilizado por Taylor (2007) que utiliza cuantiles para obtener previsiones robustas. Esta metodología es aplicada también en la demanda eléctrica (Gaillard, Goude, y Nedellec 2016).

Cipra y Hanzák (2011) aplican los filtros Kalman de forma robusta a los métodos de suavizado exponencial.

3.5.2. Precisión y los intervalos de confianza

La precisión de las previsiones es un papel fundamental en el desarrollo de las series temporales. Es necesario no sólo determinar el valor puntual de la previsión, sino también ofrecer un valor de incertidumbre que sea confiable. Para ello, hay que dividir el punto en dos puntos fundamentales: cómo medir la precisión y cómo ofrecer valores de incertidumbre. La primera se realiza mediante las funciones de scoring (puntuación) y la segunda mediante los intervalos de predicción.

La determinación de los parámetros del modelo se realiza mediante la minimización del error de la previsión. Generalmente se utiliza la previsión a un instante posterior, y mediante el uso de alguna de las funciones de scoring, se obtiene la medida del error cometido. Al tratarse de modelos no lineales, la minimización del error sólo puede realizarse mediante la utilización de algún algoritmo no lineal. La obtención de los valores máximo-verosímiles queda por tanto descartada. Del mismo modo, si se pretende conocer la precisión de las previsiones, es necesario utilizar también una función de scoring.

Un test importante para determinar si dos predicciones diferentes resultan significativamente diferentes es el test de Diebold y Mariano (Diebold y Mariano 1995; 2002). Este test, conocido como DM-Test es mejorado en (Mayer, Liu, y Dang 2017). Compara si existen diferencias significativas entre los

residuos de ambas predicciones y realiza un contraste de hipótesis.

Los intervalos de confianza son una asignatura pendiente en los modelos de previsión Holt-Winters (Makridakis et al. 1987). Los intervalos deberían poder expresarse como en (3.40).

$$IC(h) = \sqrt{h} \cdot Z_{\alpha/2} \cdot S_e \quad (3.40)$$

Donde h es el horizonte de previsión, $Z_{\alpha/2}$ es el valor crítico en una distribución normal tipificada, con nivel de confianza $(1 - \alpha)$ y S_e la desviación estándar del error cometido en el ajuste. Los cálculos de la varianza del error en los pronósticos utilizando los modelos de Holt-Winters se remonta a (Sweet 1985). En la primera competición M, sólo el 30% de los intervalos de confianza resultaron ser posibles (respecto del 95% que cabía esperar).

A partir de ahí, Gardner Jr. (1988) determina un método simple para establecer los intervalos de confianza en la predicción. Chatfield y Yar (1991,1990) y Chatfield (1996) expresan la región de incertidumbre en la medida como los intervalos de la predicción, y posteriormente, recogen las diferentes nomenclaturas con las que se refieren a la incertidumbre de la previsión (Chatfield 2000). Pone de manifiesto que, aunque las previsiones se realizan de forma general en las empresas utilizando estas técnicas, no es de uso difundido el proveer de intervalos de predicción, a pesar de su importancia.

Dada la dificultad de obtener los intervalos de predicción en los modelos de suavizado exponencial, se ha recurrido de forma continuada a asimilarlos con otros modelos. De este modo, para un método de suavizado exponencial simple, podríamos obtener que la varianza es de acuerdo a (3.41).

$$S_e = [1 + (h - 1)\alpha^2]\sigma_e^2 \quad (3.41)$$

Con α el parámetro de suavizado para el nivel, y con σ_e^2 como la varianza del error de predicción a un instante posterior.

Dada la dificultad de obtener este valor, se ha recurrido de forma continuada al uso de técnicas de simulación, como el bootstrap o métodos basados en cuantiles (Taylor y Bunn 1999).

Taylor (2007) muestra el uso de los cuantiles para los intervalos de predicción. Fildes et al (2008) comentan la importancia, pero dificultad de trabajar con los intervalos de predicción en suavizado exponencial.

La obtención para los espacios de los intervalos de predicción, permite que, en cierta forma, sean adaptables a los modelos de Holt-Winters (Koehler, Snyder, y Ord 2001; Hyndman et al. 2005). Este trabajo se extiende para la introducción de covariables en los intervalos de predicción (Göb, Lurz, y Pievatolo 2015).

3.5.3. Temperatura

Uno de los factores críticos en la previsión de la demanda es la temperatura, englobada dentro de los factores climáticos. Generalmente se incluye en los modelos de previsión. Esto se debe en gran parte a que los modelos normalmente utilizados se basan en modelos de regresión o redes neuronales (Thompson 1976; Ernoult et al. 1983; Gross y Galiana 1987).

Respecto a su utilización en un modelo de previsión para la demanda en España, Cancelo y Espasa (1991) analizan el efecto de la climatología sobre la demanda. A partir de aquí cuantifican los valores en variables y posteriormente proponen un modelo de predicción incluyendo la temperatura (Cancelo y Espasa 1995; 1996). En este último trabajo los autores descomponen la demanda eléctrica entre la demanda base (modelizada mediante modelos ARIMA con intervenciones) y una serie de variables ficticias para incluir el efecto de la temperatura del aire y los días vacacionales. Taylor y Buizza

(2003) utilizan la misma técnica, pero para incluir un conjunto racional de variables climatológicas utilizan la metodología del *European Centre for Medium-range Weather Forecasts* (ECMWF). Aquí se proponen 51 escenarios diferentes de condiciones climáticas y calculan la demanda eléctrica en Gales a mediodía de acuerdo a esa previsión, obteniendo 51 previsiones de las que luego obtener una función de densidad y cálculos probabilísticos de la demanda.

Un aspecto importante es la contribución del factor temperatura comparado con otros factores. Engle, Hendry y Richard (1983) determinaron que la temperatura es una exogeneidad débil, pero que, a la hora de la predicción, es reemplazada por una exogeneidad fuerte, lo cual implica que puede perturbar las predicciones. Eso explica la dificultad de incluir la temperatura en los modelos de forma correcta.

La introducción de las temperaturas en la demanda agregada resulta ser un punto importante. Valor, Meneu y Caselles (2001) utilizan cuatro estaciones base a partir de las cuales obtiene una temperatura representativa en España para el cálculo. Estos valores son la base para los modelos en el que las temperaturas son implementadas utilizando las curvas de enfriamiento (CDD) y calentamiento (HDD) (Pardo, Meneu, y Valor 2002; Valor et al. 2002).

Otra vertiente diferente es la aplicación de splines para modelizar los periodos estacionales del año (Martín-Rodríguez y Cáceres-Hernández 2005). Otros autores prefieren incluir la temperatura con modelos no paramétricos (Aneiros-Pérez, Cao, y Vilar-Fernández 2011; Vilar, Cao, y Aneiros 2012). Finalmente, incluyen las curvas de enfriamiento y calentamiento, y realizan combinaciones de previsiones. En ellas se utiliza variables como temperatura y horario solar (Aneiros, Vilar, y Raña 2016a; Vilar, Aneiros, y Raña 2018).

Otro modo completamente diferentes consiste en descomponer la demanda en componentes, y utilizar dos

metodología diferentes en la previsión, siendo que para la tendencia se utilizan redes neuronales y que para las fluctuaciones estacionales se utilizan funciones paramétricas que incluyen variables climatológicas (Gonzalez-Romera, Jaramillo-Moran, y Carmona-Fernandez 2006; González-Romera, Jaramillo-Morán, y Carmona-Fernández 2008).

El valor de la temperatura representativa en España es un factor importante a tener en cuenta. Moral-Carcedo y Vicéns-Otero (2005) determinan una nueva temperatura representativa en España utilizando una ponderación entre siete de las regiones españolas, y ponderando de acuerdo a la población. Cancelo, Espasa y Grafe (2008) modelizan el efecto de la temperatura mediante un modelo no lineal con umbrales. Generalmente se utiliza dentro de un modelo de regresión en el que se incluye la temperatura (OrtizBeviá, RuizdeElvira, y Alvarez-García 2014).

Moral-Carcedo y Pérez-García (2015) analizan la demanda y el efecto que produce en ella la temperatura, distinguiendo por sector de trabajo. Determinan que el sector más afectado es el sector servicios, pero con variaciones del 1%.

López et al. (2017) realizan previsiones en las Islas Baleares utilizando variables climatológicas como el viento, nubosidad y radiación solar. López et al. (2018) desarrollan una metodología para la previsión de la demanda utilizando redes neuronales para modelizar la parte climatológica.

Referente a la utilización de datos de temperatura incluidos en los modelos de Holt-Winters, hay que recordar cómo la National Grid utiliza la temperatura para escalar el factor de la demanda base, basado en los datos proporcionados por el European Centre for Medium-range Weather Forecasts (Taylor y Buizza 2003).

Taylor y McSharry (2007) describen como la utilización de modelos que incluyen temperatura en los métodos de

suavizado exponencial para la previsión a corto plazo resulta impracticable. Está claro que es influyente, pero no utilizable.

3.6. Competiciones

Las competiciones de previsión permiten poder apreciar el interés general de los investigadores por realizar predicciones fiables y precisas. Las competiciones permiten comparar de forma clara, y, al menos así se intenta, transparente, los métodos expuestos de trabajo para la previsión.

Las competiciones propuestas por Makridakis, las competiciones M, comienzan en 1982 (Makridakis et al. 1982). En esta competición se busca mejorar los métodos de previsión, y se contrastan los indicadores de precisión MAPE, MSE, AR, MdAPE y PB. La primera conclusión que obtiene es que los métodos complejos no necesariamente aportan mejores resultados que los modelos sencillos. En la segunda competición (Makridakis et al. 1993), se observa que los modelos con tendencia amortiguada proporcionan resultados notables, y se extrae que los modelos de suavizado exponencial son los más precisos. La M3 (Makridakis y Hibon 2000) trae consigo una serie de conclusiones interesantes: la medida de la precisión depende en cada caso del indicador utilizado, así como de la longitud del conjunto de datos. La combinación de modelos ofrece los mejores resultados. Una conclusión importante es que el indicador de precisión utilizado en el ajuste no es el mejor indicador para seleccionar modelos. En la última competición, el M4 (Makridakis, Spiliotis, y Assimakopoulos 2018) ha demostrado que los mejores modelos son aquellos híbridos estadísticos-inteligencia artificial.

Otras competiciones como la GefCom (Global Energy Forecasting) dirigida por Tao Hong ofrece resultados similares. Se han realizado competiciones en 2012, 2014 (T. Hong et al. 2016) y 2017 (T. Hong, Xie, y Black 2019).

Recientemente, existe una corriente revisionista de las conclusiones obtenidas en las competencias, y del modo de realizarlas (Hyndman 2019; Athanasopoulos y Hyndman 2011) y destacan cómo el principal problema es la reproducibilidad de los datos (Boylan et al. 2015).

Hong y Fan (2016) analizan la situación actual de los trabajos de investigación referentes a la previsión energética y de demanda eléctrica. Concluyen también que los métodos tradicionales están “exhaustos”. Y con el fin de encontrar el mejor modelo hay un incremento masivo de publicaciones con datos alterados, que está perjudicando el desarrollo en esta materia. Esta situación es denunciada y se reclama una reproducibilidad de los análisis a las revistas (Makridakis, Assimakopoulos, y Spiliotis 2018). Aunque esto ya lo destacan otros autores anteriormente (Armstrong y Fildes 2006).

4. Modelos de Holt-Winters múltiple-estacionales

4

4.1. Introducción

En este capítulo se presenta la utilización de los modelos de Holt-Winters múltiple-estacionales, y una metodología de selección del modelo. Con ella se pretende establecer el punto de partida de la innovación en la tesis.

En un primer apartado, se justifica la introducción de los modelos múltiple-estacionales, así como el análisis de la serie horaria de demanda eléctrica en España.

Posteriormente, se realiza una revisión bibliográfica relacionada con el tema, de modo que se establezca el estado del arte para este capítulo.

Seguidamente, se proponen los modelos múltiple-estacionales y la aplicación de los modelos y su utilización, validando los modelos realizando comparativas con otros modelos existentes.

Finalmente, se expone una conclusión de los apartados desarrollados en este capítulo.

4.2. Justificación

La utilización de modelos de Holt-Winters permite establecer de forma sencilla y parsimonial (con la determinación de unos pocos parámetros) previsiones acertadas en series con una marcada estacionalidad – como la de demanda eléctrica en España -. La nueva tendencia a introducir más de una estacionalidad en el modelo permite mejorar sus previsiones sin introducir grandes modificaciones en el mismo, y sin perder una de las claves de su uso: sencillez.

El objetivo de este capítulo es determinar un modelo múltiple estacional – de al menos dos estacionalidades – basado en los métodos de suavizado exponencial de Holt-Winters que permita la obtención de pronósticos precisos para la serie de demanda eléctrica en España.

4.3. Demanda horaria de electricidad en España

La serie temporal de la demanda eléctrica en España presenta un patrón estacional repetido a lo largo de los días de la semana. En la Figura 4.1 se puede observar fácilmente este patrón cíclico. Al mostrarse una misma semana en diferentes años, se observa cómo los días laborales repiten un patrón. Este patrón es de 24 horas y se repite de forma continuada cada día, por ello recibe el nombre de estacionalidad intradiaria. Adicionalmente, en la misma figura se aprecia claramente que, en los fines de semana, la serie adquiere un comportamiento diferente, exhibiendo un patrón diferenciado del diario y que se repite durante los fines de semana. Además, con un examen más exhaustivo del patrón de los días de la semana laboral, se puede intuir cómo existe una ligera variación dentro de la propia semana donde los miércoles suponen un grado de consumo mayor que el resto de los días, y que, como en los casos anteriores, se repite a lo largo de todas las semanas. Éste es el motivo por el cual el patrón recibe el nombre de estacionalidad intrasemanal, y cuya

longitud para la serie de demanda eléctrica horaria en España es de 168 horas.

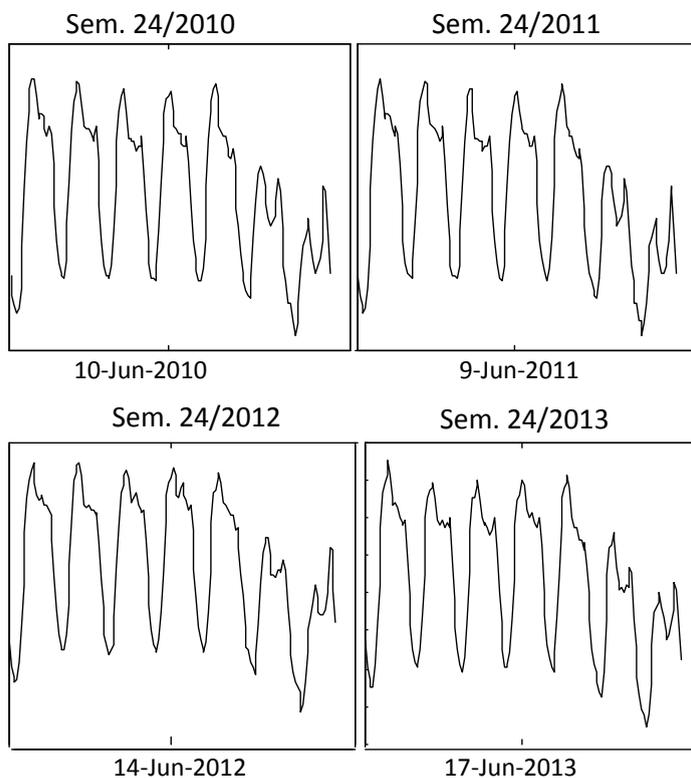


Figura 4.1. Representación de la semana 24 en varios años. Se aprecia como existe un patrón que se repite diariamente, y otro que se repite de forma semanal.

Este análisis puede hacerse más extensivo, y tal y como muestra la Figura 4.2, al analizar dos años diferentes y cercanos, se aprecia cómo prácticamente sus representaciones se superponen.

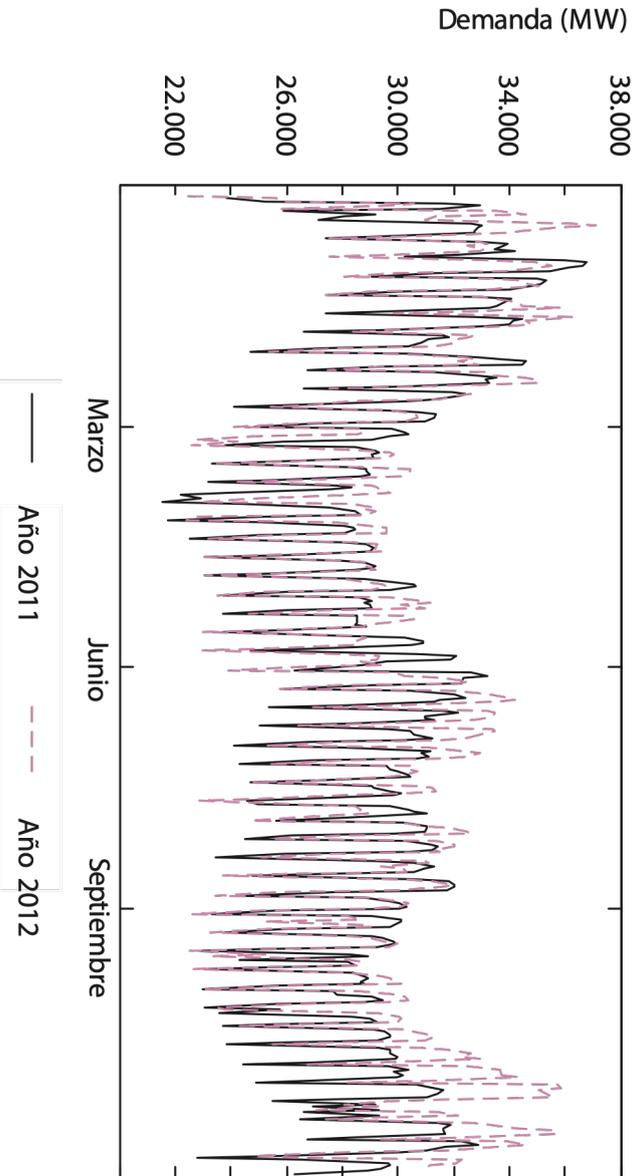


Figura 4.2. Representación de la demanda diaria en dos años diferentes. La forma descrita por ambas representaciones es similar, porque comparten un patrón estacional.

Dado que esta situación se repite a lo largo de los años, se considera la existencia de un nuevo patrón cíclico, de periodicidad aproximada de un año, y que se denomina estacionalidad intraanual. Este proceso podría ser extensible a periodos de tiempo más longevos, buscando ciclos de mayor longitud, aunque los datos utilizados no muestran nuevas estacionalidades.

4.4. Revisión bibliográfica

La utilización de múltiples estacionalidades en los modelos es relativamente reciente. Generalmente se ha optado por una desestacionalización de los modelos, antes que incluir varias estacionalidades en el mismo.

Los modelos de Holt-Winters (Winters 1960) fueron propuestos en los años 60, se expresan como en las ecuaciones (4.1) a (4.4).

$$S_t = \alpha \frac{X_t}{I_{t-s}} + (1 - \alpha)(S_t + T_t) \quad (4.1)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (4.2)$$

$$I_t = \delta \frac{X_t}{S_t} + (1 - \delta)I_{t-24} \quad (4.3)$$

$$\hat{X}_t(h) = (S_t + hT_t)d_{t-24+h} \quad (4.4)$$

donde S_t y T_t son las ecuaciones de nivel y tendencia con sus respectivos parámetros de suavizado α y γ . La ecuación I_t representa los índices estacionales (de longitud s), con parámetro de suavizado δ . Los pronósticos se realizan mediante la ecuación de previsión \hat{X}_t para los futuros h valores. Todos los

modelos incluyen una ecuación de nivel y una ecuación de previsión. La forma de combinación de las ecuaciones de tendencia y estacionalidad, además de su presencia o no, permite obtener un cuadro de opciones conocido como cuadro de Pegels (Pegels 1969), donde los modelos se representan mediante dos letras: la primera para el método de tendencia utilizado (N: ninguna, A: aditiva, M: multiplicativa), y el segundo para el método de estacionalidad. Así pues, las ecuaciones (4.1) a (4.4) son un modelo con tendencia aditiva y estacionalidad multiplicativa, o sea, AM.

Alfares y Nazeeruddin (2002) hacen una revisión de la bibliografía y los modelos que se trabajan hasta el año 2001. Concluyen que los estudios llevados a cabo en previsión de demanda se centran en desarrollar nuevos modelos basados en la regresión y la computación, en detrimento de los modelos clásicos de suavizado exponencial. Los estudios en el suavizado exponencial se dirigen más a estudiar cómo mejorar las metodologías en la práctica, que no a desarrollar nuevos modelos (Makridakis y Hibon 2000). No hay interés por tratar las diferentes estacionalidades, y de forma generalizada, se desestacionalizan los modelos.

Pero con la desregulación del sector eléctrico en muchos países, incluyendo España, los modelos necesitan ser más eficientes. La previsión de demanda no es utilizada únicamente para aumentar la fiabilidad del sistema, sino que, además, forma parte del método de establecimiento de precios, pasando a ser el eje central del sistema eléctrico. Durante todo este tiempo, las empresas eléctricas demandan mejoras en la previsión eléctrica, así como la capacidad de los modelos para trabajar con más de una estacionalidad.

En 2003, J.W. Taylor propone los modelos doble estacionales (Taylor 2003b), tanto los basados en modelos ARIMA (DSARIMA) como Holt-Winters (DSHW). No debe confundirse la terminología de doble estacionalidad con los modelos dobles de suavizado exponencial. En estos modelos se

presenta de forma anidada la periodicidad intrasemanal como modificador de la periodicidad intradiaria.

Para el modelo DSHW, en su forma de tendencia aditiva y estacionalidad multiplicativa, el modelo original de Holt-Winters se reescribe como se describe en (4.5) a (4.9):

$$S_t = \alpha \frac{X_t}{d_{t-24} w_{t-168}} + (1 - \alpha)(S_t + T_t) \quad (4.5)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (4.6)$$

$$d_t = \delta \frac{X_t}{S_t w_{t-168}} + (1 - \delta)d_{t-24} \quad (4.7)$$

$$w_t = \omega \frac{X_t}{S_t d_{t-24}} + (1 - \omega)w_{t-168} \quad (4.8)$$

$$\begin{aligned} \hat{X}_t(h) &= \\ &= (S_t + hT_t)d_{t-24+h}w_{t-168+h} + \varphi_{AR}^h \varepsilon_t \end{aligned} \quad (4.9)$$

En este modelo los índices estaciones I_t se desdoblan ahora en dos componentes, una para la estacionalidad diaria $d_{t,i}$, con parámetro de suavizado δ , y w_t con parámetro ω para la estacionalidad semanal. Se establecen dos periodos, que para la serie horaria de demanda serían de longitud 24 y 168 horas. Además, Taylor introduce un nuevo término, en el que se corrige el error de autocorrelación de primer orden, a través del factor φ_{AR} . Este factor de corrección fue propuesto originalmente por otros autores (Reid 1975; Gilchrist 1976), pero Taylor lo integra dentro del modelo. El factor debe obtenerse en el modelo de forma simultánea con el resto de parámetros. Esta corrección se conoce como ajuste AR(1).

Taylor, de Menezes y McSharry (2006) realizan una comparación exhaustiva entre los modelos doble estacionales,

además de con otras metodologías, como son las redes neuronales y métodos de regresión con análisis de componentes principales. Determinan que el modelo DSHW mejora los resultados de los demás modelos. Gardner Jr. (2006) realiza una revisión del estado del arte para los modelos de suavizado exponencial, y recoge el nuevo modelo, pero no hace ningún inciso sobre la utilidad de las múltiples estacionalidades, y se centra más en el ajuste AR(1).

Este modelo se adopta como generalizado de Holt-Winters (HWT). Algunos autores introducen modificaciones en el modelo, como la inclusión de intervenciones donde, de modo externo al modelo, se introduce una intervención para incluir la influencia de la temperatura en los modelos doble estacionales (Souza, Barros, y Miranda 2007). Estas variaciones sufren de escasa difusión.

Hyndman et al. (2008) introducen el modelo doble estacional aplicado a los modelos de espacios de estado, incluyendo nuevos métodos de inicialización de los modelos. Además, integra en su paquete “forecast” del software estadístico R la utilización de modelos doble estacionales de Holt-Winters.

Finalmente, Taylor presenta el modelo triple estacional (Taylor 2010b), TSHW, como una evolución del doble estacional. En este modelo se presenta una nueva ecuación en la que se trabaja con el periodo intraanual. El modelo queda como se indica en (4.10)-(4.15).

$$S_t = \alpha \frac{X_t}{d_{t-24}w_{t-168}a_{t-8760}} + (1 - \alpha)(S_t + T_t) \quad (4.10)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (4.11)$$

$$d_t = \delta \frac{X_t}{S_t w_{t-168} a_{t-8760}} + (1 - \delta)d_{t-24} \quad (4.12)$$

$$w_t = \omega \frac{X_t}{S_t d_{t-24} a_{t-8760}} + (1 - \omega) w_{t-168} \quad (4.13)$$

$$a_t = \rho \frac{X_t}{S_t d_{t-24} w_{t-168}} + (1 - \rho) a_{t-8760} \quad (4.14)$$

$$\hat{X}_t(h) = (S_t + hT_t) \cdot d_{t-24+h} w_{t-168+h} a_{t-8760+h} + \varphi_{AR}^h \varepsilon_t \quad (4.15)$$

Se incluye la nueva ecuación a_t , representando el índice estacional intranual y ρ su factor de amortiguamiento. El periodo considerado para la tercera estacionalidad son 365.25 días, que resulta ser 8760 horas, y que coincide con el año solar.

La introducción de los modelos de doble y triple estacionalidad requiere de la generación de nuevos métodos para determinar los valores iniciales de la serie. En este capítulo se utilizan los métodos propuestos en (Taylor 2010b). En otro capítulo posterior se analizan los métodos de inicialización.

4.5. Modelos múltiple-estacionales

Tomando las ecuaciones (4.10) a (4.15) como partida, se propone una generalización del modelo, en el que se pueden tratar n estacionalidades (nHWT). El modelo se muestra en las ecuaciones (4.16) a (4.19), donde se ha utilizado la misma forma de tendencia y estacionalidad que en las ecuaciones anteriores, para mayor comprensión.

$$S_t = \alpha \left(\frac{X_t}{\prod I_{t-s_i}^{(i)}} \right) + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (4.16)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (4.17)$$

$$I_t^{(i)} = \delta^{(i)} \left(\frac{X_t}{S_t \prod_{j \neq i} I_{t-s_j}^{(j)}} \right) + (1-\delta^{(i)}) I_{t-s_i}^{(i)} \quad (4.18)$$

$$\hat{X}_t(k) = (S_t + k T_t) \prod_i^{n_s} I_{t-s_i+k}^{(i)} + \varphi_{AR}^k \varepsilon_t \quad (4.19)$$

Donde las estacionalidades se representan mediante las ecuaciones $I_t^{(i)}$ con sus respectivos parámetros de suavizado $\delta^{(i)}$. Cada uno de los patrones estacionales tiene su longitud periódica s_i , y existen tantas ecuaciones de estacionalidad como patrones estacionales se hayan considerado. Así pues, las ecuaciones (4.10) a (4.15) son un caso particular de (4.16) a (4.19). En este modelo, además, se ha introducido el φ_{AR} que es el ajuste para el error autorregresivo de primer orden. Como se ha comentado con anterioridad, este factor permite mejorar el ajuste y las previsiones, aunque incluye un nuevo parámetro a determinar.

Esta generalización es aplicada a todos los métodos de suavizado exponencial, dependiendo del método de la tendencia y de la estacionalidad, recogidos en la Tabla 4.1. Para nombrar a los modelos, se ha considerado la misma nomenclatura ya utilizada con anterioridad, en el que la primera letra indica el método de tendencia utilizado (Aditiva o Multiplicativa, y que pueden estar amortiguadas o no) y la segunda letra indica el método de estacionalidad (Aditiva o Multiplicativa). La tercera letra se añade para indicar si existe o no el ajuste anteriormente indicado. La nomenclatura debe incluir, finalmente, las longitudes de los periodos estacionales utilizados separados por una coma (en este caso 2 estacionalidades, de periodos 24 y 168 horas), siendo, por ejemplo, el método sin tendencia y estacionalidad multiplicativa con ajuste AR(1) el modelo $NMC_{24,168}$.

Tabla 4.1. Resumen de los modelos Holt-Winters múltiple-estacionales implementados.

Estacionalidad	Ninguna	Aditiva	Multip.
Tendencia	Sin ajuste		
Ninguna	NNL	NAL	NML
Aditiva	ANL	AAL	AML
Aditiva Amortiguada	dNL	dAL	dML
Multiplicativa	MNL	MAL	DML
Multiplicativa Amortiguada	DNL	DML	DML

Estacionalidad	Ninguna	Aditiva	Multip.
	Ajustado con AR(1)		
Ninguna	NNC	NAC	NMC
Aditiva	ANC	AAC	AMC
Aditiva Amortiguada	dNC	dAC	dMC
Multiplicativa	MNC	MAC	MMC
Multiplicativa Amortiguada	DMC	DAC	DMC

La Tabla 4.2 muestra el desarrollo para todos los modelos. Los términos utilizados en las ecuaciones son los mismos que en las ecuaciones (4.16) a (4.19). En esta tabla, además, R_t es equivalente a T_t pero para tendencia multiplicativa.

En la tabla se muestran únicamente los modelos que incluyen el ajuste AR(1), con el término φ_{AR} que multiplica al error de ajuste en el último instante ε_t . Para eliminar el ajuste, simplemente hay que asignar un valor nulo al parámetro φ_{AR} .

Al coexistir múltiples estacionalidades, cabe la posibilidad de combinar las estacionalidades de modo independiente para cada estacionalidad (es decir, tener una estacionalidad combinada de forma aditiva y otra multiplicativa). Sin embargo, las primeras pruebas no dieron mejores resultados y se abandonó la idea.

Tabla 4.2. Modelos Múltiple-estacionales de Holt-Winters (nHWT). En filas se organiza por métodos de tendencia, mientras que en columnas por estacionalidad.

Estac. Tend.	Ninguna	Aditiva	Aditiva Amortiguada
Multiplicativa	$S_t = \frac{\alpha X_t}{\prod_{i \neq t-s_i} I_{t-s_i}^{(0)}} + (1-\alpha)S_{t-1}$ $I_t^{(0)} = \delta^{(0)} \frac{X_t}{S_t \prod_{j \neq t-s_j} I_{t-s_j}^{(0)}} + (1-\delta^{(0)})I_{t-s_i}^{(0)}$ $\hat{X}_t(k) = S_t \prod_{i=1}^k I_{t-s_i+k}^{(0)} + \varphi_{AR}^k \varepsilon_t$	$S_t = \frac{\alpha X_t}{\prod_{i \neq t-s_i} I_{t-s_i}^{(0)}} + (1-\alpha)(S_{t-1} + T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1-\gamma)T_{t-1}$ $I_t^{(0)} = \delta^{(0)} \frac{X_t}{S_t \prod_{j \neq t-s_j} I_{t-s_j}^{(0)}} + (1-\delta^{(0)})I_{t-s_i}^{(0)}$ $\hat{X}_t(k) = (S_t + kT_t) \prod_{i=1}^k I_{t-s_i+k}^{(0)} + \varphi_{AR}^k \varepsilon_t$	$S_t = \frac{\alpha X_t}{\prod_{i \neq t-s_i} I_{t-s_i}^{(0)}} + (1-\alpha)(S_{t-1} + \phi T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1-\gamma)\phi T_{t-1}$ $I_t^{(0)} = \delta^{(0)} \frac{X_t}{S_t \prod_{j \neq t-s_j} I_{t-s_j}^{(0)}} + (1-\delta^{(0)})I_{t-s_i}^{(0)}$ $\hat{X}_t(k) = (S_t + T_t \sum_{n=1}^k \phi^n) \prod_{i=1}^k I_{t-s_i+k}^{(0)} + \varphi_{AR}^k \varepsilon_t$
Aditiva	$S_t = \alpha(X_t - \sum_{i=1}^k I_{t-s_i}^{(0)}) + (1-\alpha)S_{t-1}$ $I_t^{(0)} = \delta^{(0)} \left(X_t - S_t - \sum_{j \neq t-s_j} I_{t-s_j}^{(0)} \right) + (1-\delta^{(0)})I_{t-s_i}^{(0)}$ $\hat{X}_t(k) = S_t + \sum_{i=1}^k I_{t-s_i+k}^{(0)} + \varphi_{AR}^k \varepsilon_t$	$S_t = \alpha(X_t - \sum_{i=1}^k I_{t-s_i}^{(0)}) + (1-\alpha)(S_{t-1} + T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1-\gamma)T_{t-1}$ $I_t^{(0)} = \delta^{(0)} \left(X_t - S_t - \sum_{j \neq t-s_j} I_{t-s_j}^{(0)} \right) + (1-\delta^{(0)})I_{t-s_i}^{(0)}$ $\hat{X}_t(k) = S_t + kT_t + \sum_{i=1}^k I_{t-s_i+k}^{(0)} + \varphi_{AR}^k \varepsilon_t$	$S_t = \alpha(X_t - \sum_{i=1}^k I_{t-s_i}^{(0)}) + (1-\alpha)(S_{t-1} + \phi T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1-\gamma)\phi T_{t-1}$ $I_t^{(0)} = \delta^{(0)} \left(X_t - S_t - \sum_{j \neq t-s_j} I_{t-s_j}^{(0)} \right) + (1-\delta^{(0)})I_{t-s_i}^{(0)}$ $\hat{X}_t(k) = S_t + T_t \sum_{n=1}^k \phi^n + \sum_{i=1}^k I_{t-s_i+k}^{(0)} + \varphi_{AR}^k \varepsilon_t$
Ninguna	$S_t = \alpha X_t + (1-\alpha)S_{t-1}$ $\hat{X}_t(k) = S_t + \varphi_{AR}^k \varepsilon_t$	$S_t = \alpha X_t + (1-\alpha)(S_{t-1} + T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1-\gamma)T_{t-1}$ $\hat{X}_t(k) = S_t + kT_t + \varphi_{AR}^k \varepsilon_t$	$S_t = \alpha X_t + (1-\alpha)(S_{t-1} + \phi T_{t-1})$ $T_t = \gamma(S_t - S_{t-1}) + (1-\gamma)\phi T_{t-1}$ $\hat{X}_t(k) = S_t + T_t \sum_{n=1}^k \phi^n + \varphi_{AR}^k \varepsilon_t$

Tabla 4.2 (cont.). Modelos Múltiple-estacionales de Holt-Winters (nHWT). En filas se organiza por métodos de tendencia, mientras que en columnas por estacionalidad.

Estac. Tend.	Multiplicativa	Multiplicativa Amortiguada
Multiplicativa	$S_t = \frac{\alpha X_t}{\prod_l I_{t-s_l}^{(l)}} + (1 - \alpha)(S_{t-1} R_{t-1})$ $T_t = \gamma(S_t/S_{t-1}) + (1 - \gamma)R_{t-1}$ $I_t^{(l)} = \delta^{(l)} \frac{X_t}{S_t \prod_{j \neq l} I_{t-s_j}^{(j)}} + (1 - \delta^{(l)}) I_{t-s_l}^{(l)}$ $\hat{X}_t(k) = (S_t R_t^k) \prod_l I_{t-s_l+k}^{(l)} + \varphi_{AR}^k \varepsilon_t$	$S_t = \frac{\alpha X_t}{\prod_l I_{t-s_l}^{(l)}} + (1 - \alpha)(S_{t-1} R_{t-1}^\phi)$ $R_t = \gamma(S_t/S_{t-1}) + (1 - \gamma)R_{t-1}^\phi$ $I_t^{(l)} = \delta^{(l)} \frac{X_t}{S_t \prod_{j \neq l} I_{t-s_j}^{(j)}} + (1 - \delta^{(l)}) I_{t-s_l}^{(l)}$ $\hat{X}_t(k) = (S_t R_t^{\sum_{j=1}^k \phi^j}) \prod_l I_{t-s_l+k}^{(l)} + \varphi_{AR}^k \varepsilon_t$
Aditiva	$S_t = \alpha(X_t - \sum_l I_{t-s_l}^{(l)}) + (1 - \alpha)(S_{t-1} R_{t-1})$ $R_t = \gamma(S_t/S_{t-1}) + (1 - \gamma)R_{t-1}$ $I_t^{(l)} = \delta^{(l)} \left(X_t - S_t - \sum_{j \neq l} I_{t-s_j}^{(j)} \right) + (1 - \delta^{(l)}) I_{t-s_l}^{(l)}$ $\hat{X}_t(k) = S_t R_t^k + \sum_l I_{t-s_l+k}^{(l)} + \varphi_{AR}^k \varepsilon_t$	$S_t = \alpha(X_t - \sum_l I_{t-s_l}^{(l)}) + (1 - \alpha)(S_{t-1} R_{t-1}^\phi)$ $R_t = \gamma(S_t/S_{t-1}) + (1 - \gamma)R_{t-1}^\phi$ $I_t^{(l)} = \delta^{(l)} \left(X_t - S_t - \sum_{j \neq l} I_{t-s_j}^{(j)} \right) + (1 - \delta^{(l)}) I_{t-s_l}^{(l)}$ $\hat{X}_t(k) = S_t R_t^{\sum_{j=1}^k \phi^j} + \sum_l I_{t-s_l+k}^{(l)} + \varphi_{AR}^k \varepsilon_t$
Ninguna	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} R_{t-1})$ $R_t = \gamma(S_t/S_{t-1}) + (1 - \gamma)R_{t-1}$ $\hat{X}_t(k) = S_t R_t^k + \varphi_{AR}^k \varepsilon_t$	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} R_{t-1}^\phi)$ $R_t = \gamma(S_t/S_{t-1}) + (1 - \gamma)R_{t-1}^\phi$ $\hat{X}_t(k) = S_t R_t^{\sum_{j=1}^k \phi^j} + \varphi_{AR}^k \varepsilon_t$

La introducción de varias estacionalidades en los modelos requiere además del desarrollo de nuevos métodos de obtención de los valores iniciales. Taylor propone un nuevo método basado en (Williams y Miller 1999), en el cual, el cálculo del valor inicial de la tendencia lo calcula como la media de los efectos en cada periodo, y el nivel como la media móvil centrada. Los valores de los índices los calcula como ratios de los valores observados sobre su media móvil, y posteriormente los ajusta para las diferentes estacionalidades.

4.6. Explotación de los modelos

La generalización de los modelos nHWT requiere de un nuevo tratamiento del modelizado, determinación de valores iniciales e incluso de optimización. En capítulos posteriores se analizarán estos aspectos con profundidad. En este capítulo se mostrará un ejemplo de aplicación.

4.6.1. Optimización y predicción

Los parámetros de suavizado exponencial son un factor clave a la hora de determinar la eficacia de un modelo para predecir correctamente valores futuros. Por ello, es necesario obtener los valores de acuerdo a un criterio de minimización del error. El método más ampliamente utilizado consiste en utilizar los datos observados y realizar una previsión a un instante de tiempo posterior. Utilizando un criterio de indicador del error cometido en la previsión, se puede establecer un problema de resolución no lineal en el que se deba minimizar el error.

En general, a la hora de determinar el error en el ajuste se utiliza el criterio de la raíz del error cuadrático medio (RMSE), que se define como en (4.20).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2} \quad (4.20)$$

Se establece por tanto el siguiente problema de resolución no lineal:

(PNL)

$$\begin{aligned} \min RMSE(\alpha, \gamma, \delta) \\ \text{s. a. } (\alpha, \gamma, \delta) \in \Omega \end{aligned}$$

donde Ω es la región factible de la función, establecido con límites entre 0 y 1. En este problema también debe incluirse φ_{AR} si se utiliza el modelo con ajuste del error de autocorrelación de primer orden.

Para la determinación del nivel de precisión de una previsión, se utilizan los mismos indicadores que anteriormente, aunque por norma general, el uso de la media del valor porcentual del error absoluto (MAPE) es el más extendido. Éste queda definido en (4.21).

$$MAPE = 100 \frac{1}{h} \sum \frac{|\hat{X}_t - X_t|}{|X_t|} \quad (4.21)$$

Otros métodos para determinar la precisión es el MAPE simétrico (sMAPE), definido en (4.22) y que proporciona mejores resultados de análisis (Makridakis 1993).

$$sMAPE = 200 \frac{1}{h} \sum \frac{|\hat{X}_t - X_t|}{|X_t + \hat{X}_t|} \quad (4.22)$$

4.7. Aplicación

Para comprobar la utilidad y efectividad de los modelos propuestos, se realiza una aplicación sobre los datos de demanda eléctrica en España. En concreto, se realiza con datos provistos por la Web de REE en su plataforma www.ree.es, y que abarcan un rango desde el 1 de julio de 2007 hasta el 3 de abril de 2014. El objetivo de esta aplicación es determinar el nivel de precisión de las previsiones mediante la obtención del MAPE de forma puntual, y posteriormente compararlas con un referente: la previsión de REE.

4.7.1. Selección del modelo

El proceso de selección del modelo se realiza mediante una competición entre los modelos candidatos. En la competición se utilizan los valores observados inmediatamente anteriores a las fechas de previsión y se realizan previsiones “dentro de la muestra”. El procedimiento se organiza en las siguientes fases:

- En una primera fase, se ajustan los modelos y se seleccionan los modelos cuyo RMSE en el ajuste es menor. No hay un criterio establecido de cuántos modelos se pueden seleccionar, pero por norma general se selecciona un par de ellos, teniendo en cuenta el resultado y la cantidad de parámetros a utilizar.
- Posteriormente, se utiliza una previsión “dentro de la muestra” con los modelos seleccionados y se obtiene la precisión de la previsión. El MAPE y el sMAPE han sido utilizado para este propósito.
- Finalmente se realiza una validación. Consiste en realizar previsiones “fuera de la muestra”, y que se comparan con los datos reales observados a posteriori.

En este capítulo se han designado cuatro ventanas de tiempo para el año 2013, representando cada una de ellas una temporada o estación del año. De este modo es posible atender a la variabilidad debida a la climatología diferenciada en cada estación del año. Dentro de las ventanas, son seleccionadas de modo aleatorio diferentes fechas donde realizar la previsión. Además, en cada una de las ventanas, se estudian tres alternativas diferentes, enunciadas a continuación:

- Un modelo doble estacional, en el que para el ajuste del modelo se utilizan las siete semanas inmediatamente anteriores a la fecha de previsión.
- Un modelo doble estacional con un periodo de ajuste utilizando todos los datos disponibles de la serie temporal. A diferencia del modelo anterior, se trata de observar

cómo afecta la cantidad de datos disponibles para el ajuste.

- Un modelo triple estacional, en el que se utilizan todos los datos disponibles de la serie temporal.

Adicionalmente, y a modo de referencia, estos resultados se comparan con pronósticos proporcionados por REE. El objetivo perseguido consiste en establecer un marco de comparación para comprobar el nivel de los resultados que se están consiguiendo. Los resultados se muestran en la Tabla 4.3.

Los resultados que se obtienen de la tabla muestran que la utilización de los modelos doble estacionales con todo el conjunto de datos obtiene los mejores resultados en términos de precisión, comparados con el resto. A priori parece un resultado inesperado, ya que la utilización de tres estacionalidades debería aportar una mejora en el modelo. Sin embargo, un análisis detallado a los resultados obtenidos por Taylor (2010b) permite comprender el resultado obtenido. Taylor filtra la serie eliminando sus irregularidades, y, principalmente, los días festivos. Para eliminar el efecto del adelanto y retraso horario debido al DST, utiliza años de 52 semanas o de 53, dependiendo de si es bisiesto o no. Sin embargo, la utilización en este trabajo ha sido de la serie original, sin modificar. Ello motiva que la tercera estacionalidad tenga dificultades para adaptarse con los años bisiestos, con la Pascua, los días festivos, etc.

Tabla 4.3. Comparativa del MAPE simétrico (sMAPE %) de los modelos que han resultado ser los más precisos. Los resultados se organizan según los modelos y alternativas de estudio. Se muestra únicamente un día de cada periodo estudiado.

Alternativa	Modelos	sMAPE(%)			
		14/01/2013	22/04/2013	8/07/2013	13/10/2013
DS nHWT 7 Semanas	AMC _{24,168}	0,741	0,689	0,351	0,611
	dMC _{24,168}	0,761	0,744	0,343	0,588
	MMC _{24,168}	0,830	1,265	0,982	0,850
DS	AMC _{24,168}	0,508	0,576	0,303	0,634
Todos los datos	DMC _{24,168}	0,505	0,577	0,304	0,633
	MMC _{24,168}	0,503	0,578	0,302	0,634
TS	NAC _{24,168,8760}	0,590	0,579	0,355	0,591
Todos los datos	AAC _{24,168,8760}	0,750	0,645	0,417	0,619
	DAC _{24,168,8760}	0,730	0,634	0,426	0,624
REE		0,449	0,534	0,416	0,532

Para comprender la evolución de la precisión en estas previsiones, se muestra la Figura 4.3. En ella se aprecia la evolución de los modelos utilizados en la Tabla 4.1. Los modelos prácticamente se superponen, con lo que los modelos utilizados no presentan diferencias entre ellos. La evolución de la precisión es ascendente, perdiendo eficacia con el paso de las horas. Sin embargo, en ocasiones se mantiene estable a lo largo del periodo de previsión.

El modelo utilizado por REE, sin embargo, tiene una evolución diferente. Se puede apreciar cómo REE efectivamente realiza reprevisiones horarias y por ello su precisión mejora y el MAPE va disminuyendo con el paso de las horas.

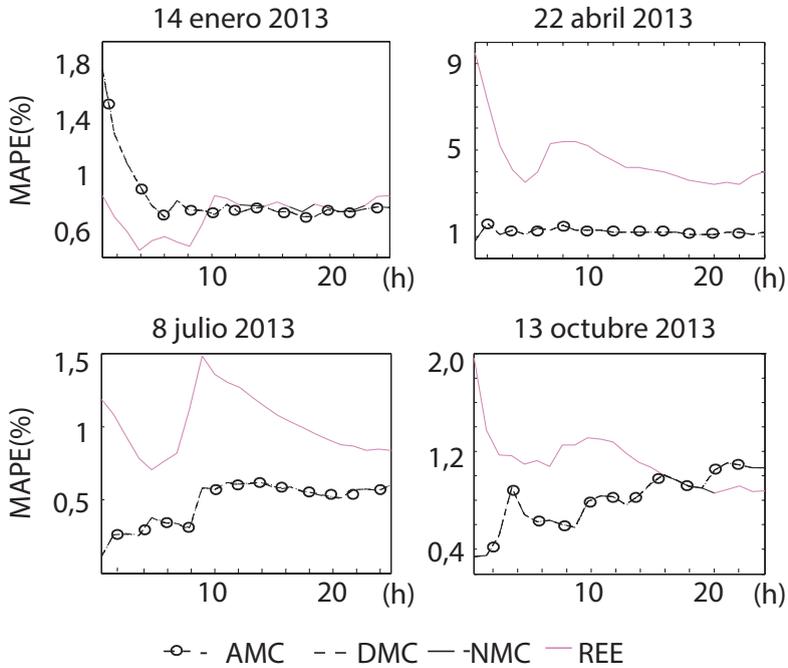


Figura 4.3. Evolución del MAPE en las previsiones “dentro de la muestra” utilizadas por los diferentes modelos doble estacionales. Los resultados prácticamente se superponen. Además, se contrasta con los resultados de las previsiones de REE.

Debido a que las diferencias entre modelos son pequeñas, se realizó un test de Diebold-Mariano para comprobar si estas diferencias resultan significativas (Diebold y Mariano 1995; 2002). Este test permite comparar los residuos de las previsiones y establecer si existen diferencias significativas entre los modelos. Uno de los testes realizado es “ H_0 : La precisión del modelo $AMC_{24,168}$ es igual a la del modelo $DMC_{24,168}$ ” vs “ H_1 : La precisión del modelo $AMC_{24,168}$ es diferente a la del modelo $DMC_{24,168}$ ”. Este mismo test se aplicó con el restante modelo. Sin embargo, el resultado obtenido determinó que no existen diferencias significativas entre los modelos. De este modo, se seleccionó el modelo $AMC_{24,168}$ ya que el modelo $DMC_{24,168}$

utiliza más parámetros, y el modelo $MMC_{24,168}$ resultó tener mayor esfuerzo computacional.

4.8. Validación

Para terminar el análisis con estos modelos, se realizó el proceso de validación. Este proceso consistió en realizar previsiones “fuera de la muestra” y compararlas con los valores obtenidos a posteriori. Las fechas utilizadas fueron tomadas durante la semana del 3 de abril de 2014 al 9 de abril. Estas fechas fueron las últimas disponibles en el momento de realizar el análisis. Las previsiones se realizaron a 24 horas vista, desde las 01:00 horas del día hasta las 24:00, utilizando el modelo $AMC_{24,168}$ y comparándolas con las previsiones de REE.

Los resultados del MAPE obtenido en las previsiones se muestran en la Figura 4.4. El hecho de utilizar el MAPE permite observar la evolución de la precisión de las previsiones realizadas por los modelos en relación con el tiempo.

Hay que tener en cuenta que los datos de previsión de REE publicados en la web funcionan del modo siguiente: se realizan previsiones cada 10 minutos y se actualizan cada hora. El máximo periodo de previsión mostrado son 12 horas.

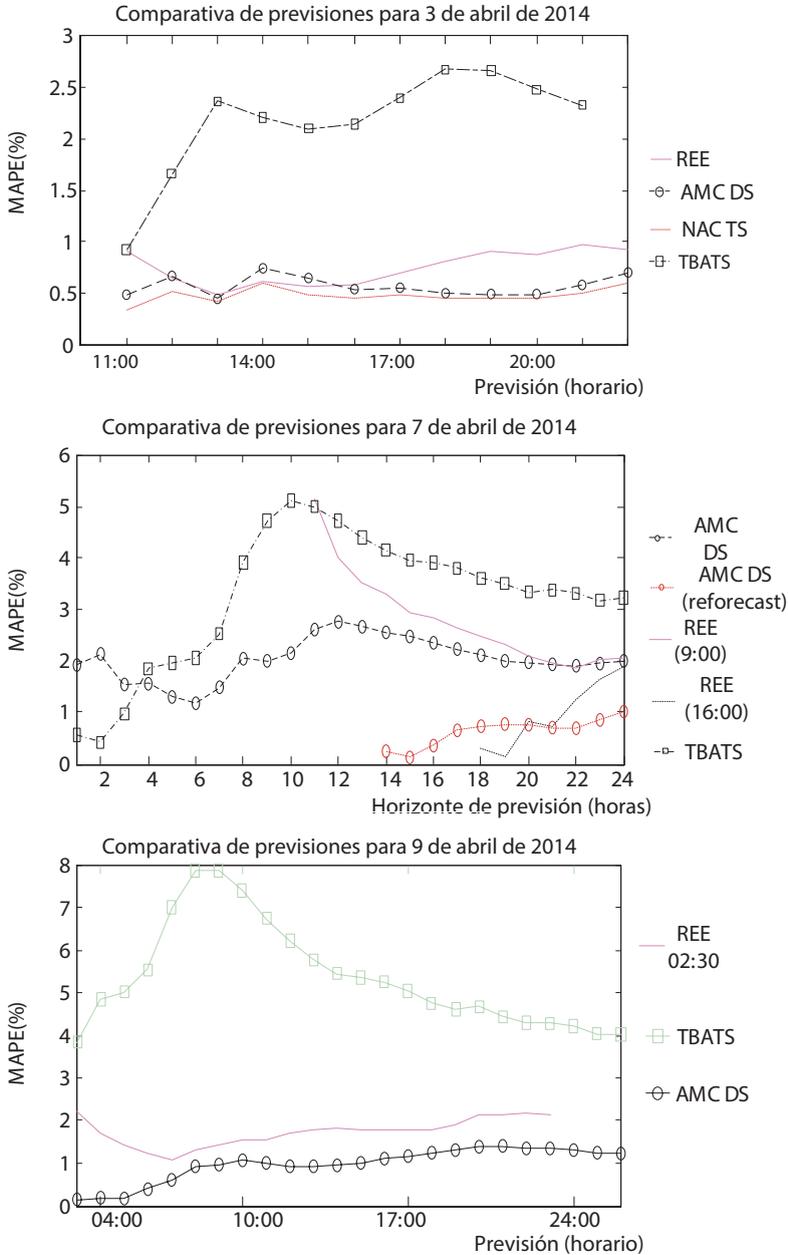


Figura 4.4. Comparación de las previsiones realizadas por el modelo $AMC_{24,168}$ y por los datos de previsión de REE. Las fechas de la previsión se indican en la gráfica.

En la gráfica superior se muestra la previsión realizada con el modelo $AMC_{24,168}$ el 3 de abril de 2014 a las 10:00 comparada con las proporcionadas con REE. Hay que tener en cuenta que la previsión de REE llega hasta las 22:50 y por eso no es posible realizar una comparativa a más largo plazo. Se observa como los resultados de las previsiones manejan valores de MAPE entre el 0,4% y el 0,9%. En este caso, las previsiones realizadas por el modelo propio se mantienen estables, mientras que las proporcionadas por REE tienden a crecer hasta el 1%.

En la gráfica central se muestra la previsión para el 7 de abril. La previsión realizada desde las 00:00 horas con el modelo $AMC_{24,168}$ muestra una precisión excelente mejorando incluso la proporcionada por REE a las 10:00. Esta previsión se mantiene sobre el 2% y a las 13:00 horas se realiza una reprevisión con el modelo. El resultado mejora siendo la previsión del orden del 1%. A las 17:00 horas se utiliza una nueva previsión dada por REE, y se observa como en principio la previsión es mejor, pero a las pocas horas esta previsión tiene de nuevo a un 2% de MAPE, mientras que la proporcionada por $AMC_{24,168}$ se mantiene en el orden del 1%.

Por último, en la gráfica inferior se muestra una comparativa para el 9 de abril. En esta gráfica se puede comprobar como en un día normal (el 9 de abril del 2014 es miércoles), la previsión realizada por el modelo $AMC_{24,168}$ supera en todo momento la previsión realizada por REE. Aunque el objetivo principal no es mejorar las previsiones del modelo de REE, se puede concluir que los modelos utilizados han sido precisos y han conseguido incluso mejorarlo, siendo el modelo de REE más complejo.

4.9. Discusión de los resultados

En este capítulo se presentan los modelos de Holt-Winters múltiple-estacionales, modelos sencillos que incluyen varias estacionalidades anidadas. Estos modelos permiten de forma

parsimonial proveer resultados de las previsiones muy precisos, estando dentro del orden – y mejorando en ocasiones – los pronósticos ofrecidos por REE. Los modelos propuestos tienen una precisión de inferior al 2% de precisión en MAPE.

Otra conclusión adicional extraída del análisis empírico realizado es que los modelos de doble estacionalidad obtienen mejores resultados en la previsión que los de triple estacionalidad. Esto se debe a que los modelos de triple estacionalidad deben trabajar con series filtradas para evitar los efectos de tipo calendario, como los días festivos, la Pascua, Navidades, etc.

5. Métodos de inicialización en los modelos de Holt-Winters múltiple-estacionales

5

5.1. Introducción

La introducción de los modelos de Holt-Winters múltiple-estacionales requiere la definición y adaptación de los métodos habituales de estimación de valores iniciales -semillas- a la múltiple estacionalidad. Este capítulo aborda esta área temática mostrando los métodos de obtención de las semillas y realiza un análisis comparativo entre ellos, con el objeto de discernir si existen diferencias entre ellos en la previsión.

En una primera sección se justifica la motivación para el estudio realizado: la necesidad de analizar los métodos de obtención de valores iniciales para los modelos múltiple-estacionales.

Seguidamente, se analiza la bibliografía existente al respecto, y se describen los métodos expuestos.

Posteriormente se realiza un análisis de los métodos expuestos, con el fin de determinar la existencia o no de diferencias entre ellos.

Finalmente, se describen las conclusiones alcanzadas en el capítulo.

5.2. Justificación

Los modelos de Holt-Winters están formados por ecuaciones recurrentes que necesitan de una estimación de los valores iniciales o semillas. Originalmente, los modelos de suavizado exponencial simple permitían el cálculo de las semillas a partir de los propios modelos. La introducción de los modelos de suavizado exponencial doble (C. C. Holt 1957; C. C. Holt 2004; Brown 1959) y triple suavizado exponencial (Winters 1960) - cabe recordar no confundir el doble y triple suavizado con el suavizado doble y triple estacional-, requirió la obtención de semillas de forma externa al modelo. Ha habido varias propuestas para establecer esos valores iniciales, aunque nunca se ha comprobado la supremacía de ninguno de estos métodos sobre los demás. Tampoco existe en la bibliografía académica un gran número de trabajos que aborden el tema.

La introducción de los modelos múltiple-estacionales necesita de una revisión de los métodos tradicionales para estimar dichos valores iniciales. La introducción de más de una estacionalidad de modo anidado afecta no sólo a cómo se obtiene los índices estacionales iniciales, sino, además, también cómo se obtienen el resto de valores.

5.3. Revisión bibliográfica

Los primeros métodos para la obtención de las semillas fueron propuestos por los desarrolladores de los métodos (C. C. Holt 1957; Winters 1960). En la sección 5.4 se describen estos métodos.

Granger y Newbold (1986) propusieron dejar el valor inicial de la tendencia a 0 en métodos aditivos, y, por tanto, 1 para los multiplicativos. Esto fuerza al modelo a calcular el valor del parámetro de tendencia de modo que ajuste desde una pendiente nula, hasta alcanzar la pendiente finalmente obtenida.

Posteriormente, Makridakis e Hibon (1991) analizaron los métodos de inicialización, concluyendo que al optimizar los valores de los parámetros, estos se compensan y no existen grandes diferencias entre los métodos propuestos. No obstante, la aparición de nuevas metodologías para el establecimiento de valores iniciales no cesó. Makridakis, Wheelright y Hyndman (1998) propusieron un nuevo método para la tendencia y la estacionalidad (método Makridakis).

Segura y Vercher (2001) recopilan algunos de los modelos más ampliamente utilizados hasta el 2001. Realizan un análisis comparativo de los resultados obtenidos, y concluyen que sí existen diferencias entre los métodos de inicialización, que influyen enormemente en los valores de los parámetros, pero que no existe un criterio único que permita determinar los valores adecuados.

Posteriormente ha habido nuevos métodos propuestos, como la realización de un modelo de regresión de donde obtener los valores de la tendencia y el nivel, como parte de la pendiente y el intercepto (Bowerman, O'Connell, y Koehler 2005). Este método no es recomendable porque sesga los valores de la pendiente frente a la estacionalidad (Hyndman 2010). Otros trabajos calculan directamente los valores iniciales a la vez que los parámetros, mediante algoritmos de minimización (Rasmussen 2004).

Algunos trabajos recopilan los métodos de inicialización, pero no evalúan qué método destaca (Kalekar 2004; Montgomery, Jennings, y Kulahci 2008), únicamente trabajos esporádicos (Suppalakpanya et al. 2019). Algunos, directamente

no tratan el tema, a pesar de ser parte de su título (Booranawong y Booranawong 2018).

Con la aparición de los modelos doble estacionales (Taylor 2003a) se abre un nuevo camino para determinar nuevos métodos de estimación. Posteriores usos de la misma aplican los métodos tradicionales independientemente de que las estacionalidades estén anidadas (Souza, Barros, y Miranda 2007).

Por otro lado, Hyndman et al. (2008) y Hyndman y Khandakar (2008) presentaron métodos doble estacionales basados en la experiencia de los espacios de estado. Estos son utilizados en la librería *'forecast'* del software estadístico *R*.

García-Díaz y Trull (2016) presentaron una generalización de los modelos para múltiples estacionalidades, y adaptan métodos tradicionales de obtención de valores iniciales para la múltiple estacionalidad.

5.4. Modelos múltiple-estacionales y los métodos de inicialización

Para el estudio de los métodos de inicialización, es necesario distinguir entre dos vertientes: la primera se basa en estimar cada semilla por separado y de forma independiente; la segunda, denominada aquí método mixto, supone que, para el cálculo de una semilla, es necesario haber calculado otra con anterioridad. Se desarrolla primeramente los métodos simples y luego los mixtos.

5.4.1. Métodos para el nivel

El nivel representa el suavizado general de la serie. Por ello suele ser el primer valor en ser estimado. Winters (1960) propuso la utilización de la media del primer periodo, en contra de lo que se había propuesto con anterioridad para el suavizado simple y doble por Holt, el uso de la media móvil centrada entre los dos primeros

periodos (C. C. Holt 1957). Williams y Miller (1999) utilizaron el primer valor de la serie. Granger y Newbold (1986) realizaron un modelo de regresión para los valores de la serie, y utilizaron el valor del intercepto para el nivel, método adoptado posteriormente por (Bowerman, Koehler, y Pack 1990). Este último método se descarta porque esta metodología sesga el valor de la pendiente. No hay más métodos encontrados en la bibliografía para el cálculo del nivel.

La adaptación de estos métodos consiste básicamente en determinar el alcance del periodo considerado para realizar el cálculo. Los trabajos realizados hasta la fecha consideran como el mejor método la utilización del periodo estacional considerado de mayor longitud. En el caso de la serie de demanda eléctrica, si consideramos una estacionalidad diaria y otra semanal, utilizaríamos la estacionalidad semanal. En la Tabla 5.1 se muestran los métodos adaptados y trabajados en el documento. Aquí, S_0 indica el valor inicial obtenido, siendo s_m la longitud del periodo estacional más largo de los considerados. Los valores de X_t representan los valores observados.

Tabla 5.1. Métodos propuestos para la obtención del valor inicial el nivel.

Denominación	Cálculo
Media móvil (Holt, 1957)	$S_0 = \frac{1}{s_m} \left[\frac{X_{1+s_m} - X_1}{s_m} + \frac{X_{2+s_m} - X_2}{s_m} + \dots + \frac{X_{2s_m} - X_{s_m}}{s_m} \right]$
Primer Valor (Williams & Miller, 1993)	$S_0 = X_1$
Media del primer periodo (Winters, 1960)	$S_0 = \frac{\sum_1^{s_m} X_i}{s_m}$

5.4.2. Métodos para la tendencia

La tendencia representa la evolución a largo plazo de la serie temporal. Winters (1960) proporciona la primera propuesta

donde se calcula el valor inicial de la tendencia (T_0) como la pendiente entre el promedio del último periodo completo disponible q , y el primero, como indica la ecuación (5.1). s indica la longitud del periodo estacional considerado (para una única estacionalidad).

$$T_0 = \frac{\bar{D}_q - \bar{D}_1}{(q - 1)s} \quad (5.1)$$

donde \bar{D}_i es el valor medio del periodo i . Sin embargo, en muchas de las ocasiones, con utilizar el primer y el segundo periodo para el cálculo de la tendencia es más que suficiente (Makridakis, Wheelwright, y Hyndman 1998), y se puede tomar $q=2$.

Granger y Newbold (1986) propusieron utilizar como valor de tendencia 0, y que la serie lo ajuste a medida que obtiene valores nuevos. Este valor se indica para los modelos cuya tendencia sea aditiva. Para los modelos con tendencia multiplicativa este valor es necesario que se la unidad. Taylor (2003b) propone para los métodos doble estacionales una adaptación de la metodología propuesta en (Williams y Miller 1999).

Todos los métodos anteriormente descritos se han adaptado para los modelos múltiple-estacionales, a excepción del método expuesto por Taylor. Se propone el método Overall (y la versión reducida a 2 periodos), recopilado en la Tabla 5.2.

Tabla 5.2. Métodos propuestos para la estimación del valor inicial de la tendencia en métodos múltiple-estacionales, adaptando los métodos actuales.

Nombre	Cálculo
Newbold (Granger y Newbold ,1986)	$T_0 = 0$ (modelo aditivo) $T_0 = 1$ (modelo multiplicativo)
Taylor (Taylor, 2003)	$T_0 = \frac{\left(\frac{\bar{D}_1 - \bar{D}_2}{s_m} + \frac{\sum_1^{2s_m} \nabla D_{12}}{2s_p} \right)}{2}$
Overall, 2 periodos (García-Díaz y Trull, 2016)	$T_0 = \frac{\sum_{i=1, \dots, q} T'_{oi}}{q}$ Siendo $T'_{oi} =$ $\begin{cases} \frac{\bar{D}_2 - \bar{D}_1}{2} & \text{para } s_i = s_m \\ \frac{\sum_1^{s_i} \nabla D_i}{s_i} & \text{resto} \end{cases}$

En esta ocasión, los T'_{oi} son un paso intermedio donde se calculan las contribuciones individuales en cada periodo (s_i) para luego calcular el promedio de todos ellos, contabilizando el número máximo de periodos q (o 2, para el caso de 2 periodos). La estacionalidad de mayor longitud se utiliza como base de cálculo. El valor de s_m indica la longitud del periodo estacional más largo considerado en el modelo. El resto, se calcula en forma de diferencias. El valor s_p indica la longitud del menor de los periodos considerados. ∇D_{12} indica diferencias de los valores para los dos primeros periodos, mientras que ∇D_i se refiere a las diferencias del periodo considerado. Finalmente se calcula el promedio de las contribuciones para obtener el valor de T_0 .

5.4.3. Métodos mixtos

La obtención de la tendencia y el nivel generalmente va muy ligada. Algunos autores proponen la obtención del nivel una vez eliminada la tendencia (Larrañeta Onieva, Gimenez, y Lozano, S.

1995). En estos casos, se calcula primero la tendencia y luego el nivel. En este caso, hemos considerado la proposición de Taylor (2003b) y el cálculo del nivel, una vez obtenida la tendencia, se calcula como (5.2). Es un modo mixto, en el cual se elimina la tendencia antes de obtener los valores del nivel.

$$S_0 = \bar{D}_1 - \frac{s_m + 1}{2} T_0 \quad (5.2)$$

Hyndman et al. (2008) utilizan un modelo mixto dedicado a los estados de espacio, pero que también se utiliza en los modelos de Holt-Winters. Se toman los 10 primeros periodos estacionales y se desestacionaliza, obteniendo una recta que sirve para determinar los valores iniciales. De esta recta, la constante es el valor del nivel, mientras que la pendiente es el valor de la tendencia.

5.4.4. Métodos para la estacionalidad

Las propuestas para la obtención de los valores iniciales de la estacionalidad son muy variadas y extensas, desde la primera propuesta realizada en (Winters 1960). Son de especial relevancia dada la fuerte influencia de la estacionalidad en la serie. La adaptación a la múltiple estacionalidad se describe en (5.3) a (5.7) para cada estacionalidad.

$$\bar{D}_j^{(s_i)} = \frac{1}{q_i} \sum_{k=1}^{q_i} X_t, \quad (5.3)$$

$$j = 1, \dots, s_i \quad t = j, j + s_i, \dots, j + (q_i - 1)s_i$$

Donde q_i es el número máximo de ciclos completos de longitud s_i que existen en la serie. I se refiere a la estacionalidad considerada, de modo que $i = 1, \dots, n_s$. El cálculo de los índices estaciones se describe a continuación:

$$I'_{t,j}^{(s_i)} = \frac{X_t}{\bar{D}_j^{(s_i)} - \left(\frac{s_i + 1}{2} - i\right) T_0}, \quad (5.4)$$

$$j = 1, \dots, s_i, t = j, j + s_i, \dots, (q_i - 1)s_i$$

$$I'_{t-s_i}^{(s_i)} = \frac{1}{s_i} \sum I'_{t,j}^{(s_i)} \quad j = 1, \dots, q_i \quad (5.5)$$

$$I^*_{t-s_i}^{(s_i)} = \frac{1}{q_i} \sum I'_{t-s_i}^{(s_i)} \quad t = 1, \dots, s_i \quad (5.6)$$

$$I_{t-s_i}^{(s_i)} = \begin{cases} I^*_{t-s_1}^{(s_1)}, & i = 1 \\ \frac{I^*_{t-s_i}^{(s_i)}}{\prod_{j=1}^{i-1} I^*_{t-s_j}^{(s_j)}}, & i > 1 \end{cases} \quad (5.7)$$

De forma similar Brockwell y Davis (1991) propusieron una nueva metodología adoptada por el National Institute of Standards and Technology (NIST/SEMATECH 2012). Adaptado a la múltiple estacionalidad, se muestran los pasos para obtener los valores iniciales descritos en (5.8).

Paso 1.

Para cada estacionalidad, es necesario reorganizar los datos, y obtener las medias en cada posición interna dentro de la estacionalidad como la media de los valores obtenidos. De este modo se obtiene los valores $A_m^{s_i}$, para cada estacionalidad de longitud s_i y que ocurre n_q veces en la serie de datos.

$$A_m^{s_i} = \frac{\sum_{j=1}^{s_i} X_{(m-1)*s_i+j}}{s_i}, m = 1, \dots, n_q$$

Paso 2.

Para cada estacionalidad, se obtiene la proporción de la serie sobre la media obtenida. Existen m_i apariciones de los ciclos estacionales en el rango considerado de longitud s_i .

	1	2	...	q
1	$X_1/A_1^{s_i}$	$X_{s_i+1}/A_2^{s_i}$		$X_{(m_i-1)s_i+1}/A_{m_i}^{s_i}$
...				
s_i	$X_{s_i}/A_1^{s_i}$	$X_{2s_i}/A_2^{s_i}$		$X_{m_i s_i}/A_{m_i}^{s_i}$

Paso 3:

Se obtienen los índices estacionales provisionales de cada estacionalidad sobre la serie.

$$I_{1-s_i}^{*s_i} = \frac{\frac{X_1}{A_1^{s_i}} + \frac{X_{s_i+1}}{A_2^{s_i}} + \dots + \frac{X_{(m_i-1)s_i+1}}{A_{m_i}^{s_i}}}{m_i}$$

$$I_0^{*s_i} = \frac{\frac{X_{s_i}}{A_1^{s_i}} + \frac{X_{2s_i}}{A_2^{s_i}} + \dots + \frac{X_{m_i s_i}}{A_{m_i}^{s_i}}}{m_i}$$

Paso 4:

Se obtienen los índices estacionales definitivos teniendo en cuenta que están anidados, y que el primer periodo equivaldría a un modelo simple estacional.

$$I_{t-s_i}^{s_i} = \begin{cases} I_{t-s_1}^{*s_1}, & i = 1, t = 1, \dots, s_i \\ \frac{I_{t-s_i}^{*(s_i)}}{\prod_{j=1}^{i-1} I_{t-s_j}^{*(s_j)}}, & i > 1, t = 1, \dots, s_i \end{cases} \quad (5.8)$$

Como variaciones de los anteriores, está el método simplificado de (Granger y Newbold 1977) donde se divide los valores del primer ciclo estacional por la media del mismo. Esto, adaptado a los modelos múltiple-estacionales se observa en (5.9) y (5.10).

$$I_{t-s_i}^{*(s_i)} = \frac{D_t}{\bar{D}_{s_i}}, t = 1, \dots, s_i \quad (5.9)$$

$$I_{t-s_i}^{s_i} = \begin{cases} I_{t-s_1}^{*s_1}, & i = 1 \\ \frac{I_{t-s_i}^{*(s_i)}}{\prod_{j=1}^{i-1} I_{t-s_j}^{*(s_j)}}, & i > 1 \end{cases} \quad (5.10)$$

Adicionalmente se ha utilizado el método descrito en (García-Díaz y Trull 2016) para las comparaciones, que se ha nombrado como método simple.

5.5. Análisis de los métodos propuestos

Los nuevos métodos de inicialización requieren de un estudio para determinar su utilidad. El siguiente análisis utiliza la demanda eléctrica en España para comparar el rendimiento de los métodos de inicialización.

5.5.1. Marco de trabajo

Para la realización del análisis se ha utilizado la serie de demanda eléctrica horaria en España en el periodo entre 1999 y 2004. Este periodo se caracteriza por un fuerte incremento en la demanda, de modo que se refleja en una tendencia aguda. Además, la estacionalidad no es completamente estable, lo que permite comprobar cómo evolucionará el valor estimado a lo largo de la serie. La Figura 5.1 muestra la evolución de la serie temporal.

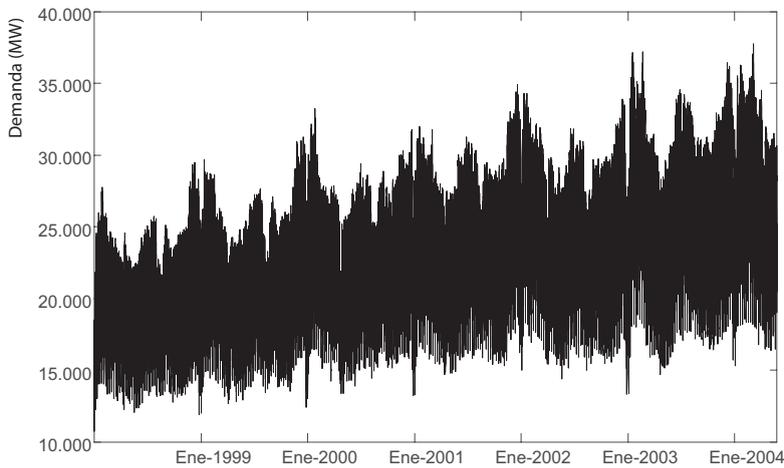


Figura 5.1. Demanda eléctrica horaria en España entre los años 1999 y 2004.

El análisis se ha planteado en forma de diseño de experimentos en el que los principales factores a analizar son los diferentes métodos para estimar los valores iniciales del nivel, la tendencia y estacionalidad. Se ha centrado el trabajo en utilizar dos estacionalidades con valores reales. Es importante destacar que, al realizar este análisis, la influencia de las variables meteorológicas se ha considerado como un factor de ruido, de modo que se han creado ventanas en las 4 estaciones del año donde se han realizado el análisis. Dentro del mismo contexto, se ha incluido varias réplicas del análisis, utilizando los diferentes años.

Las variables respuesta utilizadas han sido el RMSE y el MAPE, dos indicadores de precisión de los pronósticos ampliamente utilizados en el análisis de series temporales. Para obtener la variable respuesta, se han utilizado series de 7 semanas extraídas de forma aleatoria de la serie, aunque siempre teniendo en cuenta que pertenezcan a una estación del año en concreto – disponiendo al menos de 6 series en cada periodo estacional y cada año -. A partir de esas series, se han ajustado los modelos y se han obtenido el MAPE y RMSE.

El proceso de comparación de los valores iniciales necesita de una metodología específica, ya que una vez se realiza la optimización de parámetros, se pierden las diferencias que existen entre ellos (Makridakis y Hibon 1991; Makridakis, Wheelwright, y Hyndman 1998). Esta situación puede evitarse realizando el análisis en base a las previsiones directamente desde los valores iniciales y sin ajustar. Es necesario que el modelo además no amortigüe los resultados, lo cual implica que los parámetros utilizados deben ser $\alpha = 0$, $\gamma = 0$ y $\delta^{(i)} = 0$ para todas las estacionalidades. Este es el proceso aplicado en el análisis.

En un segundo paso, los modelos se han ajustado minimizando el RMSE y se han comparado los resultados obtenidos. En la Tabla 5.3 se muestran todos los factores y niveles analizados. Los nombres utilizados concuerdan con los métodos descritos en las secciones anteriores. Además, se han realizado en 4 años diferentes lo que supone un factor adicional a tener en cuenta.

Los modelos estudiados han sido $AMC_{24,168}$, $AAC_{24,168}$, $MAC_{24,168}$ y $MMC_{24,168}$.

Por lo tanto, nos encontramos ante un diseño multinivel con 3 factores controlables, y un factor de ruido que es el periodo del año replicado durante 4 años diferentes. El diseño de experimentos incluye 4096 pruebas.

Tabla 5.3. Resumen de los factores y niveles analizados.

Factor	Tipo	Niveles
Nivel	Controlable	Media móvil, media, primer valor, Taylor
Tendencia	Controlable	Newbold, Taylor, Overall, 2 periodos
Estacionalidad	Controlable	Normal, Winters, NIST, simple
Periodo Anual	Ruido	Invierno, primavera, verano, otoño
Año	Réplica	1999-2003

5.5.2. Resultados

Como análisis inicial se utilizarán los valores de los modelos sin ajustar, con los parámetros de inicialización directamente obtenidos. Los datos mostrados se basan con la utilización del MAPE del ajuste. La utilización del RMSE proporciona resultados similares, aunque el MAPE obtiene mayor discriminación entre los factores.

Un primer análisis sobre los resultados obtenidos descubre que existen dos grupos claramente diferenciados debido a la metodología utilizada en la tendencia. Esto se puede observar en la Figura 5.2, donde claramente se aprecian dos grupos diferenciados por el método de tendencia.

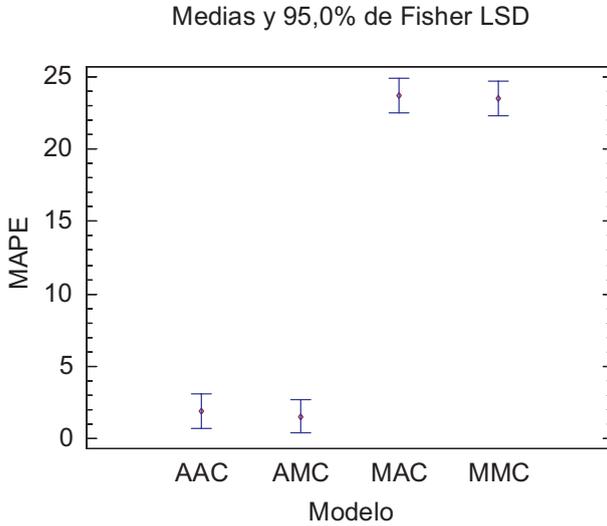


Figura 5.2. Gráfico de medias LSD correspondiente al ensayo realizado. Se muestra el MAPE (%) con los parámetros sin optimizar.

Ello propicia que el análisis se divida en dos diferentes, uno para aquellos modelos con tendencia multiplicativa (TM, desde ahora) y otro aditiva (TA), a pesar de que claramente los resultados con la TA superan a los de TM. Por ello, en lo sucesivo, el análisis se realizará por separado.

En la Tabla 5.4 se muestra el ANOVA realizado para los modelos con TM y en la Tabla 5.5 el ANOVA para los modelos con TA.

Tabla 5.4. Análisis de la varianza para los factores estudiados utilizando los modelos con tendencia multiplicativa, sin realizar ajuste.

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>Gl</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
EFFECTOS PRINCIPALES					
A:Nivel	283,894	3	94,6312	6,66	0,0002
B:Tendencia	2,95237E6	3	984124,	69240,76	0,0000
C:Estacionalidad	1099,63	3	366,542	25,79	0,0000
D:Modelo	19,359	1	19,359	1,36	0,2432
E:Periodo anual	91,2913	3	30,4304	2,14	0,0931
INTERACCIONES (significativas)					
AB	876,458	9	97,3843	6,85	0,0000
BC	300,322	9	33,3691	2,35	0,0124
BE	296,071	9	32,8968	2,31	0,0138
CD	189,571	3	63,1903	4,45	0,0040
RESIDUOS	28483,0	2004	14,2131		
TOTAL (CORREGIDO)	2,98401E6	2047			

Tabla 5.5. Análisis de la varianza para los factores estudiados utilizando los modelos con tendencia aditiva, sin ajuste.

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>Gl</i>	<i>Cuadrado Medio</i>	<i>Razón-F</i>	<i>Valor-P</i>
EFFECTOS PRINCIPALES					
A:Nivel	0,848548	3	0,282849	5,59	0,0008
B:Tendencia	1,32281	3	0,440938	8,71	0,0000
C:Estacionalidad	1864,54	3	621,514	12276,07	0,0000
D:Modelo	73,2721	1	73,2721	1447,26	0,0000
E:Periodo anual	1,19018	3	0,396725	7,84	0,0000
INTERACCIONES (significativas)					
AE	1,19074	9	0,132305	2,61	0,0053
BD	1,1674	3	0,389135	7,59	0,0000
CD	299,458	3	99,8192	1971,62	0,0000
RESIDUOS	102,218	1968	0,0506281		
TOTAL (CORREGIDO)	2345,21	2047			

Los resultados obtenidos en ambos análisis muestran similitudes, destacando que los métodos de inicialización presentan diferencias significativas entre ellos. El hecho de que

en los modelos TM se muestran más robustos frente a los TA en cuanto a la utilización del modelo y con independencia del periodo del año en el que se realice el análisis, permite establecer que los modelos con TA interpretan mejor la tendencia desde los valores iniciales. Complementando este análisis con los tiempos requeridos para la optimización de los parámetros, tal y como se muestra en la Figura 5.3, donde los tiempos de optimización para los modelos TM superan los TA, se puede establecer que los modelos cuyos valores iniciales mejor responden a los datos de las series son aquellos con tendencia aditiva.

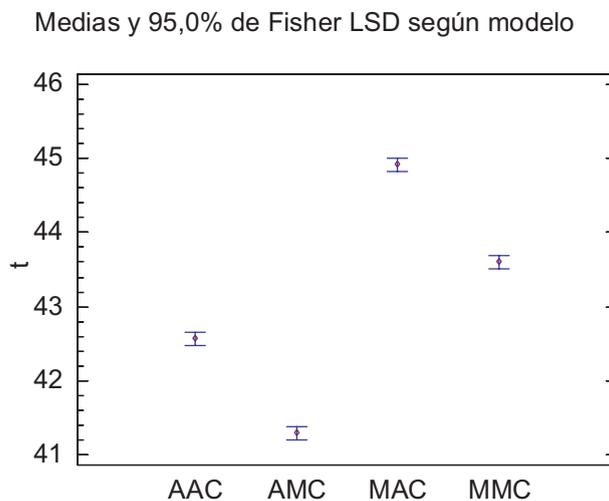


Figura 5.3. Gráfico de medias para el tiempo en segundos de optimización según modelo.

Siguiendo con el mismo análisis, hay que tener en cuenta que los modelos TA son más sensibles al periodo de previsión, de modo que, en los meses de otoño e invierno, el MAPE empeora respecto de los meses cálidos.

Si se profundiza en los resultados obtenidos, la Figura 5.4 muestra los gráficos de medias para los distintos factores analizados.

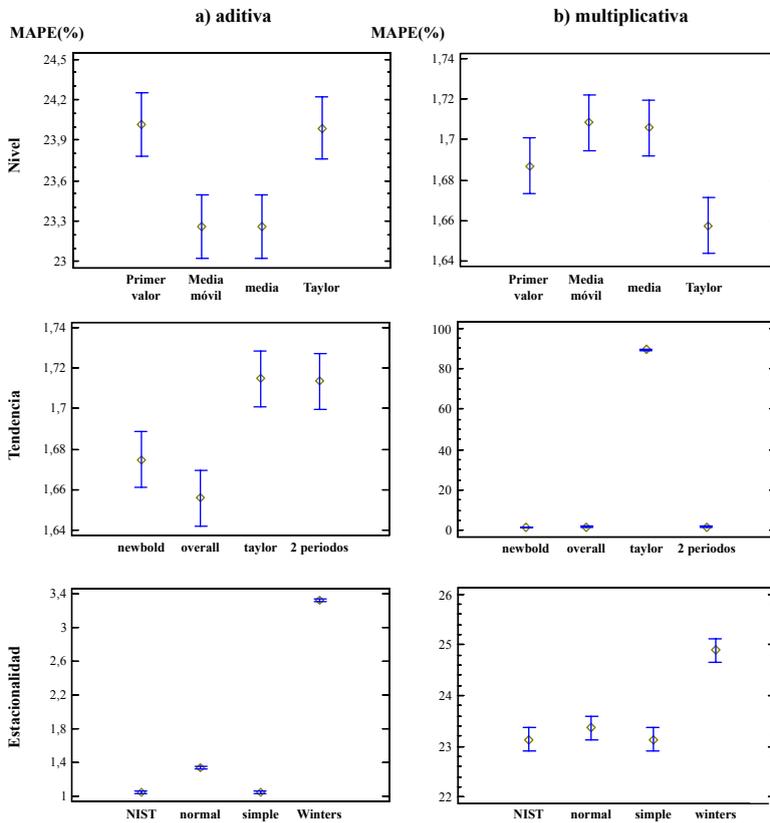


Figura 5.4. Gráficos de medias para el MAPE según los métodos de inicialización analizados. De arriba abajo: nivel, tendencia y estacionalidad. Los niveles utilizados son los descritos en la Tabla 3 del capítulo.

De ellos puede concluirse cómo la utilización de la propuesta de Taylor resulta ser la que mejor resultado obtiene para el nivel. Respecto de la tendencia, no existen grandes diferencias en los TA, aunque para el caso TM se observa que el método Taylor no proporciona buenos resultados, lo cual contrasta con el nivel. Es sorprendente ver cómo el método Newbold no resulta diferente de los demás a pesar de su sencillez.

Analizando los métodos estacionales, no existen grandes diferencias entre ellos, destacando únicamente que los métodos

propuestos por Winters no son los más acertados para el caso TA. Los resultados muestran que inicialmente los métodos aplicados en los métodos de tendencia aditiva son más precisos que los utilizados en los métodos de tendencia multiplicativa. Esta característica se pierde cuando se optimizan los parámetros.

Posteriormente, se lleva a cabo un análisis sobre los valores iniciales en sí mismos.

Análisis de la tendencia

Primeramente, se analiza la semilla para la tendencia, ya que parece ser el elemento más determinante en la elección de los parámetros iniciales. Cabe recordar que la tendencia determina el comportamiento de la serie a largo plazo. Los modelos de TM presentan valores alrededor de 1 en cualquiera de los métodos de inicialización elegidos, y no es fácil distinguir ningún resultado entre ellos. Únicamente el método de Taylor difiere, con gran variabilidad y no resulta interesante. El análisis sobre los TA proporciona más información. Se observa cómo el valor con menor variabilidad es el obtenido mediante el método overall (ver Figura 5.5). Aquí se excluye el método de Newbold, puesto que este método asigna un valor único a la semilla de la tendencia. Una vez más el método propuesto por Taylor resulta ser el de mayor variabilidad. El método 2-periodos también tiene gran variabilidad. Claramente, la variabilidad está relacionada con la longitud del conjunto de datos utilizado para obtener los valores.

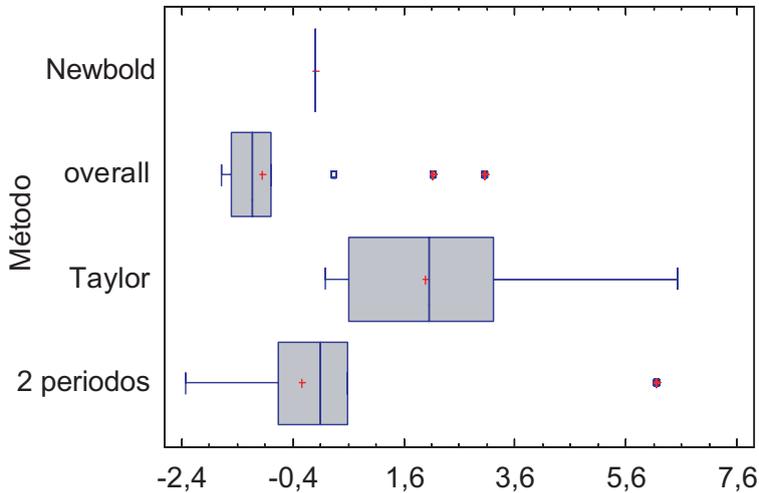


Figura 5.5. Distribución del valor inicial de tendencia (T_0) para los modelos con tendencia aditiva $AMC_{24,168}$ y $AAC_{24,168}$ en función de los métodos utilizados para su obtención, descritos en la Tabla 5.3. Los valores que se muestran son el valor de T_0 .

Análisis del nivel

Del mismo modo, el análisis sobre el valor inicial para el nivel se puede observar en la Figura 5.6. No se aprecian grandes diferencias entre los métodos, aunque posiblemente el método de Taylor tiene menor variabilidad. Esto se debe sin duda a la eliminación de la tendencia antes de obtener los valores. El resultado es análogo independientemente de la tendencia.

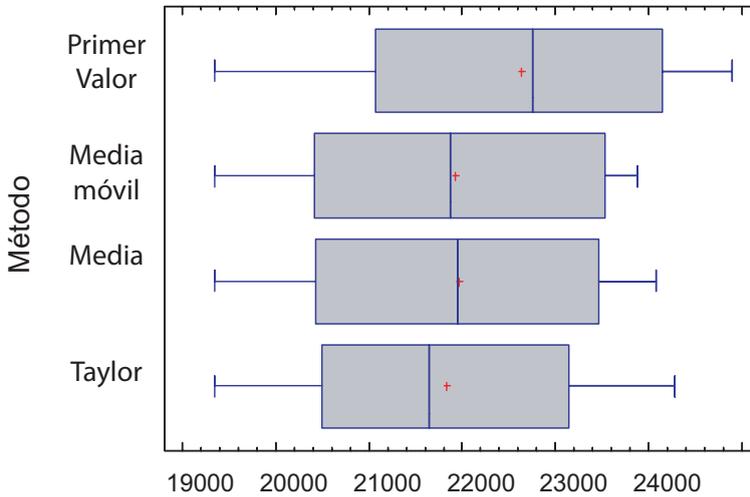


Figura 5.6. Distribución del valor inicial de nivel S_0 para el modelo $AMC_{24,168}$ y $AAC_{24,168}$ en función del método utilizado. Los valores mostrados son los valores de S_0 .

Estudio de las estacionalidades

De forma análoga se puede realizar el análisis sobre las estacionalidades. En este caso hay que distinguir entre las dos estacionalidades utilizadas en el análisis (24 y 168 horas). Las conclusiones que se van a mostrar se centran en los modelos AMC, aunque son extrapolables a los otros modelos y métodos. Inicialmente, la Figura 5.7 muestra la distribución de los valores iniciales de los índices estacionales para 24 y 168 horas. Se observa cómo la distribución de la estacionalidad diaria tiene una variabilidad muy reducida, soportando la estacionalidad semanal la variabilidad propia de la serie. Cabe recordar que la selección de las ventanas de trabajo para el análisis es aleatoria, y que, por tanto, la distribución de dicho valor debe ser acorde a la de la primera estacionalidad.

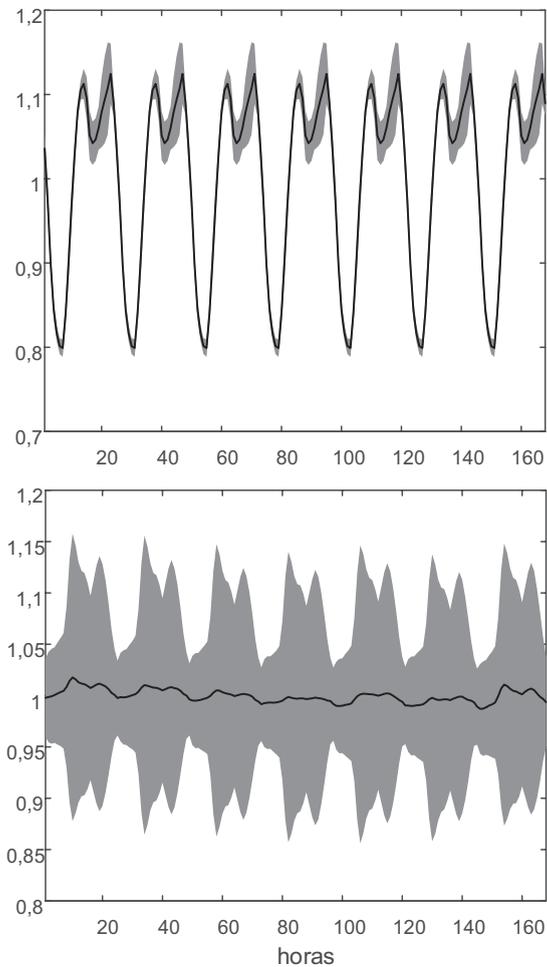


Figura 5.7. Distribución de los índices estacionales iniciales para el modelo $AMC_{24,168}$ utilizando el método simple. En la parte superior la estacionalidad de 24 horas, y en la inferior la de 168. La línea central representa la media de los valores, independientemente de la época del año, mientras que la zona sombreada representa la variabilidad con \pm una desviación estándar.

No obstante, la Figura 5.8 muestra el mismo análisis utilizando la metodología de Winters, que resulta ser significativamente diferente,

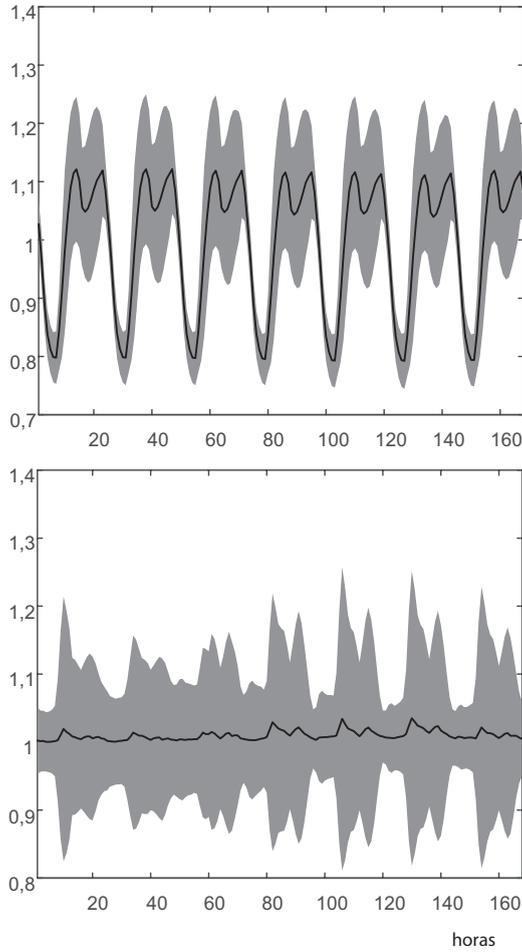


Figura 5.8. Distribución de los índices estacionales iniciales para el modelo $AMC_{24,168}$ utilizando el método Winters. En la parte superior la estacionalidad de 24 horas, y en la inferior la de 168. La línea central representa la media de los valores, independientemente de la época del año, mientras que la zona sombreada representa la variabilidad con \pm una desviación estándar.

En ella se observa cómo la variabilidad diaria es mayor que en el caso anterior, y cómo la variabilidad de la estacionalidad semanal es completamente irregular y no conforma ningún patrón. Esto responde a que este método no es robusto y no responde correctamente ante ciertas situaciones.

5.6. *Discusión de los resultados*

En este capítulo se ha mostrado la adaptación de los métodos de obtención de valores iniciales o semillas para el uso con múltiples estacionalidades. Adicionalmente se han analizado las posibles diferencias entre ellos.

El análisis se ha llevado a cabo comparando primeramente los resultados en términos de precisión utilizando los diferentes métodos de inicialización sin realizar ajuste alguno en los parámetros de la serie.

Se ha observado cómo los métodos utilizados para obtener el nivel no son significativamente diferentes entre ellos, pero sí que ocurren diferencias entre los métodos para calcular la tendencia y la estacionalidad.

De los métodos previstos en el análisis, se establece que la mejor opción es la utilización de los métodos overall (ver Tabla 5.2) para la obtención del valor inicial para la tendencia. Para el caso del nivel, no hay un método que destaque sobre el resto, así que se recomienda el uso de la media móvil, por ser el más habitualmente utilizado. En el caso de la estacionalidad, se recomienda utilizar el método descrito por el NIST adaptado a la múltiple estacionalidad.

El análisis se ha limitado para analizar los modelos con dos estacionalidades. Las conclusiones pueden ser fácilmente extendidas a modelos con un mayor número de estacionalidades.

6. Análisis de los parámetros

6

6.1. Introducción

La función que desarrollan los parámetros en las ecuaciones de suavizado en los modelos de Holt-Winters es fundamental. El hecho de asignar una mayor o menor importancia a los valores más recientes frente a los más antiguos, determina el comportamiento del modelo para realizar las previsiones futuras. Por ello, es necesario conocer el comportamiento de los parámetros en la serie.

Este capítulo aborda el tema de la optimización de los parámetros y la estabilidad de los mismos desde un punto de vista práctico, directamente relacionado con la demanda eléctrica horaria en España.

Primero se analiza la necesidad de estudiar la estabilidad, y se estudia la bibliografía existente al respecto.

Seguidamente se describe el análisis realizado para estudiar el comportamiento de los parámetros. Se determina la estabilidad de los parámetros y las relaciones con la serie de datos, y se aplica tanto para dos como para tres estacionalidades.

Finalmente se recogen los resultados del estudio realizado y se resumen las conclusiones obtenidas.

6.2. Justificación

La precisión de las previsiones en la demanda eléctrica es un papel fundamental a estudiar en las herramientas de series temporales. Cualquier imprecisión en los modelos acarrea enormes pérdidas de los gestores del sistema de transporte, de los productores, y, en definitiva, del consumidor final.

En los modelos de Holt-Winters, la precisión de las previsiones viene ligada a los parámetros de suavizado. Estos parámetros, recordemos, proporcionan un peso a las ecuaciones de suavizado para equilibrar en ellas la importancia que se les da a los nuevos valores observados frente a los ya incluidos en el modelo. Esto juega un papel fundamental en la ecuación de previsión, ya que las innovaciones dependen en gran medida de los valores de estos parámetros.

Para obtener los parámetros, se utilizan los valores observados para minimizar el error de la previsión del modelo con esos datos. Sin embargo, pueden surgir problemas de sobreparametrización, de sobreajuste, o de no conseguir un buen ajuste.

Además, una vez determinados estos valores de los parámetros, ¿durante qué periodo son válidos? ¿Y los parámetros son repetitivos en situaciones semejantes? Estas y otras cuestiones se analizan en este capítulo.

6.3. Análisis bibliográfico

La precisión de las previsiones en los modelos de Holt-Winters ha sido objeto de estudio a lo largo de la existencia de los modelos, y cómo seleccionar el mejor método y ajustar los parámetros. El capítulo anterior versaba sobre este tema.

A partir del ajuste del modelo, se trabaja con los parámetros de suavizado - que se suponen óptimos para el conjunto de datos -. Sin embargo, el estudio de sus valores o de

la estabilidad de los mismos no ha sido profundizado en la literatura. Esto se debe, en gran parte, a que los modelos no permiten un análisis matemático teórico.

Archibald (1990) utiliza 406 series mensuales provenientes de las competiciones M. Con ellas analiza los modelos con estacionalidades aditivas, y demuestra que los valores de los parámetros dentro del rango $[0,1]$ no siempre resultan invertibles, y que para que la serie sea estable y pueda mejorar las predicciones, es necesario utilizar únicamente un rango establecido dentro de la región de invertibilidad.

Lawton (1998) utiliza los espacios de estado para analizar los modelos de Holt-Winters, y aunque su trabajo se centra en la normalización de la componente estacional, analiza la estabilidad de los parámetros. A partir de los trabajos anteriores en los filtros (A. C. Harvey 1990; Barnett y Cameron 1985), determina que los modelos de Holt-Winters no son asintóticamente estables. Los valores de los vectores propios de las matrices de estabilidad para la estabilidad dependen de α , γ y δ .

Hyndman, Akram y Archibald (2003) trabajan en la obtención de los límites de los parámetros de suavizado. En los espacios de estado, los parámetros deben cumplir $0 < \alpha < \gamma^3$. Finalmente, Hyndman, Akram y Archibald (2008) establecen una serie de criterios en los parámetros para que los modelos puedan ser “prediccionables”, término que acuña si una serie será capaz de realizar previsiones con media y varianza constante. Osman y King (2018) obtienen los valores de los vectores principales y ratifican que los modelos propuestos en (Hyndman, Akram, y Archibald 2008) producen predicciones estables, pero si se utilizan regresores, estos deben ser invariantes en el tiempo.

³ El nombre de los parámetros varía según autores. En este caso, Hyndman, Akram y Archibald utilizan β para el parámetro de suavizado de la tendencia. Aquí se ha adaptado para coincidir con la nomenclatura utilizada en esta tesis.

Otro estudio interesante relacionado con este capítulo es el estudio del tamaño mínimo necesario para la muestra. Hyndman y Kostenko (2007) analizan esta situación y concluyen que no existe una respuesta clara, pero que se debe tener muchas más observaciones que parámetros. A este respecto, García-Díaz y Trull (2016) comprueban como para un modelo doble estacional, una longitud del conjunto de datos de un año produce parámetros más estables que con 8-10 semanas.

6.4. Marco de trabajo

Para determinar la pronosticabilidad de los modelos, es necesario realizar un análisis sobre dos puntos principales: las predicciones realizadas, y los parámetros utilizados.

La bibliografía expuesta anteriormente, se centra en buscar un cómputo general de esta característica de los modelos de series temporales, que difícilmente se aplica a los modelos de Holt-Winters. Sin embargo, el concepto no varía: proporcionar pronósticos estables en diferentes condiciones.

El análisis consiste en tomar un conjunto de datos y optimizar los parámetros, utilizando todos los modelos disponibles. El ajuste se ha realizado minimizando el RMSE. A partir de aquí se realizan previsiones a muy corto y corto plazo, de 24 horas durante un periodo de validación de 2 semanas y 168 horas. Para cada conjunto de datos, se extraen los valores obtenidos de cada uno de los parámetros de suavizado, así como otros datos necesarios o interesantes para el análisis.

Con el objetivo de observar la máxima variabilidad posible, se han utilizado conjuntos de datos seleccionados aleatoriamente, pero siempre cumpliendo las siguientes premisas:

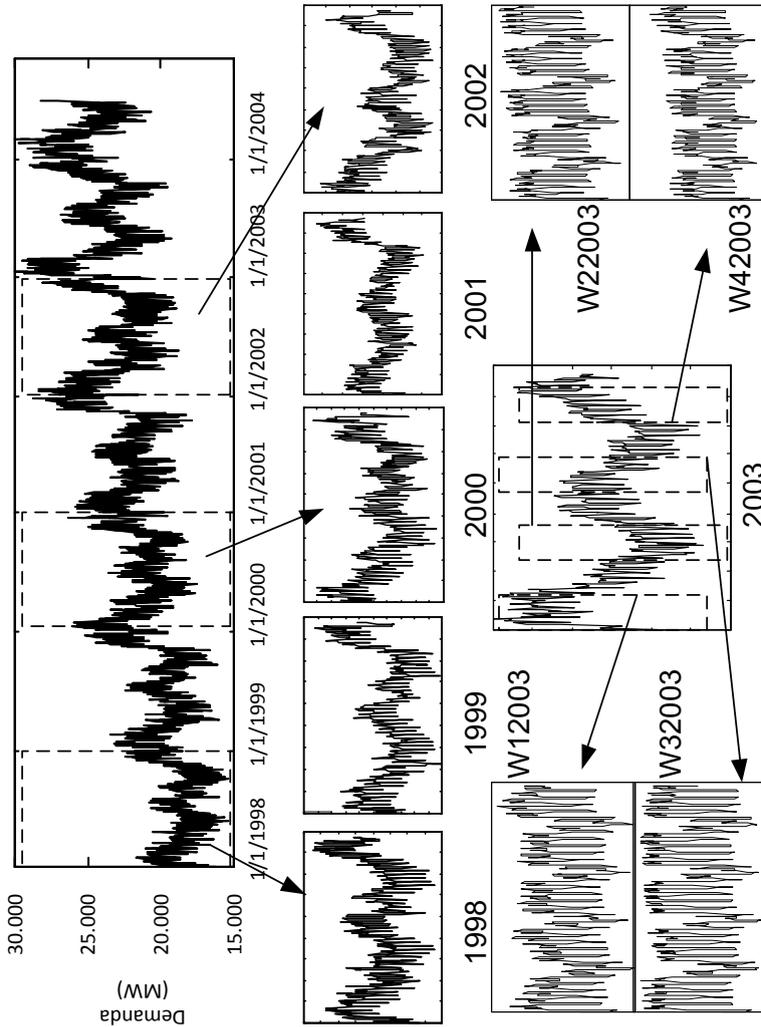


Figura 6.1. Desglose de las ventanas utilizadas para el análisis de los parámetros. El periodo global se divide en años, y dentro de cada año se divide en 4 ventanas según la estación del año. Para cada ventana, se utilizan diferentes réplicas aleatorizadas de 5 semanas.

- Al menos 3 conjuntos de datos en cada estación del año.
- Al menos debe haber conjuntos en años diferentes, para comprobar la repetitividad del proceso en situaciones semejantes en cuestión de periodo del año, incluso festivos cercanos.
- Los datos no se han filtrado ni los días especiales han sido alterados.

Este proceso se realizó primeramente para los modelos con dos estacionalidades, y con dos conjuntos de datos diferenciados. Posteriormente se realizó el mismo análisis utilizando tres estacionalidades.

Los datos utilizados para el análisis son inicialmente los datos proporcionados por REE desde el año 1998 hasta el 2003. Se toman en consideración estos datos, porque la curva de demanda muestra una tendencia pronunciada, que a priori sugiere una mayor influencia de la tendencia. Con el objetivo de comprobar las diferentes situaciones en las estaciones del año, se descompone la serie en ventanas estacionales, invierno (W1), primavera (W2), verano (W3) y otoño (W4), de varios años diferentes. Así pues, la curva de demanda se divide en ventanas para cada estación de acuerdo a lo indicado en la Figura 6.1. De este modo, el periodo de verano para el 2002 sería el W32002. Esta nomenclatura aplica a todos los estudios realizados en este capítulo.

En cada ventana estacional, se tomaron aleatoriamente series de 10 semanas, de las cuales las últimas dos se reservaron como conjunto de validación.

Puesto que el análisis previo se realizó para un periodo concreto, donde su principal característica era una fuerte tendencia, también se realizó un análisis semejante en un periodo distinto, entre 2007 y 2015. En este periodo de crisis, la componente de tendencia vista en la serie anterior no se produce, y sin embargo se producen más irregularidades en los periodos estacionales.

Así mismo, debido a la naturaleza múltiple estacional de los modelos, se llevó a cabo un análisis de los parámetros triple estacionales. Para llevar a cabo el análisis, se consideraron tres estacionalidades de 24, 168 y 8766 horas. Las dos primeras corresponden a los periodos intradiarios e intrasemanales. Para la tercera estacionalidad se consideró 365,25 días, como año natural. Para el estudio se ha utilizado la información de los años 2008 a 2017 y se ha desarrollado el trabajo únicamente sobre el modelo $AMC_{24,168,8766}$. Del mismo modo que se ha utilizado en el análisis anterior, se han hecho previsiones de 24 horas en un periodo de 2 semanas, aunque para el ajuste se han necesitado conjuntos de 3 años completos.

6.5. Resultados

A continuación, se muestran los resultados obtenidos en el análisis. Se desdobra en los análisis realizados para modelos doble estacionales y posteriormente para los modelos triple estacionales.

6.5.1. Conjunto de datos doble estacional (1998-2003)

En la Figura 6.2 se muestra la distribución de los tiempos de cálculo para la obtención de los parámetros en el primer conjunto de datos utilizado (1998-2003).

Se observa cómo la inclusión de un nuevo parámetro dispara los tiempos de cálculo. Esto hace reflexionar sobre la necesidad de utilizar modelos más complejos en la previsión de demanda eléctrica. Los tiempos de cálculo aumentan y en ocasiones la precisión de los modelos lo hace. Así que hay que analizar qué parámetros pueden ser relevantes en el estudio y cuales son superfluos.

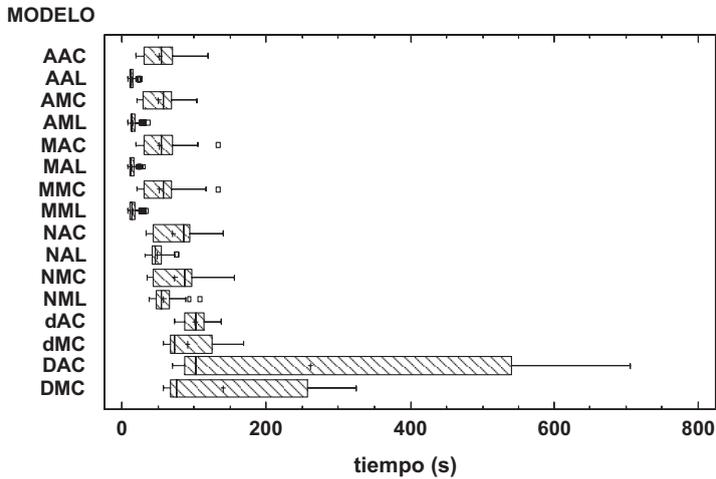


Figura 6.2. Distribución de los tiempos necesarios para realizar la optimización de los modelos. Este tiempo se mide en segundos, y ha sido generado en la obtención de los parámetros utilizando la serie de demanda eléctrica en el periodo de 1998 a 2004.

La primera fase del estudio a realizar con el conjunto de datos consistió en comparar los datos del ajuste, y comprobar que las previsiones que se producían eran acertadas, con el fin de dar sentido al estudio. Para ello, se comparó el MAPE en el ajuste y se utilizó el sMAPE para las previsiones. En la Tabla 6.1 se muestra los resultados de los modelos más relevantes en este estudio inicial. Los modelos con mayor interés de estudio fueron los $AMC_{24,168}$, $MMC_{24,168}$ y $NAC_{24,168}$. Estos modelos mostraron una precisión en las previsiones superior al resto, y con un MAPE en el ajuste similar al resto.

En la tabla los resultados del MAPE para el ajuste son similares en todas las estaciones para todos los modelos, aunque el otoño refleja un valor más elevado, seguido del invierno. Esto se debe a que otoño es la temporada más complicada e irregular para los modelos de previsión. Esto se refleja también en las previsiones, como muestran el resto de columnas. El efecto calendario tiene mucha influencia en los resultados obtenidos.

Tabla 6.1. Desglose de la distribución del MAPE para el ajuste y el sMAPE de la previsión realizada a 24 y 168 horas para los modelos a estudiar. El desglose se realiza de acuerdo a la estación del año.

MODELO	ESTACIÓN	MAPE(Ajuste)	sMAPE (24h)	sMAPE (168h)
AMC _{24,168}	Otoño	0,6899	1,2330	1,6713
	Primavera	0,5698	0,9066	1,3722
	Verano	0,4732	0,6980	1,1425
	Invierno	0,6000	0,6935	1,6465
	Media	0,5746	0,8761	1,4280
	Desv.	0,1774	0,9435	1,4723
MMC _{24,168}	Otoño	0,6918	1,1746	1,5392
	Primavera	0,5670	0,8414	1,1352
	Verano	0,4732	0,6812	1,0243
	Invierno	0,6035	0,6390	1,2131
	Media	0,5750	0,8295	1,2123
	Desv.	0,1757	0,9078	0,8169
NAC _{24,168}	Otoño	0,7084	1,2328	1,6661
	Primavera	0,5754	0,8623	1,1366
	Verano	0,4904	0,7334	1,0588
	Invierno	0,6201	0,6662	1,1620
	Media	0,5897	0,8702	1,2428
	Desv.	0,1844	0,9425	0,8869

En la Tabla 6.2 se muestran los valores de los parámetros de suavizado dependiendo de la estación del año y del año en cuestión. En ella se ha seleccionado el modelo $AMC_{24,168}$.

Se aprecia como, en general, el ajuste tiene una variabilidad reducida, con un MAPE dentro de un rango entre 0,16 y 0,20. En verano, esta variabilidad se reduce, además, hasta 0,08. Un análisis sobre los parámetros refleja que aquellos parámetros relacionados con la estacionalidad muestran una variabilidad semejante a la encontrada en el ajuste (exceptuando en los meses de otoño). La Figura 6.3 muestra la distribución de dichos parámetros según la estación del año.

Tabla 6.2. Parámetros de suavizado para el modelo $AMC_{24,168}$ y el MAPE en el ajuste.

	α	γ	$\delta^{(24)}$	$\delta^{(168)}$	φ_{AR}	MAPE	
Invierno	W11998	0,0292	0,0039	0,4103	0,2434	0,9213	0,7106
	W11999	0,1137	0,1597	0,4143	0,2622	0,9288	0,6381
	W12000	0,0108	0,0790	0,4182	0,3122	0,9204	0,4929
	W12001	0,0160	0,3910	0,3389	0,3333	0,9494	0,5388
	W12002	0,0612	0,3277	0,3745	0,2442	0,9558	0,6444
	W12003	0,0114	0,2145	0,3644	0,3697	0,9422	0,5923
	<i>Media</i>	<i>0,0383</i>	<i>0,1996</i>	<i>0,3854</i>	<i>0,2982</i>	<i>0,9369</i>	<i>0,6000</i>
<i>Desv. Est.</i>	<i>0,0869</i>	<i>0,3734</i>	<i>0,1464</i>	<i>0,1608</i>	<i>0,0304</i>	<i>0,1921</i>	
Primavera	W21998	0,1708	0,0825	0,1943	0,3545	0,9330	0,6178
	W21999	0,0692	0,0025	0,2274	0,4338	0,9336	0,5034
	W22000	0,2185	0,0014	0,2947	0,4081	0,9102	0,5866
	W22001	0,2262	0,1041	0,3066	0,3862	0,9394	0,5692
	W22002	0,2430	0,0540	0,2555	0,4090	0,9174	0,5242
	W22003	0,2403	0,0313	0,2890	0,4247	0,9238	0,6166
	<i>Media</i>	<i>0,1969</i>	<i>0,0476</i>	<i>0,2634</i>	<i>0,4024</i>	<i>0,9265</i>	<i>0,5698</i>
<i>Desv. Est.</i>	<i>0,2431</i>	<i>0,1873</i>	<i>0,1260</i>	<i>0,1605</i>	<i>0,0301</i>	<i>0,1891</i>	
Verano	W31998	0,1064	0,1163	0,3237	0,4092	0,9347	0,4671
	W31999	0,0584	0,2386	0,3016	0,3899	0,9252	0,4633
	W32000	0,2430	0,0002	0,3649	0,4017	0,9135	0,4884
	W32001	0,1934	0,0515	0,3550	0,3771	0,9240	0,5098
	W32002	0,0884	0,0079	0,3545	0,3970	0,9291	0,4610
	W32003	0,2282	0,1001	0,3828	0,4989	0,9131	0,4451
	<i>Media</i>	<i>0,1525</i>	<i>0,0849</i>	<i>0,3466</i>	<i>0,4106</i>	<i>0,9234</i>	<i>0,4732</i>
<i>Desv. Est.</i>	<i>0,1845</i>	<i>0,2510</i>	<i>0,0989</i>	<i>0,1496</i>	<i>0,0293</i>	<i>0,0818</i>	
Otoño	W41998	0,4521	0,0948	0,5298	0,5845	0,9226	0,7341
	W41999	0,4431	0,0004	0,3651	0,5885	0,9183	0,7252
	W42000	0,4123	0,1267	0,3769	0,5747	0,9194	0,7252
	W42001	0,3820	0,0039	0,4033	0,4820	0,9261	0,6824
	W42002	0,4341	0,0324	0,4559	0,5865	0,9163	0,6997
	W42003	0,2544	0,0739	0,5012	0,5097	0,9282	0,5740
	<i>Media</i>	<i>0,3965</i>	<i>0,0551</i>	<i>0,4414</i>	<i>0,5559</i>	<i>0,9219</i>	<i>0,6899</i>
<i>Desv. Est.</i>	<i>0,4066</i>	<i>0,1799</i>	<i>0,2780</i>	<i>0,3368</i>	<i>0,0299</i>	<i>0,1670</i>	

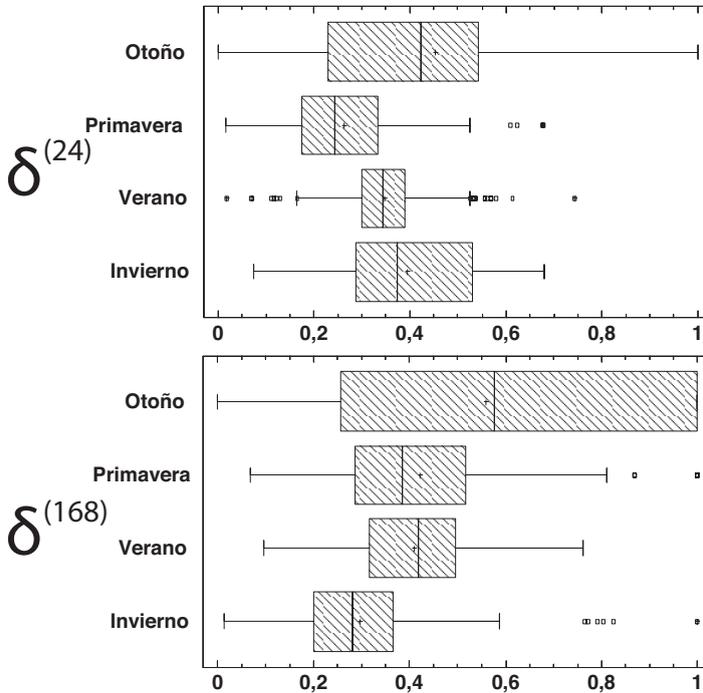


Figura 6.3. Distribución de los parámetros de suavizado estacionales intradiario e intrasemanal para el conjunto de datos 1998-2004.

El parámetro $\delta_{(24)}$ tiene una variabilidad entre 0,09 y 0,15 a excepción de otoño, donde se dispara hasta los 0,28. Por otro lado, $\delta_{(168)}$ se muestra mucho más estable, con una variabilidad alrededor de 0,15, pero con un incremento en otoño de hasta 0,34. El valor de posición se ha medido mediante la media y la mediana, que proporcionan resultados parejos.

A primera vista se observa cómo la estacionalidad diaria aumenta su valor en los meses de enfriamiento y disminuye en los de calentamiento. La estacionalidad semanal es más dispar. Otoño aumenta drásticamente mientras que en invierno se reduce. Ello hace pensar que la estacionalidad diaria está mayormente relacionada con el efecto de la temperatura mientras que la intrasemanal lo hace con el efecto calendario. Esto además se

agudiza en otoño, donde existen variaciones debidas a festividades y puentes que afectan claramente al modelo. Un aspecto importante es observar el comportamiento de las estacionalidades a lo largo del año. La Figura 6.4 muestra el diagrama de radar de los parámetros, de acuerdo al mes del año y al año.

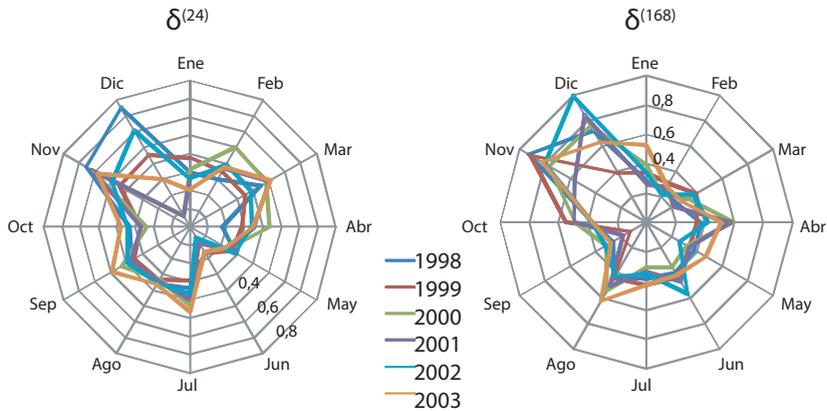


Figura 6.4. Diagrama de radar para los parámetros de suavizado asociados a la estacionalidad.

A pesar de que se realiza en diferentes años y con circunstancias diferentes, muestran un patrón similar. Se confirma que los meses de otoño son cruciales para la estacionalidad (ambas). El valor de $\delta_{(24)}$ en diciembre del año 2001 indica un valor de 0 y responde a una casualidad.

Es relevante el hecho de que en el comienzo de la primavera existe un incremento notable en los valores de los parámetros. Esto se produce tanto en $\delta^{(24)}$ como en $\delta^{(168)}$. Este repunte se debe al efecto producido por las vacaciones de Pascua. Estas vacaciones producen una alteración en la serie, y se producen cada año en fechas distintas, lo cual obliga a estos parámetros a aumentar su valor para adaptarse a los nuevos datos observados.

El parámetro de tendencia muestra un comportamiento diferente. En los periodos de primavera y otoño, cuando la temperatura en España es más suave, se reduce la variabilidad (0,18) en contra de lo que sucede en los meses verano (0,25) e invierno (0,37).

Esto se puede apreciar perfectamente en la Figura 6.3. La mediana se mueve alrededor del 0,3, aunque los valores son muy dispares. Existen una diferencia clara en los meses de otoño, donde las variabilidades de estos parámetros pueden alcanzar valores de hasta 0,3.

A tenor de lo observado en los pronósticos realizados por los modelos, parece relevante que los modelos ofrecen estabilidad en los pronósticos, demostrando buena pronosticabilidad. El posterior análisis sobre los valores de los parámetros de suavizado indica que la pronosticabilidad de los modelos depende sobretodo de los parámetros estacionales.

Por otro lado, los valores de los α y φ_{AR} están directamente relacionados, como ya se alega en (Taylor y McSharry 2007). Los valores reducidos de α se complementan con valores altos de φ_{AR} . El valor de φ_{AR} muestra muy poca variabilidad. En las ocasiones en las que el valor del nivel es elevado, independientemente del ajuste AR(1), se puede estimar que el valor del nivel intenta compensar el efecto calendario (su valor aumenta en los meses de otoño).

6.5.2. Conjunto de datos doble estacional (2008-2017)

Para el análisis doble estacional, se han extraído 250 muestras aleatorias de 10 semanas, del mismo modo que en el caso anterior. La nomenclatura utilizada es exactamente la misma. El periodo utilizado comprende los años 2008 a 2017. Este periodo se caracteriza por ser diferente al anteriormente utilizado, como se muestra en la Figura 2.5 y Figura 2.9. La tendencia prácticamente no existe y la estacionalidad es mucho más variables.

Primeramente, se observan los resultados de las previsiones de los modelos y cómo evolucionan en el tiempo (Tabla 6.3).

Tabla 6.3. Resumen del MAPE de previsión a 24 horas en los modelos doble estacionales desglosado por años.

MAPE(%)					
	AAC _{24,168}	AMC _{24,168}	dAC _{24,168}	dMC _{24,168}	DAC _{24,168}
2008	2,4755	2,4644	2,4402	2,4028	2,4483
2009	3,3322	3,2576	3,3052	3,1723	3,3217
2010	2,8705	2,8389	2,8227	2,8047	2,8034
2011	2,5367	2,4974	2,5120	2,4720	2,5183
2012	2,6761	2,5697	2,5927	2,5209	2,6054
2013	2,2657	2,2284	2,2272	2,2190	2,2351
2014	2,5447	2,4225	2,5114	2,3866	2,4846
2015	2,4527	2,4131	2,4397	2,4164	2,4279
2016	2,6741	2,7129	2,6361	2,6447	2,6399
2017	2,6238	2,6972	2,6189	2,5585	2,6296
<i>Mean</i>	<i>2,6963</i>	<i>2,6521</i>	<i>2,6571</i>	<i>2,6034</i>	<i>2,6601</i>

	DMC _{24,168}	MAC _{24,168}	MMC _{24,168}	NAC _{24,168}	NMC _{24,168}
2008	2,4119	2,4722	2,4462	2,4434	2,4061
2009	3,1572	3,3320	3,1844	3,3208	3,1339
2010	2,8087	2,8427	2,8538	2,8131	2,8043
2011	2,4519	2,5260	2,4670	2,4970	2,4196
2012	2,5267	2,6059	2,5681	2,5932	2,5126
2013	2,2045	2,2430	2,2444	2,2258	2,1720
2014	2,4077	2,5031	2,4787	2,4869	2,4407
2015	2,4117	2,4420	2,5781	2,4256	2,3999
2016	2,6330	2,6520	2,7370	2,6497	2,6366
2017	2,6184	2,6325	2,7615	2,6216	2,5810
<i>Mean</i>	<i>2,6026</i>	<i>2,6746</i>	<i>2,6531</i>	<i>2,6552</i>	<i>2,5872</i>

La muestra los resultados de las previsiones realizadas por los modelos doble estacionales. Únicamente se muestran los modelos con la corrección del ajuste del error de autocorrelación de primer orden, puesto que ofrecen mejores resultados. Los modelos triple estacionales muestran resultados con la misma dinámica, aunque con valores superiores (García-Díaz y Trull 2016).

Con excepción del año 2009, años en el cual la crisis hizo hincapié en el sector industrial español hasta ese momento incierto, el resto de años se observa una clara estabilidad en las previsiones. Los modelos de Holt-Winters se muestran muy robustos ante pequeñas variaciones. Los valores de las previsiones están en torno al 2,6% MAPE a 24 horas. En el caso triple estacional estos valores se sitúan en torno al 7,9% de MAPE.

De todos los modelos, se selecciona el modelo $NMC_{24,168}$ porque ofrece las mejores previsiones. La Figura 6.5 muestra la evolución del MAPE dependiendo del año y de la estación del año.

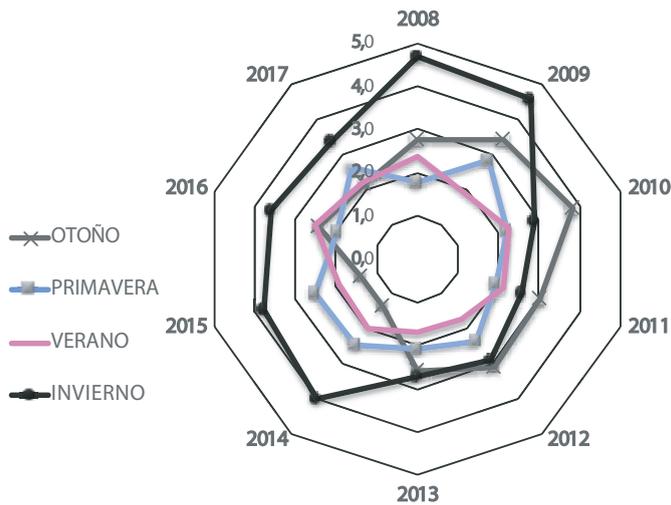


Figura 6.5. Diagrama de radar del MAPE de las previsiones para el modelo $NMC_{24,168}$ en el conjunto de datos 2008-2017.

Claramente los meses de invierno y otoño tienen niveles superiores de MAPE. Contrariamente a lo sucedido en el caso anterior, en esta ocasión los meses de invierno cuando se producen peores previsiones.

Tabla 6.4. Distribución de los parámetros del modelo $NMC_{24,168}$.

	α		$\delta^{(24)}$		$\delta^{(168)}$		φ_{AR}	
	media	Desv.	media	Desv.	media	Desv.	media	Desv.
<i>2009</i>								
Otoño	0,0647	0,0398	0,3003	0,0588	0,2660	0,0795	0,8716	0,0487
Primavera	0,0099	0,0074	0,3762	0,1326	0,1668	0,0316	0,9480	0,0245
Verano	0,0502	0,0288	0,2407	0,0870	0,2044	0,0637	0,8938	0,042
Invierno	0,6009	0,4141	0,4240	0,2209	0,6386	0,3875	0,6615	0,1899
	<i>0,1623</i>	<i>0,2982</i>	<i>0,3331</i>	<i>0,1457</i>	<i>0,3048</i>	<i>0,2548</i>	<i>0,8522</i>	<i>0,139</i>
<i>2010</i>								
Otoño	0,0805	0,0610	0,2890	0,0281	0,2152	0,0422	0,9011	0,0446
Primavera	0,0230	0,0195	0,3029	0,1101	0,2188	0,0505	0,9353	0,0163
Verano	0,0528	0,0075	0,2468	0,0921	0,2518	0,0685	0,8769	0,0279
Invierno	0,3968	0,4766	0,3148	0,1564	0,5331	0,4268	0,7537	0,2124
	<i>0,1</i>	<i>0,2056</i>	<i>0,2863</i>	<i>0,095</i>	<i>0,2696</i>	<i>0,1868</i>	<i>0,885</i>	<i>0,0966</i>
<i>2011</i>								
Otoño	0,0235	0,0723	0,3017	0,0441	0,2351	0,0839	0,9413	0,0552
Primavera	0,0291	0,0238	0,3366	0,1435	0,1973	0,0495	0,9095	0,0448
Verano	0,0804	0,0515	0,2123	0,0563	0,2228	0,0822	0,8846	0,0582
Invierno	0,1821	0,3913	0,2925	0,0575	0,4878	0,3039	0,8618	0,1942
	<i>0,0624</i>	<i>0,1528</i>	<i>0,2874</i>	<i>0,0971</i>	<i>0,2573</i>	<i>0,1566</i>	<i>0,9063</i>	<i>0,0865</i>
<i>2012</i>								
Otoño	0,0529	0,0456	0,3375	0,0452	0,234	0,0691	0,9088	0,048
Primavera	0,0244	0,0367	0,3382	0,1281	0,2057	0,0478	0,9430	0,0542
Verano	0,1005	0,0434	0,2259	0,0662	0,2083	0,0373	0,8445	0,0208
Invierno	0,4701	0,472	0,3858	0,2204	0,6269	0,4147	0,6781	0,244
	<i>0,1264</i>	<i>0,2415</i>	<i>0,3179</i>	<i>0,1263</i>	<i>0,2852</i>	<i>0,2258</i>	<i>0,8638</i>	<i>0,1358</i>
<i>2013</i>								
Otoño	0,0429	0,0175	0,3259	0,0798	0,2420	0,0793	0,856	0,0574
Primavera	0,0182	0,0187	0,3160	0,1168	0,1683	0,0606	0,9365	0,0389
Verano	0,017	0,0187	0,2218	0,0824	0,2306	0,0708	0,9240	0,0541
Invierno	0,5574	0,4954	0,5706	0,3562	0,7178	0,3904	0,6341	0,271
	<i>0,1244</i>	<i>0,2932</i>	<i>0,3407</i>	<i>0,2067</i>	<i>0,2992</i>	<i>0,2681</i>	<i>0,8657</i>	<i>0,165</i>
<i>2014</i>								
Otoño	0,0676	0,0362	0,3823	0,0496	0,2369	0,0866	0,7644	0,1494
Primavera	0,0221	0,0205	0,3568	0,1677	0,1965	0,013	0,9376	0,0361
Verano	0,0139	0,0238	0,1954	0,1014	0,2385	0,0363	0,9537	0,0148
Invierno	0,3812	0,4967	0,3156	0,1955	0,4692	0,4601	0,7007	0,191
	<i>0,1212</i>	<i>0,2652</i>	<i>0,3125</i>	<i>0,1414</i>	<i>0,2853</i>	<i>0,2296</i>	<i>0,8391</i>	<i>0,1547</i>
<i>2015</i>								
Otoño	0,0021	0,0021	0,3123	0,0285	0,2428	0,0314	0,9474	0,0133
Primavera	0,044	0,0386	0,3507	0,1349	0,1673	0,0215	0,9199	0,036
Verano	0,0314	0,033	0,2616	0,1234	0,2486	0,1469	0,9278	0,0539
Invierno	0,3722	0,4874	0,3429	0,2105	0,4552	0,4718	0,681	0,214
	<i>0,1124</i>	<i>0,2616</i>	<i>0,3169</i>	<i>0,125</i>	<i>0,2785</i>	<i>0,239</i>	<i>0,869</i>	<i>0,1486</i>
<i>2016</i>								
Otoño	0,0443	0,0082	0,3238	0,0165	0,239	0,0273	0,9209	0,0068
Primavera	0,0553	0,0437	0,3345	0,1226	0,2279	0,0868	0,8508	0,1155
Verano	0,0755	0,0304	0,2021	0,0764	0,238	0,0832	0,8876	0,0036
Invierno	0,3290	0,5173	0,2690	0,1228	0,4970	0,4370	0,7450	0,2567
	<i>0,126</i>	<i>0,2536</i>	<i>0,2824</i>	<i>0,098</i>	<i>0,3005</i>	<i>0,227</i>	<i>0,8511</i>	<i>0,1385</i>
<i>2017</i>								
Otoño	0,0273	0,0206	0,3193	0,0416	0,2226	0,0298	0,9324	0,0348
Primavera	0,0188	0,0182	0,3501	0,197	0,2208	0,0481	0,9483	0,0277
Verano	0,0494	0,0021	0,3012	0,0305	0,2127	0,0419	0,9225	0,0085
Invierno	0,3347	0,5109	0,3765	0,2708	0,4963	0,4366	0,7259	0,2737
	<i>0,1075</i>	<i>0,2579</i>	<i>0,3368</i>	<i>0,1476</i>	<i>0,2881</i>	<i>0,2266</i>	<i>0,8823</i>	<i>0,1516</i>
<i>TOTAL</i>	<i>0,1054</i>		<i>0,3089</i>		<i>0,2764</i>		<i>0,8738</i>	

En la Tabla 6.4 se muestra la distribución de los valores de los parámetros en función del año y periodo estacional. En esta ocasión se puede observar que ha habido un desplazamiento en los valores de los parámetros del otoño al invierno. Los valores para la estacionalidad diaria están en el orden de 0,2 a 0,3 a excepción de invierno, donde aumenta hasta el valor de 0,4. Para la estacionalidad intrasemanal tiene un valor de 0,2 y para la estación invernal pasa a ser 0,5.

En la Figura 6.6 se muestra una representación de los parámetros a lo largo del tiempo. Se aprecia cómo los valores siguen un patrón de acuerdo al periodo del año.

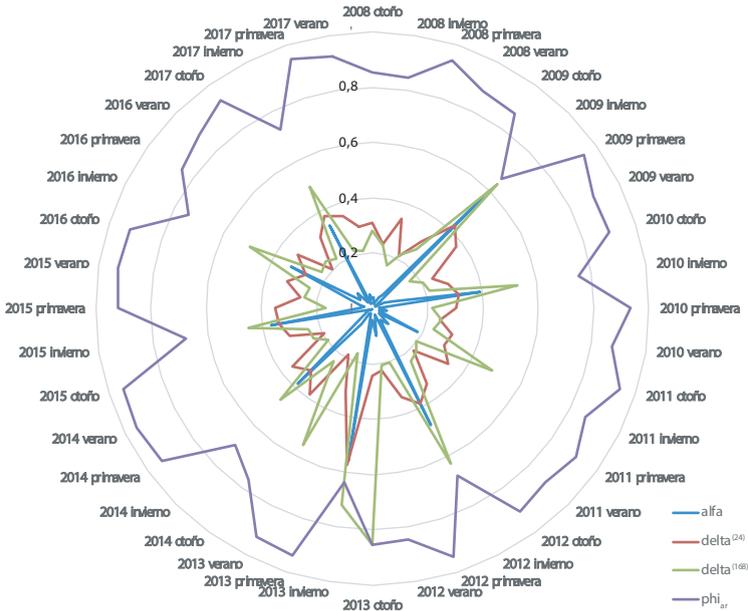


Figura 6.6. Diagrama de radar para la representación de la media de los parámetros en función del tiempo para el modelo $NMC_{24,168}$.

Los valores de nivel y de ajuste AR(1) son ligeramente diferentes a los del análisis anterior. Los valores de nivel son superiores mientras que el ajuste AR(1) son inferiores. Esto se produce porque al eliminar la tendencia, las posibles variaciones a largo plazo las supe el nivel.

El análisis se complementó con un estudio sobre el tamaño del conjunto de datos. Se fijó la fecha 11 de julio de 2016 para realizar 2 semanas de previsiones, y se fue incrementando el tamaño del conjunto de ajuste desde 8 semanas hasta varios años. De este modo, se pretendía observar el comportamiento del modelo frente al tamaño de muestra, siguiendo las indicaciones de (Hyndman y Kostenko 2007a).

En la Figura 6.7 se muestran el resultado obtenido para el nivel de MAPE de las previsiones a 24 horas en función del tamaño de la muestra.

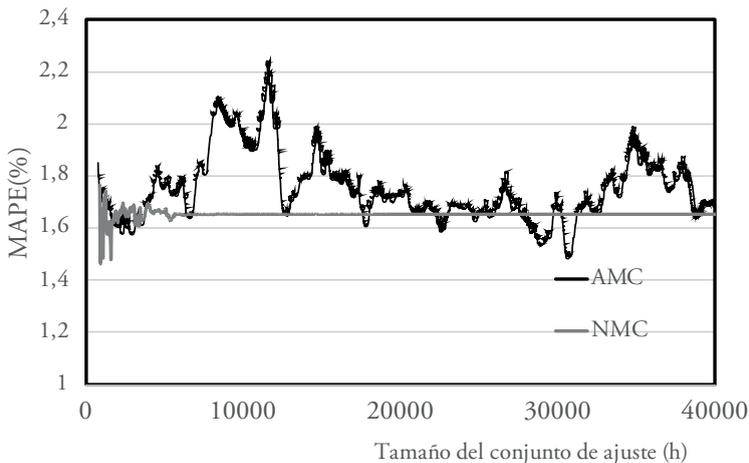


Figura 6.7. MAPE de la pevisión a 24 horas en función del tamaño del conjunto de datos utilizado.

Se utilizan los modelos NMC y AMC para poder comparar el comportamiento de ambos. Se observa que los modelos AMC tienen mayor variabilidad y que a partir un conjunto suficientemente grande (20000 horas) se empieza a estabilizar alrededor del valor medio 1,7%. Si el conjunto empieza a ser demasiado grande, vuelve a tener problemas de estabilidad. El modelo NMC, sin embargo, se muestra mucho más estable en esta ocasión, y con conjuntos relativamente

pequeños, de 5000 horas mantiene los valores de precisión en la previsión alrededor del 1,6%.

La Figura 6.8 muestra la evolución del valor de cada parámetro de acuerdo al tamaño del conjunto de datos utilizado. Se observa como existe una estabilización de forma asintótica de los valores. Sorprende cómo los valores de los parámetros asociados a la estacionalidad intercambian los pesos a medida que el conjunto de datos crece.

En ocasiones se aprecian unos picos donde los valores se disparan. Estos picos coinciden con que la serie comienza en días festivos. De hecho, los picos más intensos coinciden en las fechas del puente de la Inmaculada o Navidad.

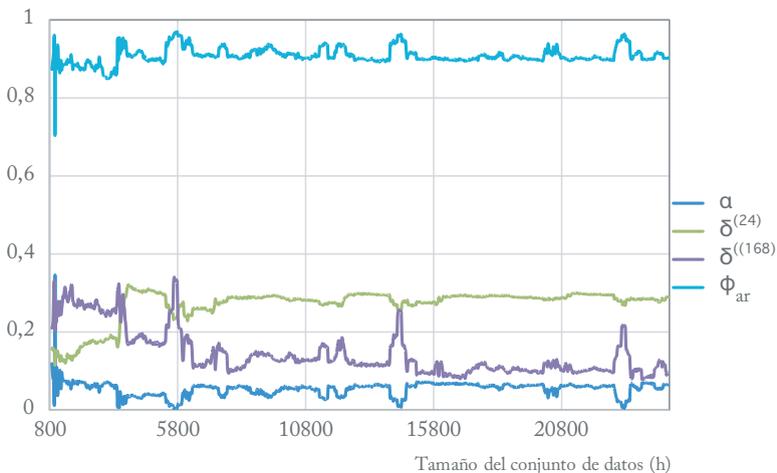


Figura 6.8. Evolución de los parámetros frente al tamaño del conjunto de datos.

Una vez más se observa una estabilidad en los pronósticos demostrando un gran pronosticabilidad. Esta característica no se comporta igual en todos los modelos, y depende en gran parte de los valores de la componente estacional, siempre manteniendo bajos los valores del parámetro de suavizado α .

Tabla 6.5. Distribución de los valores de los parámetros de suavizado para el modelo $AMC_{24,1.68,87.66}$.

	α	γ	$\delta^{(24)}$	$\delta^{(1.68)}$	$\delta^{(87.66)}$	ψ_{AR}						
	MEDIA D.E.	MEDIA D.E.	MEDIA D.E.	MEDIA D.E.	MEDIA D.E.	MEDIA D.E.						
2011												
OTOÑO	0,0008	0,00092	0,00010	0,0000	0,3081	0,00036	0,22959	0,00189	0,0783	0,03059	0,9469	0,00190
PRIMAVERA	0,0006	0,00080	0,00010	0,0000	0,31370	0,00693	0,23765	0,01834	0,04799	0,05024	0,9463	0,00119
VERANO	0,0001	0,0000	0,00010	0,0000	0,31930	0,0094	0,22654	0,00866	0,07181	0,06353	0,94766	0,00144
INVIERNO	0,00010	0,0000	0,00010	0,0000	0,30637	0,00439	0,2144	0,01457	0,1612	0,00382	0,9466	0,00041
TOTAL	0,00032	0,00052	0,00010	0,0000	0,31278	0,00810	0,22670	0,0149	0,08920	0,06042	0,94659	0,00135
2012												
OTOÑO	0,00010	0,0000	0,00010	0,0000	0,31319	0,01133	0,22445	0,00821	0,04833	0,06821	0,94981	0,00156
PRIMAVERA	0,00076	0,00086	0,00010	0,0000	0,3032	0,00453	0,22767	0,00177	0,08856	0,02211	0,94383	0,00078
VERANO	0,00073	0,00126	0,00010	0,0000	0,31895	0,00899	0,234	0,01386	0,06844	0,04868	0,9442	0,00170
INVIERNO	0,00037	0,00047	0,00010	0,0000	0,32593	0,01010	0,24036	0,02149	0,0826	0,03864	0,94459	0,00158
TOTAL	0,00054	0,00082	0,00010	0,0000	0,31575	0,01155	0,23444	0,01381	0,07352	0,04045	0,9458	0,00256
2013												
OTOÑO	0,00010	0,0000	0,00010	0,0000	0,31850	0,00789	0,23482	0,01215	0,08018	0,0154	0,95095	0,00028
PRIMAVERA	0,00010	0,0000	0,00010	0,0000	0,30378	0,00462	0,22797	0,00751	0,08853	0,03275	0,95335	0,00172
VERANO	0,00010	0,0000	0,00010	0,0000	0,31470	0,00299	0,22137	0,00555	0,10170	0,02591	0,95145	0,00112
INVIERNO	0,00010	0,0000	0,00010	0,0000	0,31785	0,01332	0,22917	0,0020	0,14810	0,05712	0,95222	0,00144
TOTAL	0,00010	0,0000	0,00010	0,0000	0,31339	0,00896	0,22721	0,00755	0,10642	0,0416	0,9523	0,00144

Tabla 6.5 (cont). Distribución de los valores de los parámetros de suavizado para el modelo $AMC_{2,4,168,8766}$.

	α		γ		$\delta^{(24)}$		$\delta^{(168)}$		$\delta^{(8766)}$		φ_{AR}		
	MEDIA	D.E.	MEDIA	D.E.	MEDIA	D.E.	MEDIA	D.E.	MEDIA	D.E.	MEDIA	D.E.	
2014	OTOÑO	0,00010	0,0000	0,00010	0,0000	0,31775	0,00995	0,24519	0,00774	0,04669	0,04624	0,94371	0,00053
	PRIMAVERA	0,00010	0,0000	0,00010	0,0000	0,31447	0,00292	0,22513	0,00722	0,08928	0,0126	0,94191	0,00038
	VERANO	0,00010	0,0000	0,00010	0,0000	0,32353	0,0130	0,23518	0,00936	0,05573	0,05172	0,94286	0,00182
	INVIERNO	0,00010	0,0000	0,00010	0,0000	0,32441	0,00318	0,23181	0,00276	0,10034	0,05145	0,94457	0,00022
TOTAL	0,00010	0,0000	0,00010	0,0000	0,324	0,00840	0,23433	0,00974	0,0731	0,04392	0,94326	0,00158	
2015	OTOÑO	0,00010	0,0000	0,00010	0,0000	0,29835	0,0095	0,22581	0,01059	0,09831	0,02037	0,94255	0,00144
	PRIMAVERA	0,00010	0,0000	0,00010	0,0000	0,30496	0,00396	0,2279	0,00420	0,04030	0,01473	0,94212	0,00141
	VERANO	0,00065	0,00095	0,00010	0,0000	0,31336	0,00550	0,22497	0,01265	0,05955	0,05229	0,9411	0,00272
	INVIERNO	0,00010	0,0000	0,00010	0,0000	0,31597	0,00684	0,21166	0,00735	0,13770	0,03026	0,94033	0,00034
TOTAL	0,00024	0,00048	0,00010	0,0000	0,30816	0,00921	0,22238	0,01025	0,08396	0,0481	0,94150	0,00172	
2016	OTOÑO	0,00010	---	0,00010	---	0,32633	---	0,22462	0,0399	---	0,94698	---	
	PRIMAVERA	0,00010	0,0000	0,00010	0,0000	0,30348	0,0067	0,22623	0,00964	0,0757	0,02728	0,94527	0,00153
	VERANO	0,00010	0,0000	0,00010	0,0000	0,31116	0,00651	0,22323	0,00553	0,08812	0,03439	0,94574	0,00221
	INVIERNO	0,00010	0,0000	0,00010	0,0000	0,30889	0,00398	0,21710	0,0025	0,13012	0,03810	0,94299	0,00077
TOTAL	0,0002	0,0005	0,0001	0,0000	0,3134	0,0097	0,2281	0,0115	0,0862	0,0462	0,9456	0,0038	

6.5.3. Conjunto de datos triple estacional

Para la realización de este análisis, se han tomado conjuntos de datos de tamaño 3 años (53x24x7x3 horas) necesarios para poder ajustar los modelos. A partir de ahí, y de forma análoga al proceso anterior, se han realizado previsiones a 24 horas durante dos semanas. A pesar de que se ha analizado con todos los métodos de estacionalidad y tendencia, no existen grandes diferencias entre los modelos, y el modelo $AMC_{24,168,8766}$ resulta ser el más fácil de estudiar, al disponer de 6 parámetros, que incluyen nivel, tendencia, estacionalidad y ajuste.

Los resultados obtenidos en el análisis se muestran en la Tabla 6.5, donde se organizan los valores de los parámetros en función de la estación del año y año.

Al contrario de lo que pasa en los modelos doble estacionales, y como se ha visto en el apartado anterior, al utilizar conjuntos de tamaño superior a 20000 horas, los valores de los parámetros se estabilizan.

Los valores del parámetro $\delta^{(24)}$ se estabiliza alrededor del 0,3 sea el periodo que sea y con una variabilidad mínima. El valor para $\delta^{(168)}$ se estabiliza alrededor del 0,2 y el nuevo parámetro $\delta^{(8766)}$ alrededor de 0,08 y 0,1. Estos valores siguen el patrón indicado en la Figura 6.8, aunque se produce una transferencia entre el parámetro $\delta^{(168)}$ y $\delta^{(8766)}$. La introducción de la tercera estacionalidad ha forzado al modelo a que la estacionalidad intrasemanal se actualice con datos más modernos.

Por otro lado, los valores de α se estabilizan alrededor de prácticamente 0, y los de φ_{AR} cerca de 0,95. La existencia de tantos datos hace que prácticamente el ajuste AR(1) se encargue de adaptar el nivel y que la ecuación de nivel resulte redundante. Esto supondría la eliminación de un parámetro a optimizar.

Adicionalmente, se ha realizado, del mismo modo que en el caso anterior, un análisis sobre el conjunto de datos y sus

consecuencias en la previsión. Se utilizó el mismo día 11 de julio de 2016, donde se fue aumentando gradualmente el tamaño del conjunto de datos observados y se realizaron previsiones a 24 horas y se realizaron previsiones a 24 horas durante dos semanas. El resultado se muestra en la Figura 6.9.

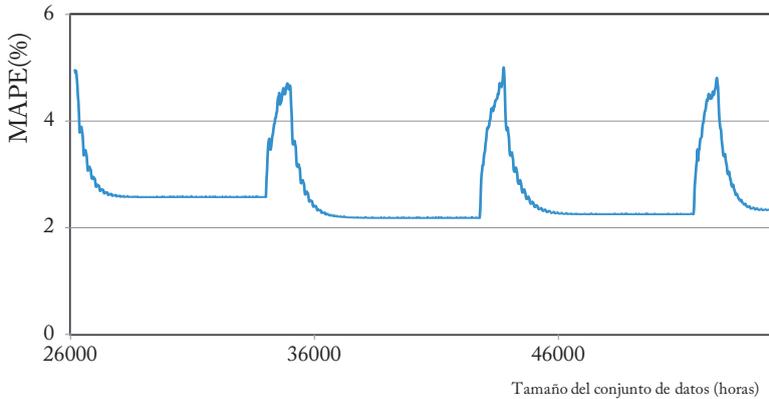


Figura 6.9. Evolución del MAPE de la previsión a 24 horas con el tamaño del conjunto de datos.

Se puede apreciar una evolución asintótica hacia un MAPE de previsión del 2%, aunque de forma periódica, el MAPE se dispara y vuelve a reducirse. La forma de aleta de tiburón responde al comienzo del otoño, y termina con el fin del mismo – recordemos que, en el otoño, el efecto calendario era mucho más importante que en otras fechas.

Una de las características principales que se observan en los modelos triple estacionales es la variabilidad en la pronosticabilidad producida por la época del año donde se producen más festivos: el otoño.

6.6. *Discusión de los resultados*

El objetivo de este capítulo es el análisis empírico de los modelos de Holt-Winters múltiple-estacionales asociados a la demanda eléctrica horaria en España.

La bibliografía encontrada que analiza los parámetros de los modelos intenta dar solución al análisis de estabilidad teórico, con la determinación del concepto de pronosticabilidad. Sin embargo, la aplicación de modelos de Holt-Winters no es directa. Es necesario realizar un análisis empírico de los modelos y de sus previsiones, y a partir de ahí obtener conclusiones sobre la pronosticabilidad.

Se ha establecido un marco de trabajo en el que de un conjunto de datos proporcionado por REE se obtienen muestras para realizar el proceso habitual de ajuste y previsión. La información recopilada de estas previsiones se analiza.

Los modelos doble estacionales con un periodo de ajuste de 8 semanas se muestran robustos en las predicciones. Se han utilizado dos periodos diferentes, con características distintas, y se han obtenido MAPEs en la predicción a 24 horas de alrededor del 2% al 2,6%. En los modelos con mejor comportamiento se han analizado los parámetros, y se ha encontrado una relación directa entre la variabilidad y los valores elevados de los parámetros de suavizado asociados a la estacionalidad, y en las épocas donde ocurre mayor número de festivos que caen en fechas.

El tamaño del conjunto de datos observados influye en la estabilidad. El modelo AMC tiene una variabilidad del 0,2% en el MAPE, que a partir de unas 20000 horas se reduce al 0,1%. El modelo NMC es mucho más estable – la serie tampoco mostraba tendencia-, consiguiendo esta estabilidad en conjuntos superiores a los 5000 horas. A medida que aumenta el número de observaciones, los parámetros de suavizado presentan una estabilización.

En el caso triple estacional ocurre que es necesario un número elevado de observaciones para ajustar el modelo, y por lo tanto, los valores de los parámetros se estabilizan desde el principio. No por ello las previsiones son mejores que en el caso de los modelos doble estacionales. Se aprecia cómo la previsión empeora cuando el conjunto de valores empieza en fechas señaladas del otoño, cuando ocurren muchos festivos.

En definitiva, se puede observar que los parámetros necesitan de un conjunto elevado de datos para estabilizarse, y que los modelos triple estacionales no son capaces de mejorar las previsiones de los doble estacionales debido al efecto calendario. Como consecuencia, es necesario desarrollar modelos que sean capaces de reducir esta variabilidad incluyendo el efecto calendario en el modelo.

7. Modelado de eventos especiales mediante el uso de estacionalidades móviles de intervalo discreto.

7

7.1. Introducción

Este capítulo introduce un nuevo concepto en los modelos de Holt-Winters múltiple-estacionales. Se trata de una estacionalidad discreta que permite aplicar el concepto de estacionalidad en ciertos momentos, siempre que se mantenga la longitud del periodo estacional considerado.

El capítulo está organizado del siguiente modo: en una primera sección se expone la justificación de la necesidad de introducir este nuevo concepto en los modelos, seguido de un análisis sobre la bibliografía existente al respecto. Posteriormente se muestran los modelos de Holt-Winters con estacionalidades móviles de intervalo discreto, y se muestra una aplicación para la demanda eléctrica horaria en España en los días de Pascua, festivos y casos especiales como las huelgas. Finalmente, se resumen las conclusiones alcanzadas en el estudio llevado a cabo mediante estos modelos.

7.2. Justificación

La previsión de demanda eléctrica utiliza modelos que reproducen el patrón regular a lo largo de toda la serie, de modo que se reproduzca lo más fielmente posible este patrón (Hyndman y Athanasopoulos 2018). Sin embargo, las series contienen irregularidades que desvirtúan el patrón regular, y que, en muchas ocasiones, resultan determinantes para la realización de una predicción. Las irregularidades naturales de la serie suelen mostrarse en forma de ruido sobre el patrón, de valor limitado y generalmente asimilado a un ruido blanco.

En ocasiones, puede existir un factor que provoque una irregularidad, que puede ser identificado o no. Ejemplos de este tipo de variaciones pueden ser:

- una variación brusca de la temperatura, que no sucede habitualmente en las fechas de la previsión,
- un festivo,
- una huelga,
- un puente entre dos días festivos,
- Pascuas,
- Etc.

Estos últimos elementos son predecibles, y exceptuando las huelgas, forman parte del denominado efecto calendario. Si además se incluyen las huelgas, se trata de lo que normalmente se denomina como suceso especial.

Estos sucesos provocan que la serie demanda eléctrica modifique su patrón habitual, y se produzca lo que en la literatura se conoce como demanda anómala. Es importante no confundir demanda anómala con valores atípicos. Estos últimos se refieren a valores que de forma inesperada se salen de la normalidad de la serie, mientras que los valores anómalos pueden ser modelizados y estudiados.

Un ejemplo de esta situación puede verse en la Figura 7.1, donde se ha representado la demanda eléctrica horaria en España, comparando la prevista que proporciona un modelo frente a la real. Se puede observar que el modelo intenta reproducir el patrón de los valores observados con anterioridad, pero no es capaz de reproducir la demanda anómala producida durante las Pascuas de ese año. Tanto si se utiliza un modelo doble estacional como un modelo triple estacional, este modelo no será capaz de reproducir esta variación, ya que cada año varía la fecha de comienzo de la Pascua.

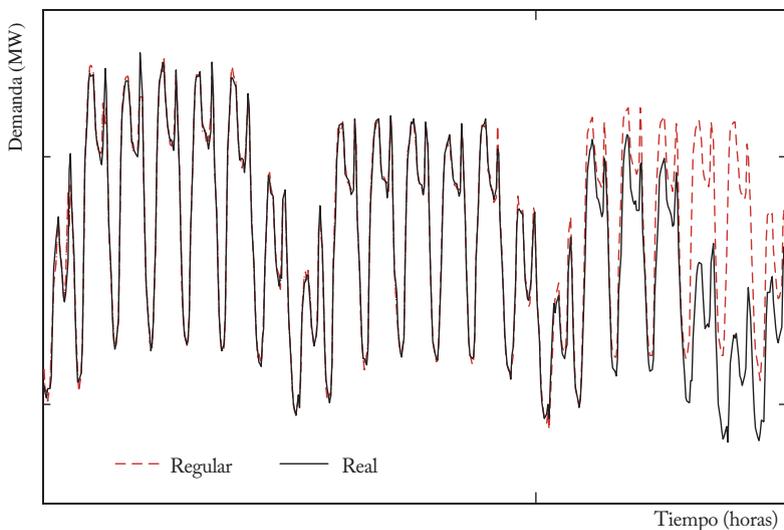


Figura 7.1. Comparativa del efecto producido por un evento especial (Pascuas en este caso) sobre la serie de demanda horaria eléctrica en España. La serie sufre una demanda anómala (línea llena) que el modelo de series temporales (línea a trazos) no es capaz de reproducir, al ser diferente del patrón observado anteriormente.

El objetivo en este capítulo es mostrar un nuevo modelo de Holt-Winters múltiple estacional, que permita mejorar las previsiones en los días especiales y se presentan las estacionalidades móviles de intervalo discreto (DIMS, *Discrete-Interval moving seasonalities*).

7.3. Revisión bibliográfica

El efecto producido por los días especiales y vacacionales ha sido estudiado de diversas formas. Una de las propuestas más habituales es proponer un método de regresión para calcular el efecto de la Pascua y los días especiales, separando este efecto de la estacionalidad (Bell y Hillmer 1984; Čobanov 2018). Otros autores utiliza lógica difusa para determinar los patrones de los días vacacionales (Srinivasan, Chang, y Liew 1995).

Tradicionalmente las técnicas desarrolladas para gestionar la demanda en ocasiones especiales tratan de adaptar la serie con elementos modificadores externos. Findley et al (1996) desarrollan en el método X-12 ARIMA la posibilidad de introducir efecto calendario mediante la adición de variables ficticias.

Cancelo y Espasa (1996) describen el modelo seguido por REE para poder tratar la demanda en días especiales, mediante el uso de variables ficticias. Esta técnica es utilizada de forma generalizada para los modelos de previsión de la electricidad en España con pocas variaciones (Pardo, Meneu, y Valor 2002; Moral-Carcedo y Vicéns-Otero 2005). Cancelo, Espasa y Grafe (2008) utilizan variables ficticias para los días especiales, pero construyendo un modelo separado por contribuciones, en el que la demanda eléctrica se construye como la suma de una demanda base más la contribución de los días especiales y de los efectos de la temperatura.

Otro método utilizado por Contreras et al. (2003) propone la utilización de funciones de transferencia para la modelización de estos eventos especiales. De modo similar se aplica la misma técnica para la demanda eléctrica en Italia (Bianco, Manca, y Nardini 2009). Dordonnat et al. (2008) utilizan variables ficticias para los eventos especiales en Francia, dentro de las denominadas ecuaciones de regresión aparentemente no relacionadas (SURE).

Otra técnica habitual, comentada por Weron (2006), y que es utilizada en muchos trabajos, es la sustitución de un día con eventos especiales por un día similar. Esta técnica se denomina *método ingenuo*, o Método Naïve y de días similares. Weron (2006) explica que se recurre a buscar días similares ocurridos con anterioridad, y se realiza la previsión asumiendo que el día es de ese tipo. Por ejemplo, prever que la demanda de eléctrica en un día de huelga será similar a la de un domingo, y utilizar esta demanda como previsión a futuro. Esta misma técnica es utilizada para el ajuste. Así, los trabajos de Taylor (Taylor 2003b; Taylor, de Menezes, y McSharry 2006; Taylor 2010b) sustituyen los días donde ocurre un evento especial por un día habitual sin este evento en el momento del ajuste de sus modelos. La aplicación a los métodos de suavizado exponencial y métodos de Holt-Winters siempre se ha realizado modificando la serie original. De Livera, Hyndman y Snyder (2011) explican cómo primero realizan un modelo con espacios de estado, los comparan con los datos reales y obtienen el efecto del calendario, que lo restan a la serie original y tras realizar de nuevo todo el proceso, lo introducen de nuevo.

La utilización de la inteligencia artificial y redes neuronales adquiere otro punto de vista. Se utiliza las redes neuronales artificiales para modelar los eventos especiales (Srinivasan, Chang, y Liew 1995), y también es de amplio uso los Mapas autoorganizados (métodos de clustering) para hacer las previsiones (Chicco, Napoli, y Piglionne 2001). Fidalgo y Lopes (2005) aplican esta técnica en la industria, con un software (DMS) aplicado a la previsión en redes.

Un nuevo enfoque se ha dado a la gestión de los eventos especiales, en los cuales se evita el uso de variables externas al modelo, y se gestiona con variables internas. Bermúdez (2013) introduce covariables dentro del modelo que permiten modelizar tanto el efecto de la temperatura como los días especiales. En este trabajo, se considera la utilización de covariables con valor 1 para días considerados normales, y valores diferentes según el peso esperado para cada tipología de evento especial. Arora y Taylor

(2013, 2018b) utilizan métodos basados en reglas (rule-based methodology) para poder establecer un modelo sin la utilización de variables exógenas. En esta metodología se modifica el periodo y longitud de la estacionalidad de forma seleccionada, de modo que se utilice la demanda de un día similar para alimentar el modelo y hacer previsiones.

Actualmente REE trabaja la clasificación de los días especiales para integrar en los modelos propios para la previsión (López et al. 2019).

En este capítulo se presenta un método diferente con un punto de vista alternativo. Basándose en modelos de Holt-Winters múltiple-estacionales, que han demostrado ser muy efectivos para realizar previsiones, se pretende introducir estas demandas anómalas debidas a situaciones y eventos especiales como parte inherente del modelo, sin la necesidad de utilizar variables exógenas, y procurando que el modelo sea el que se ajuste lo mejor posible a los datos con la mínima intervención.

Uno de los aspectos a tener en cuenta es la normalización de las estacionalidades. Lawton (1998) estudia la normalización de las estacionalidades asociadas a los modelos de Holt-Winters, a pesar de que lo realiza desde una perspectiva de los espacios de estado. En este trabajo, analiza las bases de los índices estacionales y concluye que no es necesario que la suma de los índices sea siempre 0, o que sea necesario corregir la estacionalidad. Sin embargo, sí que indica que las estacionalidades, en el caso de que contenga irregularidades, es mejor mantenerlas y añadir las correcciones. Archibald y Köhler (2003) sin embargo, recomiendan en todo momento actualizar las estacionalidades.

7.4. Modelos de Estacionalidad móvil de intervalos discretos (DIMS)

El modelo general de Holt-Winters (nHWT), expresado en su variante de tendencia aditiva y estacionalidad multiplicativa se exhibe en las ecuaciones (7.1) a (7.4).

$$S_t = \alpha \left(\frac{X_t}{\prod I_{t-s_i}^{(i)}} \right) + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (7.1)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (7.2)$$

$$I_t^{(i)} = \delta^{(i)} \left(\frac{X_t}{S_t \prod_{j \neq i} I_{t-s_j}^{(j)}} \right) + (1 - \delta^{(i)})I_{t-s_i}^{(i)} \quad (7.3)$$

$$\hat{X}_t(k) = (S_t + kT_t) \prod_i I_{t-s_i+k}^{(i)} + \varphi_{AR}^k \varepsilon_t \quad (7.4)$$

Donde S_t y T_t son las ecuaciones para el nivel y la tendencia, con parámetros de suavizado α y γ . $I_t^{(i)}$ son las ecuaciones para los índices estacionales, de longitud s_i , con parámetro de suavizado $\delta^{(i)}$. Existen tantas ecuaciones estacionales como patrones estacionales se deseen estudiar en la serie. X_t son los datos observados.

Finalmente, $\hat{X}_t(k)$ es la ecuación de previsión para k instantes de tiempo en el futuro, que recoge la información obtenida en el modelo y realiza la previsión. Para incluir el ajuste del error de autocorrelación de primer orden, se incluye φ_{AR} . Este modelo no tiene en consideración los eventos especiales.

Al observar el efecto de un día de huelga sobre la demanda eléctrica horaria en España, como se muestra en la Figura 7.2,

puede apreciarse como el evento especial modifica el comportamiento de la serie de forma sustancial.

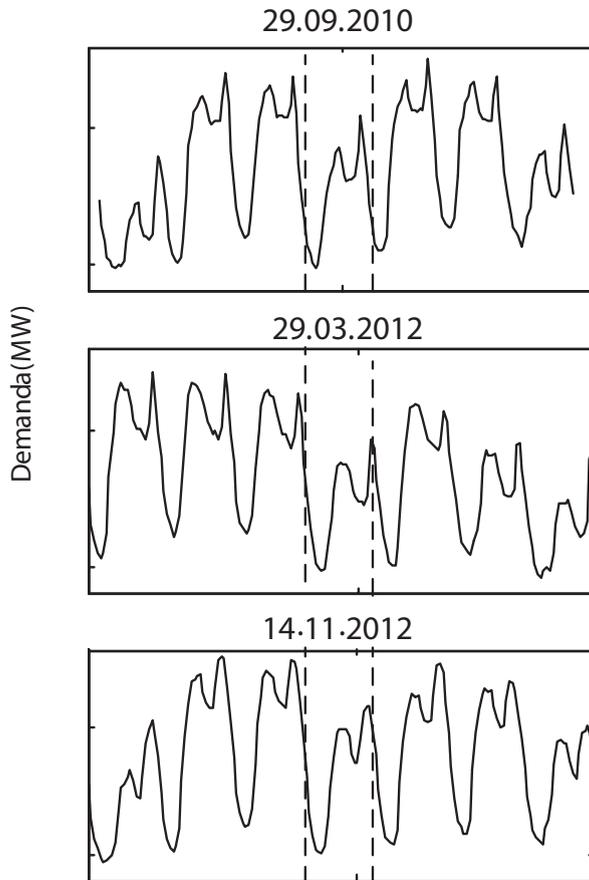


Figura 7.2. Efecto provocado por una huelga sobre la demanda eléctrica horaria en España. Se aprecia como el patrón que siguen las series temporales se trunca con un descenso el día de la huelga. No obstante, este descenso sigue un patrón similar.

Además, y a pesar de que no se sigue el patrón principal, puede observarse un nuevo patrón que se repite en cada nueva aparición, y que se produce con una longitud de periodo fija. Ello indica que puede tratarse como una nueva estacionalidad, aunque debe ser discreta, puesto que sólo está modificando la serie principal en un momento concreto de tiempo.

Siguiendo las indicaciones descritas en (Lawton 1998; Archibald y Koehler 2003) es importante mantener las estacionalidades y sobreponer los efectos modificadores. De esta forma, se puede introducir como una nueva estacionalidad que modifica a la ya existente.

Otro elemento importante es determinar cuándo se va a producir esta nueva estacionalidad discreta, ya que no tiene una posición fija en la serie temporal. Es por ello, que esta estacionalidad ha de presentarse como móvil, además de ser discreta. El nombre utilizado será Estacionalidad Móvil de Intervalo Discreto, DIMS (Discrete-Interval Mobile Seasonality).

En el caso que se ha mostrado anteriormente, es necesario que la estacionalidad esté presente únicamente desde las 00:00 horas del día de huelga hasta las 24:00 del mismo día, y actuando como una nueva estacionalidad anidada al resto de estacionalidades que se repiten de forma continuada en la serie. Por ello, se debe introducir como se indica en la ecuación (7.5).

$$D_{t_h^*}^{(h)} = \delta_D^{(h)} \left(\frac{X_t}{S_t \prod_j I_{t-s_j}^{(j)} \prod_{m \neq h} D_{t_h^* - s_m}^{(m)}} \right) + (1 - \delta_D^{(h)}) D_{t_h^* - s_h^*}^{(h)} \quad (7.5)$$

$D_{t_h^*}^{(h)}$ son las nuevas ecuaciones para los índices estacionales discretos de longitud s_h , cuyo parámetro de suavizado es $\delta_D^{(h)}$, y que se define únicamente en el periodo de tiempo t_h^* . Para que la recursividad del modelo se pueda determinar de forma variable según cada aparición del evento, estas ecuaciones deben ser recurrentes en el tiempo de forma variable, y para ello debe recurrirse a $t_h^* - s_h^*$, donde s_h^* es la distancia entre el mismo punto de partida del DIMS actual, y la inmediata aparición anterior.

Para incorporar el DIMS al modelo principal, debe introducirse una nueva ecuación de estacionalidad, integrada con el resto del modelo. Se introduce de forma anidada dentro del modelo, con el fin de que esté relacionada con el resto de estacionalidades. Para mantener la filosofía del modelo original, la estacionalidad está suavizada, y depende únicamente de un parámetro de suavizado. El nuevo modelo resultante se muestra en (7.6) a (7.10).

$$S_t = \alpha \left(\frac{X_t}{\prod I_{t-s_i}^{(i)} \prod D_{t^*-s_j}^{(j)}} \right) + (1 - \alpha) (S_{t-1} + T_{t-1}) \quad (7.6)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (7.7)$$

$$I_t^{(i)} = \delta^{(i)} \left(\frac{X_t}{S_t \prod_{j \neq i} I_{t-s_j}^{(j)} \prod_m D_{t^*-s_m^*}^{(m)}} \right) + (1 - \delta^{(i)}) I_{t-s_i}^{(i)} \quad (7.8)$$

$$D_{t_h^*}^{(h)} = \delta_D^{(h)} \left(\frac{X_t}{S_t \prod_j I_{t-s_j}^{(j)} \prod_{m \neq h} D_{t_h^*-s_m^*}^{(m)}} \right) + (1 - \delta_D^{(h)}) D_{t_h^*-s_h^*}^{(h)} \quad (7.9)$$

$$\hat{X}_t(k) = (S_t + kT_t) \prod_i I_{t-s_i+k}^{(i)} \prod_j D_{t^*-s_h^*+k}^{(h)} + \varphi_{AR}^k \varepsilon_t \quad (7.10)$$

La nueva ecuación $D_{t_h^*}^{(h)}$ se integra dentro del modelo como una estacionalidad más en la ecuación de previsión (7.10).

7.5. Método de trabajo con DIMS

La utilización de DIMS en los modelos requiere de una particular forma de trabajar. Su funcionamiento es sencillo, y resulta similar al proceso con el método regular, aunque existen diferencias a la hora de establecer los valores iniciales y los parámetros. En la Figura 7.3 se muestra el esquema de trabajo.

7.5.1. Obtención de los valores iniciales

En primera instancia, los valores iniciales del modelo regular sin la utilización de los DIMS se obtienen de forma general, como se describe en el capítulo anterior. Tras haber obtenido las semillas del modelo regular, pueden obtenerse las semillas para cada una de las DIMS. Es importante tener en cuenta que la nueva estacionalidad afecta únicamente a un determinado conjunto de instantes de tiempo, a la par que tiene una longitud periódica que no tiene por qué cuadrar con ninguna otra estacionalidad. Por ello es necesario distinguir entre las estacionalidades propias del modelo, y las DIMS. Se seguirá el esquema de la parte central de la Figura 7.3.

El primer paso consiste en descomponer la serie en sus componentes principales, tendencia y estacionalidad. Deben utilizarse tantas estacionalidades como se hayan apreciado en el modelo. Por ello en este trabajo se ha utilizado la descomposición STL (Seasonal-Trend based on Loess, (Cleveland et al. 1990)) múltiple estacional. Se puede utilizar cualquier otro tipo de descomposición, pero esta ha dado muy buenos resultados. La descomposición puede verse en (7.11).

$$X_t = T_t + \sum S_t^{(s_i)} + U_t \quad (7.11)$$

Donde T_t vuelve ser la tendencia, y $S_t^{(s_i)}$ son los índices estacionales para cada uno de los patrones estacionales considerados en la serie. U_t es el residuo.

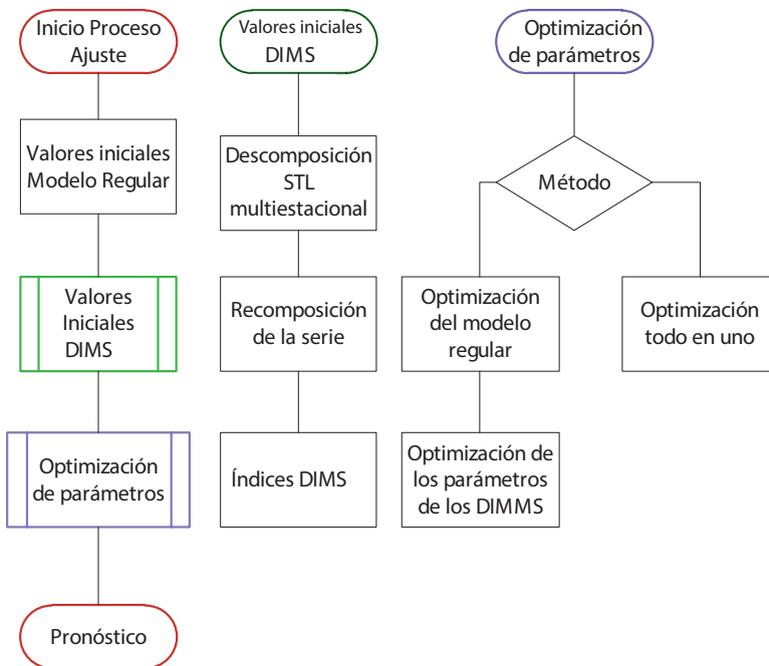


Figura 7.3. Diagrama de flujo para la utilización de los DIMS. En la parte izquierda se encuentra el diagrama troncal, y a su derecha se muestran los desarrollos de cada una de las macro etapas.

En un segundo paso, la serie se recompone de nuevo obteniendo la ecuación (7.12). Aquí es fundamental tener claro que el residuo no debe incluirse en la reconstrucción, puesto que la información que se pretende utilizar se encuentre en él.

$$R_t = T_t + \sum S_t^{(s_i)} \quad (7.12)$$

Aquí R_t es la serie recompuesta y sin incluir los residuos U_t . Finalmente, es necesario obtener los valores de los índices. Para ello se recurrirá a obtener primeramente los valores de los pesos de los valores de la serie sobre la serie reconstruida. En la Tabla 7.1 se puede apreciar cómo calcular los valores de los pesos. Esta tabla se organiza de modo que cada columna

representa cada una de las apariciones de la estacionalidad discreta. En filas se organiza cada uno de los datos observados en cada estacionalidad. La cantidad de datos necesario vendrá determinada por s_m^* .

Tabla 7.1. Cálculo de los pesos de los valores de la serie sobre la serie reconstruida. En las columnas se encuentra cada aparición del DIMS, y en las filas cada instante de tiempo dentro de la estacionalidad discreta.

	1	2	...	k
1	$\frac{X_{p_1}}{R_{p_1}}$	$\frac{X_{p_2}}{R_{p_2}}$		$\frac{X_{p_k}}{R_{p_k}}$
2	$\frac{X_{p_{1+1}}}{R_{p_{1+1}}}$	$\frac{X_{p_{2+1}}}{R_{p_{2+1}}}$		$\frac{X_{p_{k+1}}}{R_{p_{k+1}}}$
...
s_m^*	$\frac{X_{p_1+s_m^*-1}}{R_{p_1+s_m^*-1}}$	$\frac{X_{p_2+s_m^*-1}}{R_{p_2+s_m^*-1}}$		$\frac{X_{p_k+s_m^*-1}}{R_{p_k+s_m^*-1}}$

En la tabla, los valores de p_i son los instantes de tiempo múltiplos de cada estacionalidad, contados a partir del momento en el que se utiliza.

Una vez determinados los valores de los pesos, es necesario obtener los valores de los índices estacionales. Se recurrirá a la media aritmética para obtener los índices en cada instante de la estacionalidad discreta. En la Tabla 7.2 se observa cómo se obtienen los índices.

Tabla 7.2. Obtención de los índices estacionales a partir de las medias aritméticas de los pesos en cada instante de tiempo.

$$\begin{aligned}
 D_1^{(i)} &= \frac{1}{k} \left(\frac{X_{p_1}}{R_{p_1}} + \frac{X_{p_2}}{R_{p_2}} + \frac{X_{p_3}}{R_{p_3}} + \dots + \frac{X_{p_k}}{R_{p_k}} \right) \\
 D_2^{(i)} &= \frac{1}{k} \left(\frac{X_{p_1+1}}{R_{p_1+1}} + \frac{X_{p_2+1}}{R_{p_2+1}} + \frac{X_{p_3+1}}{R_{p_3+1}} + \dots + \frac{X_{p_k+1}}{R_{p_k+1}} \right) \\
 &\quad \dots \\
 D_{s_m^*} &= \frac{1}{k} \left(\frac{X_{p_1+s_m^*-1}}{R_{p_1+s_m^*-1}} + \frac{X_{p_2+s_m^*-1}}{R_{p_2+s_m^*-1}} + \dots + \frac{X_{p_k+s_m^*-1}}{R_{p_k+s_m^*-1}} \right)
 \end{aligned}$$

7.5.2. Optimización de los parámetros

Como en ocasiones anteriores, se introduce un nuevo parámetro de suavizado que es necesario optimizar. Esta optimización debe ser efectiva únicamente para el periodo de tiempo en el que el DIMS tiene influencia en la serie principal.

A fin de obtener los parámetros que mejor ajusten a los datos observados, se procede a minimizar el error de la previsión en un instante de tiempo posterior, utilizando cualquiera de los indicadores vistos anteriormente. En esta ocasión se minimizará el valor de la raíz cuadrada del valor medio del error cuadrático, RMSE.

Para optimizar los parámetros, se puede realizar según dos metodologías.

- La primera consiste en determinar todos los parámetros de forma simultánea, tal y como concluyen que es necesario Chatfield (1978) y Taylor (2003b).
- La segunda consiste en realizar una optimización del modelo regular, y posteriormente optimizar los parámetros de los DIMS.

7.6. Aplicación

Para comprobar la efectividad de la utilización de los DIMS en la previsión de demanda eléctrica ante sucesos especiales, se ha llevado a cabo la aplicación frente a diversos sucesos especiales, todos ellos sobre la serie de demanda eléctrica horaria en España. El periodo comprendido por la serie abarca desde el 1 de julio de 2007 hasta el 10 de septiembre de 2015.

7.6.1. Previsión de la demanda en una huelga

Una huelga se traduce en términos de estacionalidad discreta como una estacionalidad de periodicidad de 24 horas. Tiene además la particularidad de producirse en muy pocas fechas, con lo que la información disponible resulta ser escasa. La utilización de los DIMS para poder realizar una previsión de la demanda en un momento de huelga puede ayudar a entender su funcionamiento.

Las huelgas generales en España que se han producido en los últimos tiempos han sido en las fechas: 29 de septiembre de 2010, 13 de abril y 14 de noviembre del 2012.

Ya se ha visto cómo el efecto de una huelga afecta al comportamiento de la serie de demanda eléctrica en España (Figura 7.2). Se ha realizado el análisis utilizando los DIMS y modelos doble estacionales (periodicidad intradiaria, de 24 horas, y periodicidad intrasemanal, de 168 horas). Los DIMS se han establecido con longitud 24 horas, y con comienzo a las 00:00 horas del día de la huelga.

Con el fin de comprobar su funcionamiento en todos los métodos de tendencia y estacionalidad, se ha realizado un análisis con todos los modelos presentados en el capítulo relacionado con los modelos múltiple-estacionales. La optimización se ha realizado en dos pasos, y los resultados obtenidos se muestran en la Tabla 7.3.

Tabla 7.3. Comparativa de previsiones a 24 horas utilizando los DIMS frente a los modelos regulares. En esta comparación, se utiliza el MAPE(%) a 24 horas para comparar la precisión de los modelos.

	MAPE(%)					
	AMC	AAC	MAC	MMC	NMC	NAC
NORMAL	10,57	9,61	9,59	10,34	12,48	9,12
CON DIMS	2,56	3,27	3,27	7,82	7,86	3,99

En esta tabla se presentan los MAPES obtenidos en la previsión a 24 horas del 14 de noviembre de 2012. Para el cálculo, se ha utilizado en todos los casos los valores desde el 1 de julio de 2007 hasta el día anterior de la huelga. Esto indica que se ha utilizado la información de las dos huelgas anteriores. Se puede apreciar cómo los modelos regulares, normales, no son capaces de adaptarse a lo sucedido en la huelga. Los MAPES se disparan de un valor regular de 2-5% a valores por encima del 9%. Sin embargo, los valores obtenidos utilizando DIMS se reducen a valores en torno al 3%. En algunos casos los modelos no han respondido bien en general, independientemente de utilizar DIMS o no, aunque siempre resulta positivo su uso y se mejora la previsión.

Para una mayor comprensión, en la Figura 7.4 se muestra la previsión de forma gráfica comparada con la demanda real habida en el día de huelga.

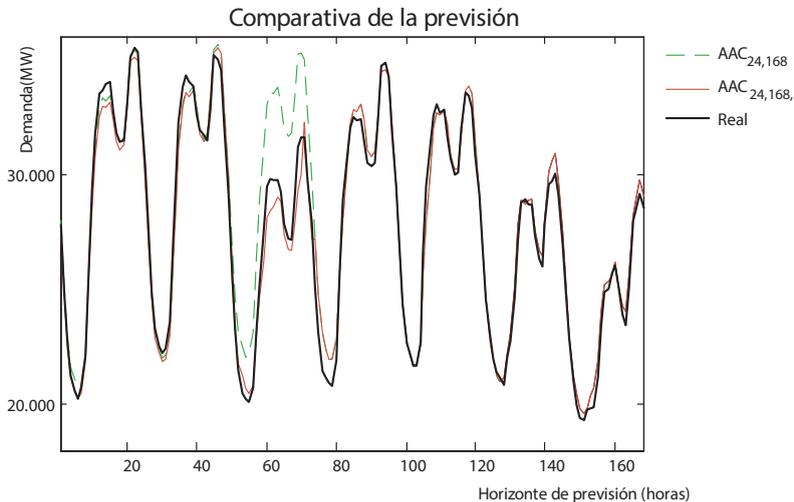


Figura 7.4. Comparativa de previsión a 24 horas para el modelo $AAC_{24,168}$ (línea discontinua) frente al modelo $AAC_{24,168,DIMS}$ que incluye los DIMS (línea llena). La demanda real se muestra con la línea gruesa. Se aprecia fácilmente como la previsión realizada por el modelo que utiliza DIMS es mucho más precisa que la que no lo lleva.

La gráfica realiza una comparativa entre la previsión realizada con el modelo $AAC_{24,168}$, que se muestra con línea discontinua, frente a la demanda real (con línea gruesa). El modelo no es capaz de atender la irregularidad producida por la huelga. La introducción de los DIMS genera previsiones más precisas, y en este caso, el modelo $AMC_{24,168,DIMS}$ mejora notablemente el resultado obtenido por el modelo anterior (línea negra fina).

7.6.2. Previsión de la demanda en fiestas de Pascua

Un evento de especial dificultad para realizar la previsión de la demanda eléctrica es la Pascua. En España, la Pascua es cristiana, y, por lo tanto, tiene un calendario que varía dependiendo del año, determinando el domingo de Pascua cada año. La determinación de la fecha exacta, en general responde a los siguientes criterios:

- Debe ser posterior al equinoccio de primavera.
- Posterior a la primera luna llena.
- El primer domingo que ocurra.

A partir de ahí se fijan los días de pascua, así como otros eventos religiosos, que carecen de interés en este momento. El hito principal lo marca el domingo de resurrección, a partir del cual se establece el viernes santo, que es festivo en casi todas las comunidades autónomas. Posteriormente, el jueves santo no es festivo en general, aunque muchos colectivos los disfrutan. El lunes de Pascua es un caso particular: en varias regiones es fiesta de forma general, y en algunas depende del año.

En la Tabla 7.4 se muestra las fechas de las Pascuas desde el 2008 hasta el 2015. Estos son los días que se va a utilizar la información para realizar el análisis.

Tabla 7.4. Periodos de Pascua en España. Comienza con el domingo de ramos y termina con el domingo de resurrección. En la tabla se muestran las fechas de estos eventos desde el 2008 hasta el 2015.

<u>Año</u>	<u>Domingo de ramos</u>	<u>Domingo de resurrección</u>
2008	16 marzo	23 marzo
2009	5 abril	12 abril
2010	28 marzo	4 abril
2011	17 abril	24 abril
2012	1 abril	8 abril
2013	24 marzo	31 marzo
2014	13 abril	20 abril
2015	29 marzo	5 abril

En primera instancia, se observa la demanda eléctrica horaria en España en la Figura 7.5, donde se refleja la demanda en las fechas de Pascua y la demanda generada en días adyacentes. Se puede observar fácilmente como el patrón regular de la serie se ve interrumpido en los días de Pascua. Además, se observa como en general el periodo del nuevo patrón comienza en el jueves santo y se extiende hasta el lunes de Pascua. Sin

embargo, no es descabellado pensar que toda la semana puede estar influenciada por la Pascua.

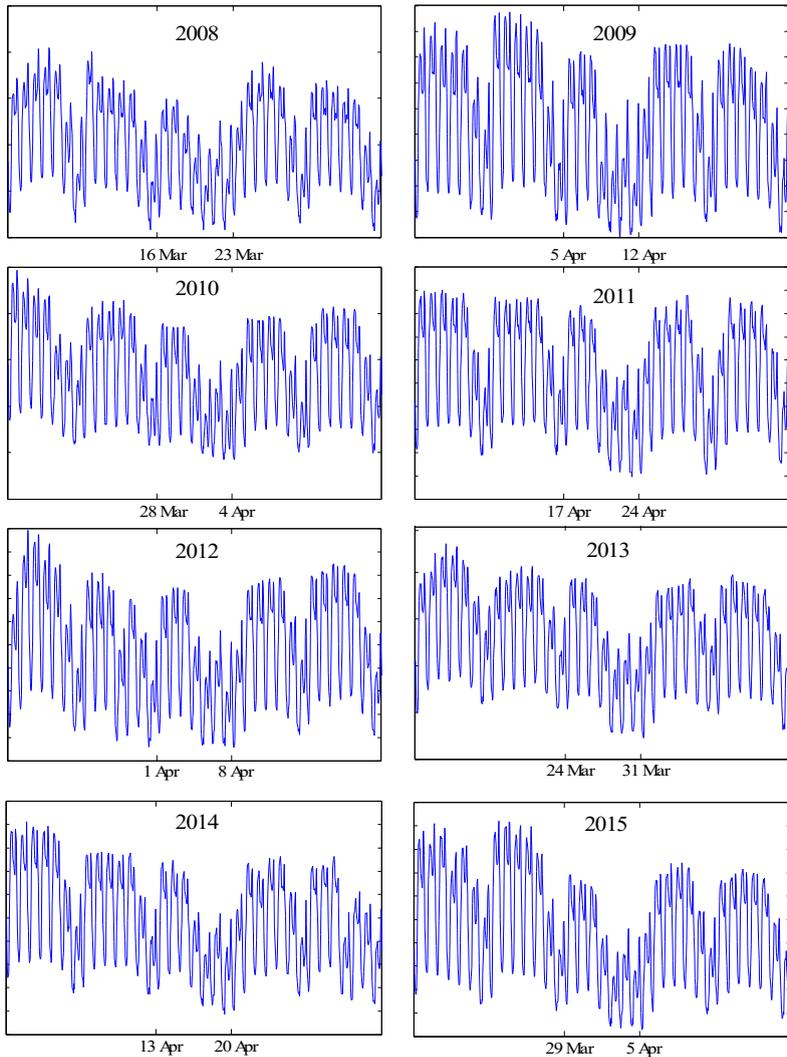


Figura 7.5. Comportamiento especial de la demanda eléctrica horaria en España en periodos de Pascua en los últimos años. Cada gráfica muestra la demanda en periodos adyacentes a las Pascuas y en dicho periodo.

Todo ello lleva a realizar un estudio en el que se presentan varios elementos que pueden influir en el éxito de la utilización de los DIMS para mejorar la previsión de la Pascua. Así pues, por un lado, se analizan los diferentes tipos de optimización, tanto la optimización en dos pasos, como la de todos los parámetros simultáneamente. En referencia a la longitud del DIMS y fecha, se consideran las opciones de comenzar la misma semana en lunes, miércoles y jueves, y considerando que el lunes puede estar incluido o no en la previsión. Esto se refleja en la Tabla 7.5 como periodo.

Tabla 7.5. Marco del análisis. Dos tipos de optimización, y diferentes fechas de inicio y longitud de la estacionalidad. Adicionalmente, dos métodos son estudiados.

Resumen del análisis		
Optimización de Parámetros	Todos a la vez M1	En dos pasos M2
Periodo	Empezando en	Longitud
1	Lunes después del domingo de Ramos	192 h
2	Jueves Santo	120 h
3	Miércoles	96 h
4	Miércoles	120 h
Modelos	AMC	AAC

Para ver la influencia sobre los diferentes métodos de suavizado, se ha realizado el análisis con dos modelos: AMC y con AAC, ambos con dos estacionalidades, 24 y 168 horas. El resumen de los parámetros del análisis se muestra en la Tabla 7.5. El motivo de utilizar únicamente dos estacionalidades responde al hecho de que integrar una tercera estacionalidad en el modelo no suele traer beneficios a la previsión a no ser que ésta esté trabajada y depurada, y sin embargo puede perjudicar a la utilización de los DIMS, ya que eliminaría del residuo una parte importante del cálculo.

Tabla 7.6. MAPE obtenido en previsiones a 24 horas durante las Pascuas. Las cabeceras de las columnas indican el modelo, AMC o AAC, y las variantes. Estas son 0 para el modelo regular (sin DIMS), mientras que el resto se corresponde al periodo utilizado. Sólo se muestran el caso 1 y 2 porque el resto no ha proporcionado mejores resultados. Dentro de cada caso, además se muestra el resultado según el método utilizado. En la Tabla 7.5 se muestran las descripciones para cada caso.

MODELO		AMC _{24,168}				MAPE (%)
VARIANTE		CASO 0	CASO 1	CASO 2, M2	CASO 2, M1	
Jueves	17/04/2014	13,12	3,05	2,73	2,79	
Viernes	18/04/2014	11,38	1,74	2,41	3,06	
Sábado	19/04/2014	10,97	1,68	1,44	1,58	
Domingo	20/04/2014	3,25	1,65	1,88	4,04	
Lunes	21/04/2014	4,94	6,25	3,57	7,02	
Jueves	02/04/2015	11,35	2,90	2,79	3,07	
Viernes	03/04/2015	10,66	3,44	1,55	2,62	
Sábado	04/04/2015	10,51	1,10	2,58	2,04	
Domingo	05/04/2015	3,60	2,56	1,53	2,47	
Jueves	06/04/2015	5,91	1,51	3,93	4,69	

MODELO		AAC _{24,168}			MAPE (%)
VARIANTE		CASO 0	CASO 1	CASO 2, M2	
Jueves	17/04/2014	12,25	6,42	5,90	
Viernes	18/04/2014	14,22	1,79	2,39	
Sábado	19/04/2014	11,34	1,40	1,28	
Domingo	20/04/2014	5,85	4,33	4,67	
Jueves	21/04/2014	5,80	4,87	5,06	
Jueves	02/04/2015	12,02	5,47	4,81	
Viernes	03/04/2015	12,82	0,97	1,13	
Sábado	04/04/2015	10,32	2,64	2,45	
Domingo	05/04/2015	4,86	3,11	3,44	
Jueves	06/04/2015	7,40	2,84	3,04	

Los resultados obtenidos se muestran en la Tabla 7.6. Se puede apreciar como la introducción de los DIMS en cualquiera de sus modalidades ha mejorado el resultado en la precisión de la previsión.

En esta tabla se muestran únicamente los mejores resultados. El resto de resultados obtenidos se han omitido porque, aunque siguen mejorando la precisión, no lo hacen en la misma magnitud.

Tabla 7.7. Comparativa del MAPE para previsiones de 168 horas en adelante entre los modelos regulares nHWT y los nuevos propuestos con DIMS. La columna de cabecera indica el día para el cual se realizó la previsión.

	MAPE(%)	
	REGULAR	DIMS
17/4/14	7,67	5,68
18/4/14	9,06	4,60
19/4/14	20,00	5,96
20/4/14	8,04	9,21
21/4/14	6,47	12,29
2/4/15	7,44	5,63
3/4/15	10,48	5,42
4/4/15	21,92	7,30
5/4/15	9,69	10,69
6/4/15	7,57	13,05

Por último, hay que reseñar que, en la previsión del lunes, la precisión del modelo se reduce frente a la realizada por el modelo estándar. Este fenómeno se produce porque en los diferentes años utilizados por el modelo para el ajuste, el lunes no es un día festivo en todas las comunidades autónomas. Ello provoca otro tipo de irregularidades en la serie de más difícil comprensión. Por lo tanto, el resultado de la previsión es difícil que se acerque a valores muy reducidos. Otra característica es que el domingo es un día donde siempre es festivo, y que, por lo tanto,

la variación entre un domingo “normal” y un domingo de Pascua debe ser mínima. Sin embargo, se aprecia como la utilización de DIMS mejora el resultado, dejando en evidencia que no es un domingo cualquiera. Se puede observar en la Tabla 7.7 como los resultados mejoran en casi todos los aspectos.

También se ha analizado la previsión a un plazo más largo, con el fin de observar el comportamiento de la serie. Al realizar la previsión a más largo plazo, el modelo con DIMS se muestra inestable. Finalmente, en la Figura 7.6, se muestra de nuevo las previsiones realizadas a 24 horas con el modelo seleccionado, el $AMC_{24,168}$ tanto en la versión que incorpora las DIMS como la que no.

Se puede apreciar como la línea azul, representada por las previsiones realizadas con el modelo regular, se distancia de la demanda real cada día de la previsión, porque no es capaz de tratar la irregularidad por las Pascuas. En cambio, la línea roja que representa el mismo modelo, pero incluyendo las DIMS, es capaz de tratar con la irregularidad, y prácticamente solapa la línea real.

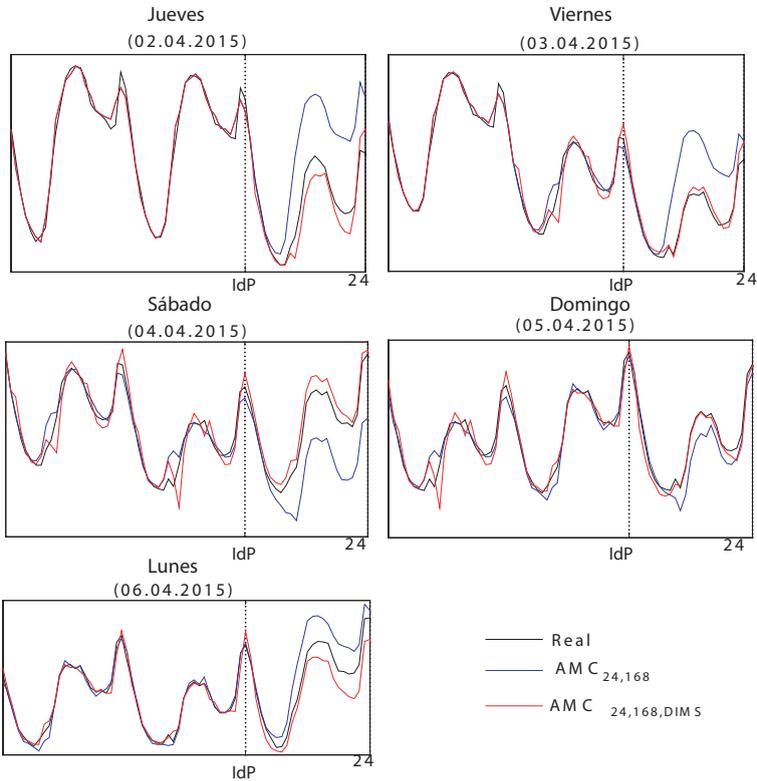


Figura 7.6. Previsiones de 24 horas en delante de los modelos nHWT regulares y los modelos nHWT con DIMS propuestos. Las previsiones se muestran a partir del inicio de la previsión (IdP).

7.6.3. Previsión de la demanda en días festivos

El modelo puede aplicarse para cualquier situación en la que el efecto calendario tenga efecto real sobre la serie de demanda. Como ejemplo de aplicación, se han tomado las festividades nacionales de los últimos años, y se han realizado comparativas entre la demanda prevista por el método regular (nHWT) y el método propuesto.

Contrariamente a lo descrito en Cancelo, Espasa y Grafe (2008) y más cercano a lo expuesto por Bermúdez (2013) donde

se utiliza una variable de regresión para cada día festivo, se ha optado por la simplicidad del modelo y se ha optado por considerar únicamente 2 DIMS, uno para la Pascua, y otro para el día festivo, sea cual fuere el día y posición.

Para llevar a cabo este análisis, se han considerado únicamente aquellos festivos de ámbito nacional, puesto que se ha aplicado a la serie de demanda eléctrica agregada para la península. Es cierto que algunos festivos de carácter regional, como aquellos producidos en la Comunidad de Madrid o en Cataluña pueden tener influencia en el ámbito estatal, y podrían modelizarse del mismo modo que se describe en este trabajo, pero no se han considerado necesarios en este momento. Por lo tanto, se toman como eventos especiales las festividades de la Asunción de la Virgen María (15 de agosto), Día de la Hispanidad (12 de octubre), Todos los Santos (1 de noviembre), Día de la Constitución (6 de diciembre), Día de la Inmaculada Concepción (8 de diciembre), Natividad del Señor o Navidades (25 de diciembre), Año Nuevo (1 de enero) y Epifanía del Señor o Día de Reyes (6 de enero). Adicionalmente, se ha considerado la opción de incluir en el análisis el día de Fin de Año (31 de diciembre), al ser únicamente parcial el trabajo, y no incluir el día 1 de mayo (Día del trabajador) por ser redundante con los anteriores. Ello permite comprobar el resultado de las previsiones en días con características similares, pero no iguales (como el día de Fin de Año).

Tabla 7.8. Resumen de los MAPE de previsión a 24 horas obtenidos en las fechas indicadas.

Festividad	Fecha	Años	Día de la semana	No festivo	Regular	2-pasos	simultáneo
Asunción	15-ago	2015	Domingo	x	4,393	4,392	4,335
		2016	Lunes		10,945	5,154	3,244
		2017	Martes		8,944	4,229	5,089
Hispanidad	12-oct	2015	Lunes		12,176	4,507	4,225
		2016	Miércoles		11,649	3,974	4,048
		2017	Jueves		12,071	3,345	3,747
Todos los santos	1-nov	2015	Domingo	x	3,952	3,951	3,938
		2016	Martes		10,116	8,905	3,331
		2017	Miércoles		12,741	3,505	5,589
Constitución	6-dic	2015	Domingo	x	4,296	4,096	4,244
		2016	Martes		10,143	4,095	11,374
		2017	Miércoles		10,701	3,481	3,261
Inmaculada	8-dic	2015	Martes		9,238	5,398	6,661
		2016	Jueves		9,386	4,269	4,389
		2017	Viernes		7,461	5,234	3,999
Navidad	25-dic	2015	Viernes		13,391	5,797	4,970
		2016	Domingo	x	7,445	7,452	7,397
		2017	Lunes		18,209	8,122	5,844
Fin de año	31-dic	2015	Jueves		6,002	6,878	6,413
		2016	Sábado	x	3,230	3,228	3,442
		2017	Domingo	x	3,760	4,745	4,677
Año nuevo	1-ene	2016	Viernes		12,355	7,013	4,038
		2017	Domingo	x	7,013	7,013	7,083
		2018	Lunes		18,045	7,685	5,423
Reyes	6-ene	2016	Miércoles		11,520	11,677	3,236
		2017	Viernes		12,037	4,545	4,820
		2018	Sábado	x	5,568	6,002	6,070

La Tabla 7.8 resume el análisis realizado. Se muestra los días considerados y el año.

Los días festivos tienen su influencia en la serie de demanda dependiendo del día de la semana en que caigan. Por ejemplo, un día 1 de enero en miércoles tiene mayor influencia que un día 1 de enero en sábado o domingo. Esto se refleja en la columna “No Festivo”, donde los días marcados con “X” son días en los que no debe considerarse la estacionalidad discreta debido a esta circunstancia.

Esto es importante, porque la estacionalidad discreta sólo debe tener efecto en los días aquellos que suponga una variación respecto de la demanda habitual esperada, si fuera un día normal. Por otro lado, existen días en los que la festividad, al caer en un domingo, se traslada al lunes. Esto también se ha considerado y ejecutado, aunque no se refleja en la tabla, por cuestiones de espacio. Los resultados obtenidos son similares.

En la tabla se muestra el MAPE de la previsión del modelo nHWT y de los DIMS, ejecutados tanto en dos pasos como de forma simultánea. Se observa que los días en los que ocurre un festivo, la serie normal eleva el valor del MAPE hasta alcanzar valores no deseados, mientras que la utilización de los DIMS permite mantener estable la previsión. La reducción en el MAPE no se realiza de la misma forma en todos los casos. En el caso del 12 de octubre el MAPE desciende desde un 12% con el método regular hasta valores medios del 4%, habiendo grandes diferencias dependiendo del año y del método. En esta ocasión el método de optimización en dos pasos ha ofrecido mejores resultados que la optimización de todos los parámetros de forma simultánea. Esta parece ser la tónica generalizada, aunque cuando hablamos de los días de diciembre – por otra parte, los más complicados de realizar previsiones – el método de obtener los parámetros de forma simultánea ofrece mejores resultados. No parece haber un motivo claro, y no se está en condiciones de asegurar el motivo, pero parece evidente que aquellas situaciones donde los días festivos se encuentran más aislados parecen tener mejor previsión utilizando optimización en dos pasos. Sin embargo, las situaciones de diciembre, donde existen muchos

días anteriores con festividades, se obtienen mejores resultados con la optimización “todo en uno”.

Las Figura 7.7a a Figura 7.7d, muestra algunos ejemplos de previsión seleccionados. En la Figura 7.7a se muestra el caso de un día no festivo (el 16 de agosto de 2014 cayó en domingo) y cómo la previsión del modelo incluyendo los DIMS es similar a la del modelo regular. En esta ocasión, las previsiones deben ser semejantes y se comprueba que la inclusión de los DIMS en el modelo no distorsiona los resultados obtenidos.

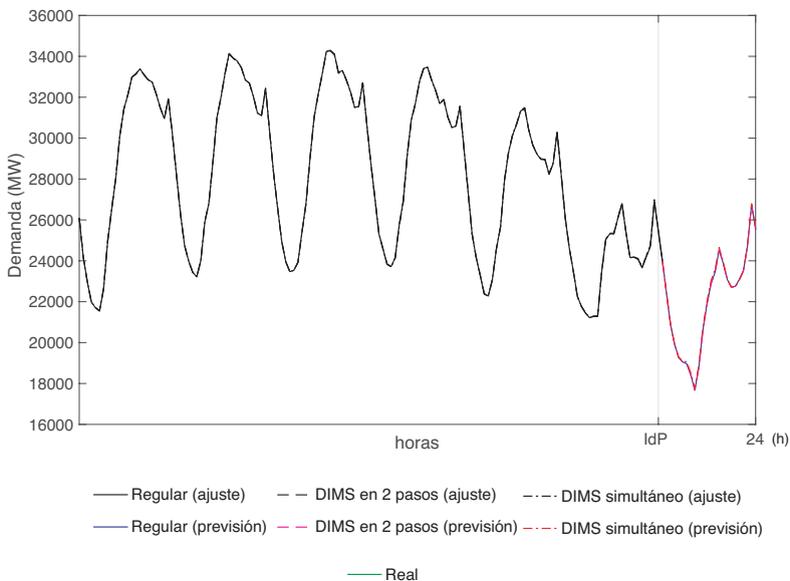


Figura 7.7a. Comparativa de la previsión de 16 de agosto de 2014, domingo.

En la Figura 7.7b es el caso de un día como el de todos los santos, que en esta ocasión (1 de noviembre de 2017) ocurrió en jueves. Se puede observar como el modelo regular no es capaz de tratar esta demanda anómala, mientras que los métodos con DIMS se acercan al valor real. Este ejemplo permite observar como para casos en los que un día aislado ocurre, esta metodología funciona correctamente.

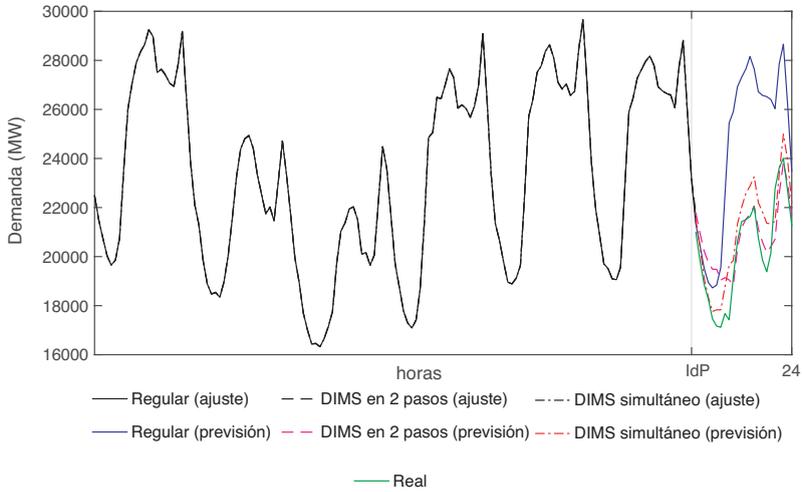


Figura 7.7b. Comparativa de para el día de todos los santos (1 de noviembre de 2017).

El caso de la Figura 7.7c permite comparar un día significativo como es el día de Navidad (25 de diciembre de 2015) que se encuentra inmerso en una semana (o quincena de cambios constantes debido a la Navidad). De hecho, se puede observar cómo al caer viernes, el día anterior, Nochebuena, también tiene una demanda particular. Sin embargo, el método trabaja correctamente, ofreciendo buenos resultados.

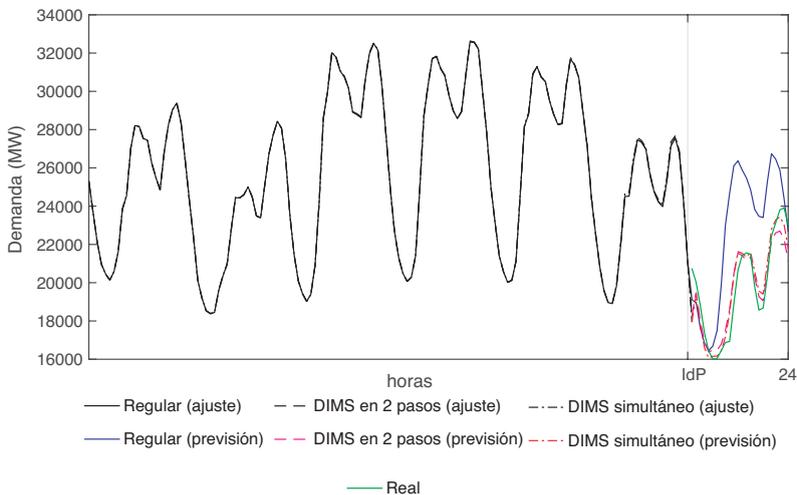


Figura 7.7c. Comparativa de para el día de Navidad, 25 de diciembre de 2015.

El caso de la Figura 7.7d muestra el primer día del año. De forma semejante al día de Navidad, inmerso en semanas de vacaciones. El día de fin de año suele ser similar al de Nochebuena, con trabajo a media jornada.

Como se ha comentado anteriormente, se ha considerado únicamente una estacionalidad discreta para todos los días festivos. El hecho de no aumentar la cantidad de estacionalidades se debe a que la capacidad de cálculo requerida es mucho menor, mientras que los resultados obtenidos son suficientes para demostrar el buen desarrollo del método. Los días comentados de Nochebuena y fin de año pueden también caracterizarse del mismo modo, con su particular estatus de día a media jornada. Del mismo modo, los días de puentes, o jornadas festivas en comunidades autónomas como Madrid o Catalunya, que tienen una influencia significativa en la demanda eléctrica en España también pueden modelizarse de este modo.

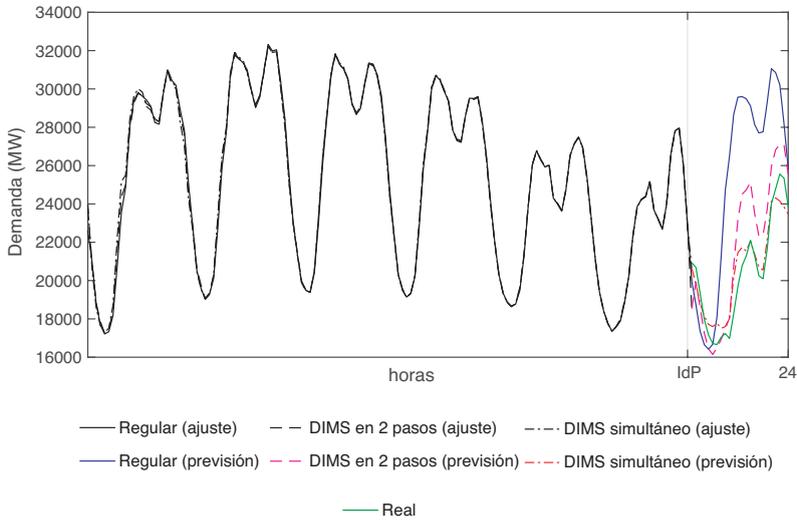


Figura 7.7d. Comparativa de para el día de año nuevo (1 de enero de 2017).

7.7. Discusión de los resultados

En este capítulo se han presentado un nuevo modelo para trabajar con las irregularidades de las series temporales asociadas a eventos especiales. Este nuevo método introduce en el modelo lo que se ha denominado estacionalidades móviles de intervalo discreto, DIMS (Discrete-Interval Mobile Seasonalities). A diferencia de otros métodos, esta estacionalidad forma parte intrínseca del modelo, y no es un elemento que modifica el modelo a posteriori.

También se ha presentado la metodología de trabajo mediante estos modelos.

Posteriormente se ha utilizado estos nuevos modelos para los casos en concreto:

- Huelgas, donde se exhiben pocas apariciones de los eventos especiales, y de un periodo de 24 horas. Las huelgas además no tienen una posición fija en la serie temporal.
- Pascuas, que se producen de forma anual, y que cada año varía su posición en la serie temporal. Las Pascuas tienen la particularidad de tener una periodicidad más larga, y que se ha determinado ser el valor ideal de 120 horas.
- Festividades. Son de especial atención los días festivos y el efecto calendario en la serie. Son periodos de 24 horas cuya posición en la serie varía de año en año, pero con gran influencia en el resultado de la previsión.

En ambos casos, la introducción de las DIMS ha mejorado la precisión de las previsiones, reduciendo en algunos casos en más de un 50% los MAPE(%). Así pues, para el caso de las huelgas, se pasa de un 10% a un 3%, mientras que, para las pascuas, se pasa de entre un 10% a 13% hasta un 5% a 3%. Del mismo modo, para los días festivos, el nivel de precisión en las previsiones se mantiene alrededor del 3-4%, cuando un modelo regular es inestable, y puede alcanzar valores de más de un 10% en MAPE.

No obstante, existen limitaciones técnicas para el completo desarrollo de los DIMS, puesto que la introducción de una nueva estacionalidad limita la capacidad de cálculo del ordenador. En futuros trabajos, con mejores capacidades de cálculo, es posible distinguir entre varios tipos de festividades, así como tener en cuenta los días de la semana en la que se producen.

8. Modelos de Holt-Winters con indicadores turísticos

8

8.1. Introducción

Este capítulo presenta un nuevo modelo nHWT en el que se introduce una variable explicativa exógena relacionada con el turismo para mejorar las previsiones de la demanda eléctrica en las Islas Baleares. Se utiliza un indicador turístico proporcionado por el Institut d'Estadística de les Illes Balears (IBESTAT) con el cual se mejoran los resultados de la previsión respecto de los modelos habituales.

El capítulo se organiza del siguiente modo: primeramente, se presenta una justificación del análisis realizado en este capítulo. Seguidamente se realiza una revisión bibliográfica del tema tratado, y se analiza la demanda eléctrica en las islas de Mallorca y Menorca, con las posibles relaciones con otras variables. A partir de este estudio, se describe el indicador de presión humana y se introduce este indicador dentro del modelo. Finalmente se aplica este nuevo modelo a la serie de demanda eléctrica horaria en Mallorca y Menorca y se analizan los resultados. Por último, se resumen las conclusiones alcanzadas de este estudio.

8.2. Justificación

La necesidad de mejorar las previsiones en la demanda eléctrica en un destino como en les Illes Balears, ligado al turismo, resulta

de vital importancia. En las islas, la generación de electricidad se realiza mayoritariamente mediante combustibles fósiles, y la demanda aumenta en las fechas de mayor afluencia turística. El mix de producción debe ajustarse en la mayor medida posible a la demanda, y se necesitan modelos que sean capaces de mejorar las previsiones de consumo. Se plantea en este capítulo utilizar esa relación entre los consumos eléctricos y la afluencia de turistas para mejorar las previsiones.

Basándose en el trabajo de Bakhat y Roselló (2011), el objetivo de este capítulo es integrar en un modelo la información contenida en un indicador turístico, relacionado con la población, que permita realizar una mejora en las previsiones de los modelos de Holt-Winters de forma horaria y reducir de esta forma el coste económico y medioambiental.

8.3. Revisión bibliográfica

El impacto producido por el turismo suele medirse como positivo en el ámbito económico, ya que produce ingresos no sólo por las pernoctaciones, sino también por las actividades desarrolladas. Sin embargo, el análisis del impacto provocado no debería centrarse únicamente en el económico, sino también en el social y medioambiental (Gray y Bebbington 2001; Rubio Gil y Mazón Martínez 2009; Archer, Cooper, y Ruhanen 2005). La concentración del turismo en zonas delimitadas y el volumen de turistas congregados supone además un incremento de la presión realizada sobre el medioambiente (Zhang et al. 2018). El incremento continuo de visitantes empeora aún más esta situación. La Islas Baleares son un claro ejemplo de esta situación.

Esta presión se transmite también a la generación y distribución de energía eléctrica. Becken y Simmons (2002) analizan cómo se comporta la demanda eléctrica en zonas turísticas como Nueva Zelanda y Gössling indica cuáles son los daños potenciales que pueden producirse por el efecto del turismo (Gössling et al. 2002; Gössling 2002). Aunque siempre se ha

relacionado la contaminación y las emisiones de CO₂ con el transporte, ya que este genera aproximadamente el 60% de las emisiones (Scott, Hall, y Gössling 2016; Scott et al. 2016), es cierto que la producción de energía genera una gran parte de las mismas. Algunos autores relacionan las emisiones y el consumo energético con la afluencia de turistas (Katircioglu, Feridun, y Kilinc 2014), que alcanzan hasta un 5% de las emisiones globales (Rutty et al. 2015; Pablo-Romero, Pozo-Barajas, y Sánchez-Rivas 2017).

Por lo tanto, la previsión de demanda eléctrica se convierte en un factor fundamental para la correcta gestión económica y medioambiental. Cualquier imprecisión en la demanda supone que los equipos de generación se reorganicen, dando preferencia a los generadores con combustible fósil, y aumentando las emisiones, además de las pérdidas económicas que ello supone. Se estima que un 1% de error en la precisión puede suponer pérdidas de entre cientos de miles a millones de dólares (Hobbs 1999). Hong (2015) determina que en una estación de generación de 1GWh de pico, una mejora del 1% en el desfase entre demanda y producción supone una mejora de unos 600.000 dólares anuales. No se conoce de la existencia de cálculos del mismo tipo para las emisiones de CO₂, aunque a partir de los datos de REE, se estima un 2% de error en la previsión genera 1 tonelada de CO₂/hora adicional.

Los gestores del sistema de transporte como REE utilizan herramientas de series temporales para la previsión de demanda eléctrica. Weron (2006) recopila los métodos habituales para la previsión de demanda. Los métodos habituales incluyen modelos de regresión, modelos ARIMA, modelos de Holt-Winters con una única estacionalidad y, más extensamente, modelos de inteligencia artificial con redes neuronales. Generalmente los modelos utilizados por los TSO no son publicados, ya que son con licencia propietaria, pero suelen ser una combinación de diferentes métodos (Suganthi y Samuel 2012). En cualquier caso, los modelos de Holt-Winters, incluidos los doble estacionales, suelen proporcionar los mejores resultados (Taylor 2008). En el

caso de REE, los modelos son complejos y requieren de una metodología de tratamiento de la información (López et al. 2018). La relación de la demanda con temperaturas y sectores productivos ha sido analizado por Moral-Carcedo en varios trabajos (Pérez-García y Moral-Carcedo 2016; Moral-Carcedo y Pérez-García 2015). Ello permite determinar que existe una relación entre la demanda y los diversos factores a analizar.

La introducción de variables exógenas en los modelos de Holt-Winters no es trivial. La utilización de modelos multivariados permite relacionar variables exógenas con las variables del modelo (Bermúdez, Corberán-Vallet, y Vercher 2009a; Pfeiffermann y Allon 1989; Corberán-Vallet, Bermúdez, y Vercher 2011). Pero no integran la información en el mismo modelo.

Bermúdez (2013) introduce el uso de covariables en los modelos de suavizado exponencial aplicado a la demanda eléctrica, que otros autores posteriormente también utilizan (Göb, Lurz, y Pievatolo 2015; Osman y King 2015; Wang 2006). En este trabajo, la asignación de los días festivos se realiza de forma cualitativa y no binaria, como con el uso de variables ficticias.

López et al. (2017) analizan la relación de la demanda eléctrica en las Islas Baleares con la temperatura. Para la predicción en las Islas Baleares, Bakhat y Roselló (2011) proponen un modelo de regresión en el que se incluyen variables meteorológicas pero también de otra índole, como indicadores turísticos.

8.4. Demanda eléctrica en Mallorca y Menorca

Para llevar a cabo este análisis, se ha utilizado la serie de demanda eléctrica de Mallorca y Menorca, en un periodo que comprende desde mayo del 2013 hasta octubre de 2016. Estos datos han sido proporcionados por REE a través de su Web, y se utilizan directamente, sin modificaciones. En la Figura 8.1 se representa dicha demanda.

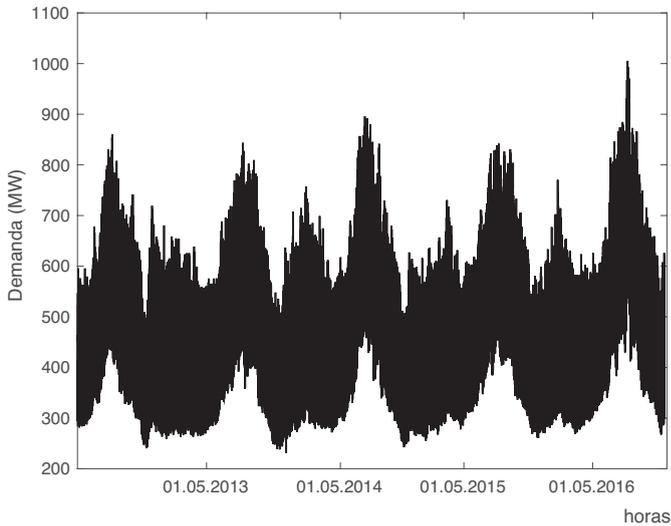


Figura 8.1. Demanda eléctrica horaria en la isla de Mallorca.

Se puede apreciar cómo tiene un perfil típico de demanda donde en esta ocasión los picos máximos coinciden con el verano. Existe otra serie de picos que coinciden con la época de Pascua. Estos picos se deben a la influencia del turismo en la actividad de la isla.

Para comprobar el hecho de la influencia del turismo sobre la curva de demanda eléctrica, se muestra la Figura 8.2, donde se representa el peso del turismo sobre el PIB. A título comparativo, se muestra el PIB turístico de España y el de las Islas. Se puede apreciar cómo el peso que tiene en las Islas alcanza valores de hasta el 45%, mientras en España alcanza el 11%. Esto provoca una dependencia de la demanda respecto del turismo poco usual, que la hace diferente de la demanda peninsular.

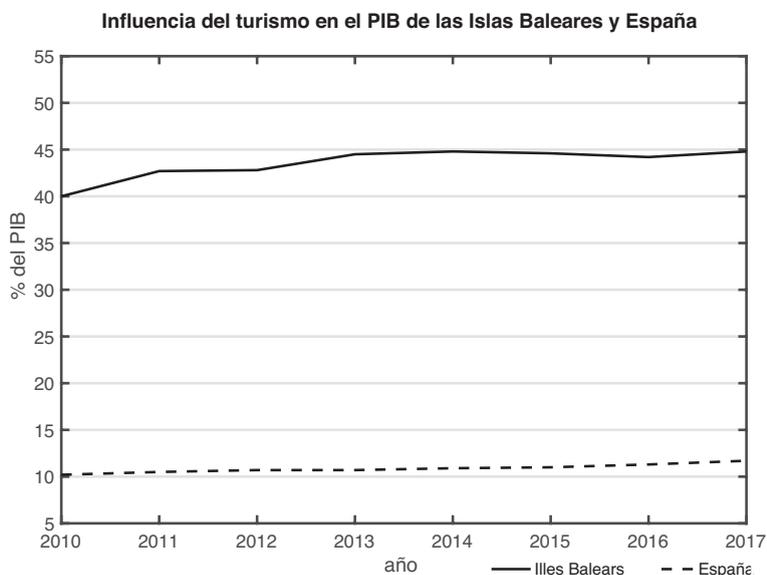


Figura 8.2. Comparativa y evolución del PIB turístico en España y en las Islas Baleares. Fuente: Elaboración propia a partir de datos de Exceltur.

En cuanto a emisiones y contaminación, Herce (2008) analiza la economía de las Islas Baleares, y su relación con la generación de electricidad. Destaca cómo las emisiones de CO₂ aumentaron hasta en un 62% en el periodo de 1990 a 2005 debido a la utilización de unidades de generación de combustible fósil.

Esta situación llevó a la administración a realizar el “Plan Director Sectorial Energéticos de les Illes Balears”, (Decreto 96/2005, de 23 de septiembre, de aprobación definitiva de la revisión del Plan Director Sectorial Energético de las Illes Balears) con el objetivo de reducir las emisiones. Las principales actuaciones fueron instalar un cable de transmisión submarino, y fomentar el uso de renovables. Se consiguió reducir las emisiones. Sin embargo, tal y como se aprecia en la Figura 8.3, estas emisiones han ido en continuo aumento, debido entre otros, al aumento de la demanda y la producción mediante las centrales de combustible fósil.

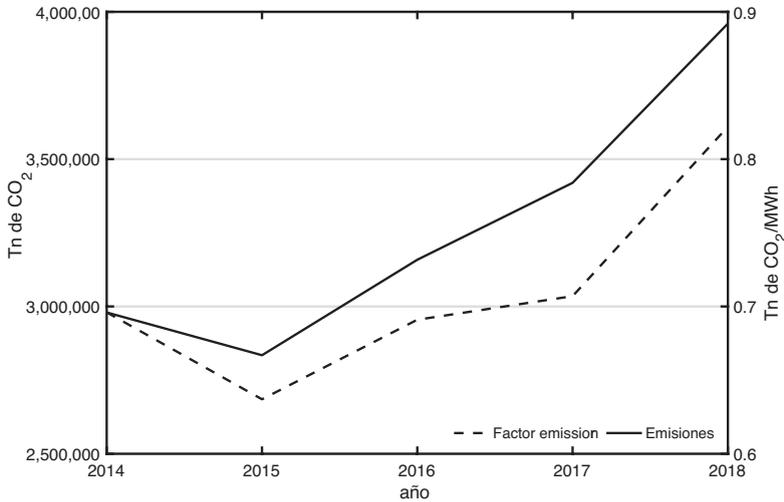


Figura 8.3. Emisiones de CO₂ en las Islas Baleares en el periodo de 2014 a 2018 debido a la generación de electricidad. El factor de emisión se mide como el cociente entre las emisiones por energía conseguida.

Se puede comprobar en la Figura 8.4, donde se muestra la distribución de la generación de electricidad en las islas en el mismo periodo. Se aprecia como la utilización de centrales de carbón no ha menguado, sino más bien incrementado su producción, a pesar de contar con centrales menos contaminantes y alternativas renovables. Otros autores analizan una situación semejante en las islas británicas y concluye que no hay un camino claro a seguir, ya que existen muchas restricciones para no evitar el uso de las centrales de combustible fósil (Pfenninger y Keirstead 2015). El crecimiento de la generación eléctrica viene acompañado por un incremento de turismo en las islas, y del impacto ejercido.

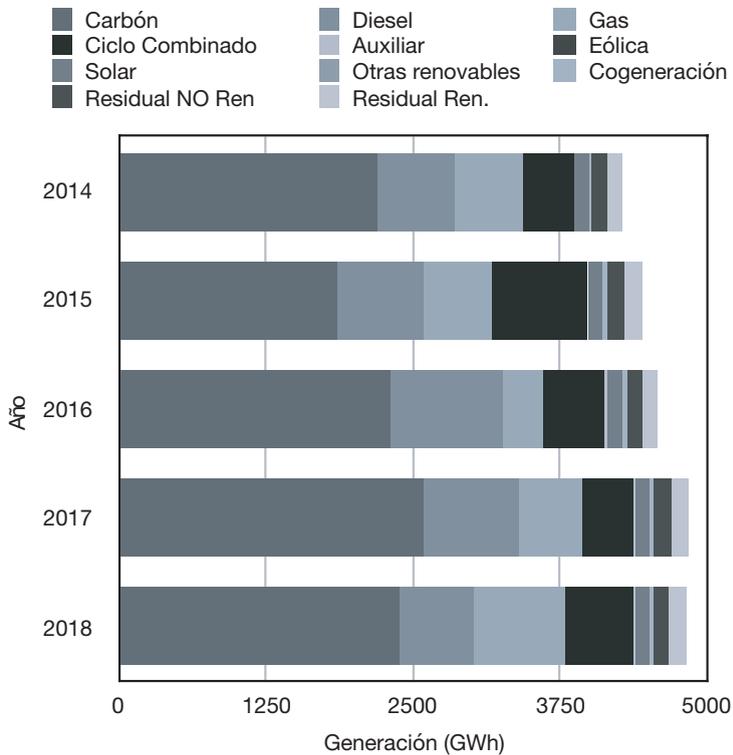


Figura 8.4. Mix energético de la producción eléctrica en la Islas Baleares.

Para paliar esta situación, cabe la posibilidad de mejora de las emisiones y de los aspectos económicos utilizando un modelo mejorado de demanda, que sea capaz de relacionar la demanda con la actividad turística.

8.5. Indicador de presión humana

Las islas tienen la característica de poder controlar eficientemente las entradas y salidas al realizarse únicamente por vía marítima o aérea. El balance de la llegada de turistas puede observarse en la Figura 8.5. Se observa un crecimiento continuado a lo largo de los años. El IBESTAT publica un indicador con carácter diario y

mensual que interpreta los datos obtenidos en la gráfica y considera las entradas y salidas de las islas además de tener en cuenta la población residente.

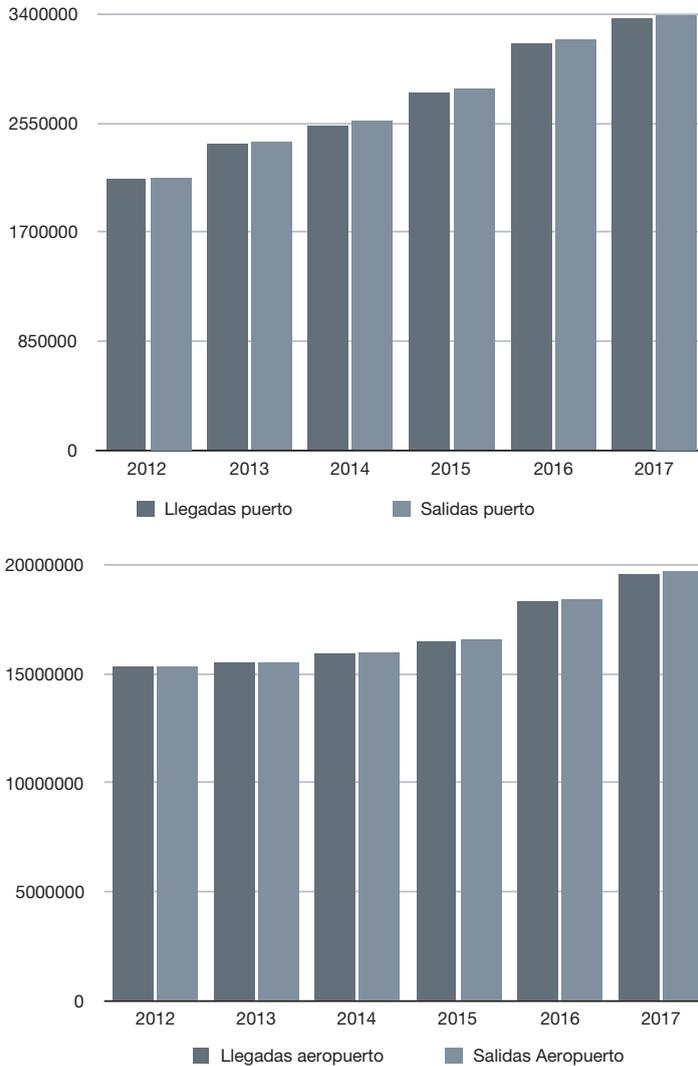


Figura 8.5. Balance de entradas y salidas anuales a las islas mediante transporte marítimo (izquierda) y aéreo (derecha). Fuente: IBESTAT.

Este indicador se denomina Indicador de Presión Humana (IPH), y se presenta en formato diario (IDPH) o mensual (IMPH).

Este indicador fue concebido por Riera y Mateu (2007) y resulta una medida eficiente del efecto de la entrada y salida de turistas en las islas. La ecuación (8.1) muestra el indicador.

$$IDPH_D = POP_a + \sum_{d=1}^D (A_{da} - D_{da} + w_{da}D_a) \quad (8.1)$$

Donde POP_a refleja la población el día 1 de enero del año considerado a , A_{da} supone las llegadas del día d y el año a , tanto de forma marítima como aérea. Del mismo modo D_{da} representa las salidas y D_a representa la diferencia de población entre el año a y el posterior. Por último, w_{da} representa la probabilidad de cometer un error cuando se estiman las llegadas.

La Figura 8.6 muestra la evolución diaria del IDPH en las islas de Mallorca y Menorca (principales islas de la región).

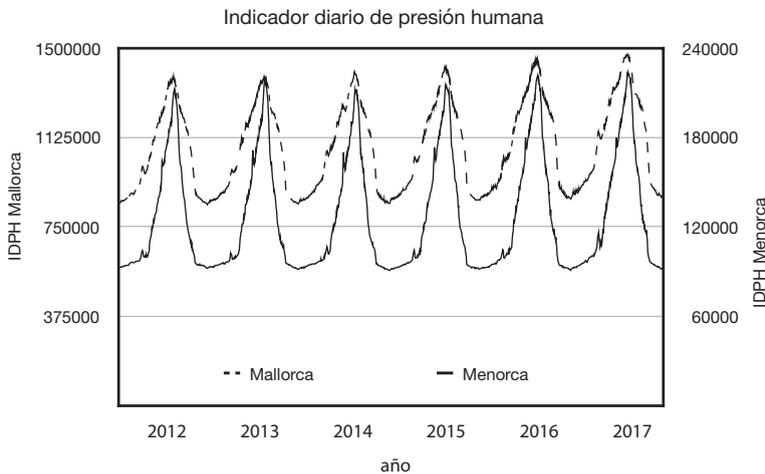


Figura 8.6. Evolución del indicador diario de presión humana en las islas de Mallorca y Menorca. El eje de la izquierda es la escala para Mallorca, mientras que el de la derecha es para Menorca. Fuente: IBESTAT.

Se observa una marcada componente estacional con picos en verano (con grandes diferencias respecto del resto del año) y con

repuntes puntuales en las fechas de la Pascua. Este indicador está muy relacionado con la temperatura (Aguiló, Alegre, y Sard 2005; Manera 2009). Esta relación es básica para la integración en un modelo de previsión de demanda energética.

8.6. Modelo

Partiendo de un modelo de Holt-Winters múltiple estacional, se pretende integrar la información contenida en el indicador para poder mejorar la precisión de las previsiones. El primer problema que surge es la sincronización de los datos proporcionados con el indicador con la previsión horaria. Es por ello que se ha considerado descomponer la demanda diaria en 24 modelos horarios, de modo que cada modelo realice su previsión y pueda incorporarse la información del IDPH. El modelo general, con tendencia aditiva y estacionalidad multiplicativa se muestra en (8.2)-(8.5).

$$S_t = \alpha \left(\frac{X_t}{I_{t-s}} \right) + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (8.2)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1} \quad (8.3)$$

$$I_t = \delta \left(\frac{X_t}{S_t I_{t-s}} \right) + (1 - \delta)I_{t-s} \quad (8.4)$$

$$\hat{X}_{t+k} = (S_t + kT_t)I_{t-s+k} + \varphi_{AR}^k \varepsilon_t \quad (8.5)$$

Donde α , γ y δ son los parámetros de suavizado definidos en el capítulo 4, y φ_{AR}^k el parámetro de ajuste para el error de autocorrelación de primer orden (ε_t). Así mismo, S_t , T_t y I_t son las ecuaciones de suavizado para el nivel, tendencia y estacionalidad (una única estacionalidad en este caso). \hat{X}_{t+k} es la ecuación de previsión donde los valores observados son X_t .

A tenor del estudio realizado en este capítulo, se observa que el IPH tiene una clara relación con la demanda eléctrica. Dentro de las posibilidades que ofrece la bibliografía para la introducción de variables exógenas, se recurrió al uso de covariables siguiendo las indicaciones en Bermúdez (2013) . Los resultados no mostraron una mejora en el MAPE de la previsión.

Sin embargo, se optó por introducir la información aportada por el indicador como parte del error, y en concreto, formando parte del parámetro φ_{AR} Como se ha comentado anteriormente, este factor supone un ajuste para el error de autocorrelación de primer orden. Se trata de un factor que viene a introducir, de modo ponderado, el error cometido en anteriores previsiones, y en el cual introducimos todo aquello que no podemos controlar. No obstante, hay cierta información que puede extraerse de forma coherente. Y dentro de esta información se encuentra el IDPH. Cabría la posibilidad de introducir la temperatura en el modelo, pero no resulta positivo, ya que, de alguna forma, existe una correlación directa entre la demanda y la temperatura que la propia estacionalidad del modelo ya refleja, y que el IDPH también utiliza (recordemos que este indicador está relacionado con la temperatura anual de la isla). Este tema, sin embargo, se tratará en el capítulo siguiente.

Nowotarski et al. (2016) encuentran que al combinar las previsiones de dos series hermanas (aquellas que provienen de muestras diferentes, pero en el mismo periodo), se pueden mejorar las previsiones sobre demanda eléctrica, porque pueden tener una relación.

En nuestro caso, la relación entre ambas series puede ser aprovechada en el modelo del siguiente modo: si se genera un modelo de HW para el IDPH (lo cual tiene mucho sentido, debido a la enorme influencia de la estacionalidad en el modelo), la parte de previsión del modelo estará incluida de forma intrínseca en la serie de demanda. El error cometido en la previsión es una información de variabilidad no controlada de la serie que afecta,

de modo intrínseco, a la serie de demanda. Así pues, se determina un modelo para el IDPH, como indica (8.6)-(8.9).

$$S_t^{IDPH} = \alpha_{IDPH} \left(\frac{IDPH_t}{I_{t-s}^{IDPH}} \right) + (1 - \alpha_{IDPH})(S_{t-1}^{IDPH} + T_{t-1}^{IDPH}) \quad (8.6)$$

$$T_t^{IDPH} = \gamma_{IDPH}(S_t^{IDPH} - S_{t-1}^{IDPH}) + (1 - \gamma_{IDPH})T_{t-1}^{IDPH} \quad (8.7)$$

$$I_t^{IDPH} = \delta_{IDPH} \left(\frac{X_t^{IDPH}}{S_t^{IDPH} I_{t-s}^{IDPH}} \right) + (1 - \delta_{IDPH})I_{t-s}^{IDPH} \quad (8.8)$$

$$\hat{X}_{t+k}^{IDPH} = (S_t^{IDPH} + kT_t^{IDPH})I_{t-s+k}^{IDPH} \quad (8.9)$$

Nótese que en la ecuación (8.9) no se incluye el ajuste con el error de autocorrelación, para evitar perder esta información. De este modo, el error cometido por la ecuación se integra en un modelo de HW, modificando la ecuación (8.5) y resultando como en (8.10).

$$\hat{X}_{t+k} = (S_t + kT_t)I_{t-s+k} + \varphi_{AR}^k [\varepsilon_t - \rho(\hat{X}_{t+k}^{IDPH} - IDPH_{t+k})] \quad (8.10)$$

En la Figura 8.7 se muestra, con el fin de mejorar la comprensión, el esquema de trabajo con los modelos de HW integrando el IDPH.

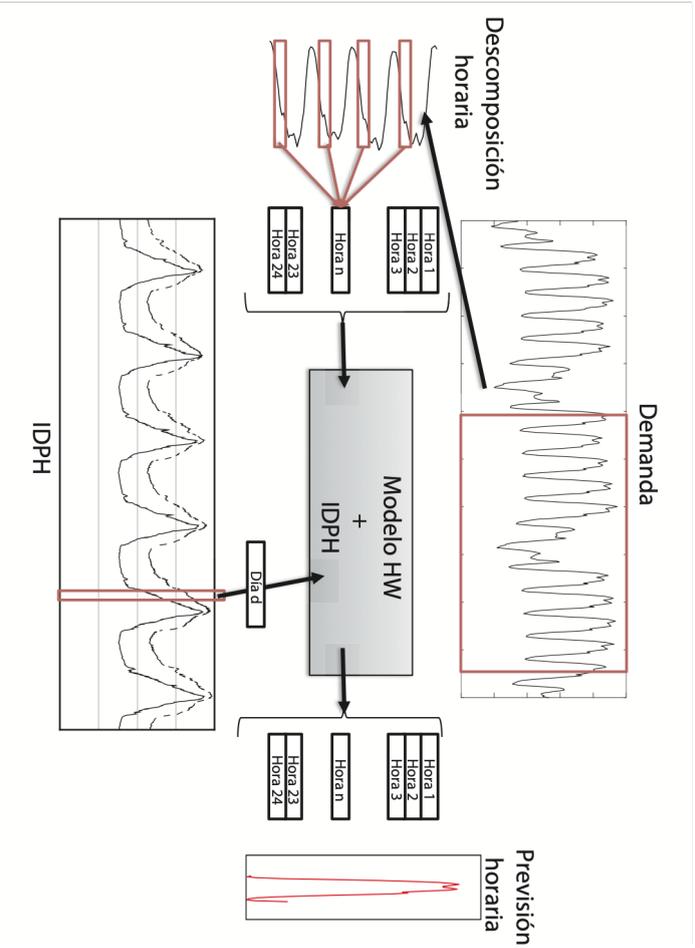


Figura 8.7. Esquema de aplicación del modelo HW con la introducción del IDPH.

La inclusión del parámetro permite relacionar de forma lineal ambos errores, y es necesario calcularlo. En principio este parámetro no adquiere ninguna restricción, si bien los valores (debido a la diferencia de escalas entre el IDPH y la demanda) son pequeños. Para su obtención se requiere primero la obtención de los parámetros para el modelo de IDPH, y posteriormente, recurrir a uno de los dos métodos:

- optimización en dos pasos, donde se ajusta el modelo de demanda por separado y luego se integra la información del IDPH.
- Optimización de todos los parámetros a la vez.

Con el fin de valorar el resultado de la utilización del nuevo modelo, se recurrió a la extracción de muestras aleatorias donde el 90% de los datos se utilizó para el ajuste del modelo, y el resto para la previsión de demanda de hasta 7 días en adelante. Para comprobar la precisión de los modelos se recurrió a la utilización del MAPE a 24 horas.

8.7. Resultados

Los resultados obtenidos con la aplicación del modelo fueron comparados con el modelo original. En la Tabla 8.1 se muestra la mejora obtenida por el nuevo modelo.

Se aprecia una ligera reducción en MAPE tanto para las islas de Mallorca como Menorca, siendo importante en Mallorca. Esto se produce en todos los modelos utilizados, si bien en los casos que se ha optado por optimizar todos los parámetros de forma simultánea, se ha obtenido una mayor reducción. El motivo de la diferencia entre la mejora dada por el modelo para Mallorca y Menorca seguramente reside en la propia serie de demanda. La serie en Menorca debe ser más estable, por lo tanto, la introducción del indicador no aporta tanto beneficio.

Tabla 8.1. Mejora de la precisión de los modelos propuestos frente al modelo original. Valores de MAPE a 24h en 7 días.

	MAPE(%)			
	Mallorca		Menorca	
	2- PASOS	SIMULTANEOS	2- PASOS	SIMULTANEOS
AMC	-0,06	-0,12	-0,03	-0,02
AAC	-0,05	-0,10	-0,03	-0,03
NAC	-0,05	-0,09	-0,03	-0,03
NMC	-0,06	-0,11	-0,03	-0,03

Tabla 8.2. Reducción del MAPE de acuerdo a la hora

Hora	MAPE(%)			
	AMC	AAC	NAC	NMC
1	0,0	0,0	0,0	0,0
2	-0,1	0,0	0,0	0,0
3	0,0	0,0	0,0	0,0
4	0,0	0,0	0,0	0,0
5	0,0	0,0	0,0	0,0
6	0,0	0,0	0,0	0,0
7	-0,1	-0,1	-0,1	-0,1
8	-0,3	-0,2	-0,2	-0,3
9	-0,2	-0,2	-0,2	-0,2
10	-0,1	-0,1	-0,1	-0,1
11	-0,1	-0,1	-0,1	-0,1
12	-0,2	-0,1	-0,1	-0,2
13	-0,1	-0,1	-0,1	-0,1
14	-0,1	-0,1	-0,1	-0,1
15	-0,1	-0,1	-0,1	-0,1
16	-0,2	-0,2	-0,2	-0,2
17	-0,2	-0,2	-0,2	-0,2
18	-0,3	-0,2	-0,2	-0,2
19	-0,2	-0,2	-0,2	-0,2
20	-0,2	-0,2	-0,2	-0,2
21	-0,2	-0,2	-0,2	-0,2
22	-0,1	-0,1	-0,1	-0,1
23	0,0	0,0	0,0	0,0
24	-0,1	-0,2	0,0	0,0

Sin embargo, si acudimos al desglose horario, tal y como se aprecia en la Tabla 8.2, se puede observar como el resultado mejora en ciertas horas alcanzando hasta el 0,3%. Esto proporciona una mejora en el rendimiento del modelo, y, tal y como se puede observar en la Figura 8.8, en las horas centrales del día, la curva de demanda del modelo que incluye el IDPH se acerca a la curva de demanda real.

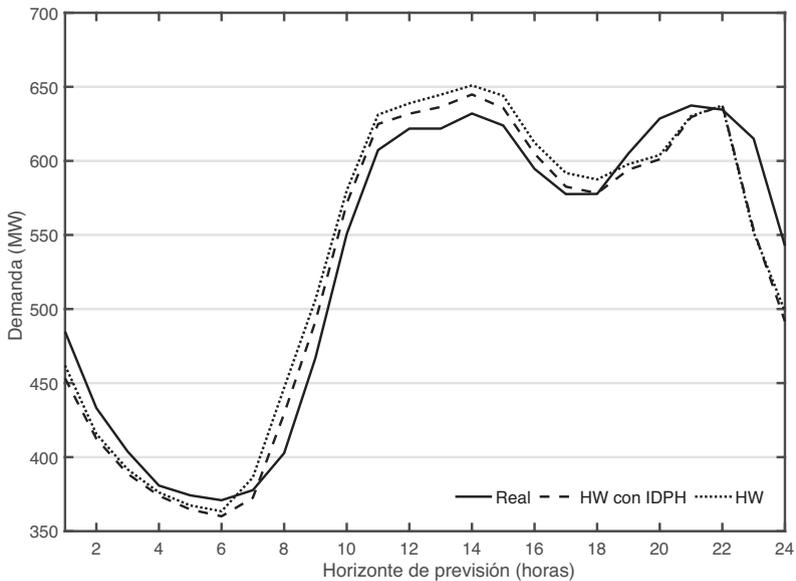


Figura 8.8. Media de las previsiones realizadas con el modelo HW-IDPH frente al modelo HW y los datos reales.

8.8. *Discusión de los resultados*

Los errores en la predicción de la demanda eléctrica suponen una pérdida no sólo económica, sino también medioambiental Y en especial, esto ocurre en destinos turísticos como las Islas Baleares, donde gran parte de la generación de electricidad se realiza mediante centrales de combustible fósil, lo cual se traduce en una emisión de gases de invernadero y otros –

las emisiones de CO₂ provenientes de la generación eléctrica se estima en un 5% -. Si a esto se le suma el incremento de turistas que se está produciendo, este problema se agrava.

El método propuesto utiliza la información proporcionada por el indicador diario de presión humana para mejorar la previsión horaria en las Islas Baleares. Se utiliza modelos de Holt-Winters a los que, mediante una combinación lineal de varios modelos, la información proporcionada por el indicador es utilizada en el modelo de demanda eléctrica para producir mejores previsiones, reduciendo el error hasta en un 0.3 %.

Según los cálculos realizados, esto puede suponer una disminución de las emisiones de hasta 200 kg/hora, además de la consecuente mejora en la parte económica. Sin embargo, este modelo está limitado única y exclusivamente a las Islas Baleares, puesto que el IBESTAT es el único en proporcionar este indicador. No obstante, se puede extender este modelo a otros destinos turísticos con comportamiento semejante, que proporcionen la misma información.

9. Modelo híbrido Holt-Winters múltiple estacional con temperatura

9

9.1. Introducción

Este capítulo aborda el desarrollo de un nuevo modelo de Holt-Winters múltiple estacional en el que se incorpora la temperatura del aire como variable exógena para mejorar las previsiones en la demanda eléctrica horaria a corto plazo.

Primeramente, se analiza la necesidad de incluir la temperatura en los modelos de Holt-Winters múltiple-estacionales.

Seguidamente, se realiza un análisis sobre la bibliografía existente respecto de la inclusión de la temperatura en los modelos de previsión.

A partir de aquí, se desarrolla un método de trabajo en el que, de forma híbrida, mediante la utilización de modelos nHWT y con la ayuda de redes neuronales, se mejoran las previsiones de demanda eléctrica horaria en Mallorca. Este método se aplica posteriormente a la demanda eléctrica en España y se comprueba que también mejora las previsiones.

Finalmente, se resumen las conclusiones alcanzadas en el capítulo.

9.2. Justificación

Es un hecho que el consumo energético está ligado a las condiciones climáticas ambientales del momento. La temperatura del aire, las condiciones de humedad o la presión meteorológica son variables que afectan al desarrollo normal de la actividad diaria, y que, por tanto, influyen en mayor o menor medida en el consumo de electricidad.

Esto se refleja en la gran cantidad de modelos desarrollados para determinar las previsiones de consumo eléctrico. Sin embargo, dependiendo del método utilizado, la utilización de las variables climáticas en los modelos de previsión de demanda a corto plazo puede no ser fácil: la temperatura se encuentra embebida en la propia estacionalidad diaria, y no sufre variaciones bruscas, por lo que los modelos generalmente no necesitan de la inclusión de dichas variables (Taylor, de Menezes, y McSharry 2006).

No obstante, y con el objetivo de mejorar la precisión de las predicciones, en este capítulo se introduce la utilización de la temperatura en un modelo híbrido, junto con la utilización de redes neuronales.

9.3. Revisión bibliográfica

Las condiciones climáticas forman parte de los factores que afectan al consumo energético y son incluidas en muchos modelos (Thompson 1976; Ernoult et al. 1983; Gross y Galiana 1987). Cancelo y Espasa (1991a) analizaron los efectos provocados en la demanda eléctrica por las condiciones climáticas, determinando que la temperatura del aire es la variable influyente. Esta temperatura se calcula a partir de 10 estaciones meteorológicas en España, mediante funciones no

lineales que distinguen una zona caliente y una zona fría (por debajo de 20°C y por encima de 22°C) y se calcula una temperatura estimada de acuerdo a (Cancelo y Espasa 1991b). Como resultado Cancelo y Espasa (1995,1996) propusieron un modelo para la demanda eléctrica utilizando un modelo de regresión. Este modelo descompone la demanda eléctrica entre la demanda base (modelizada mediante modelos ARIMA con intervenciones) y una serie de variables ficticias para incluir el efecto calendario, y dos polinomios de retardos para la zona de temperaturas fría y caliente. Las variables ficticias sirven para determinar cada uno de los festivos, y el día de la semana en que se produce.

Sin embargo, ya se comenta que la contribución de la temperatura es muy inferior comparada a la de otros factores. Engle, Hendry y Richard (1983) determinaron que la temperatura es una exogeneidad débil, pero que, a la hora de la predicción, es reemplazada por una exogeneidad fuerte, lo cual implica que puede perturbar las predicciones. Eso explica la dificultad de incluir la temperatura en los modelos de forma correcta.

El grupo de trabajo de Valor y Meneu introducen un modelo similar, en el que las temperaturas son modeladas utilizando las curvas de enfriamiento y calentamiento, denominadas HDD y CDD (Valor, Meneu, y Caselles 2001; Pardo, Meneu, y Valor 2002; Valor et al. 2002). Por otro lado, en otros países como en Francia, el gestor del sistema Electricité de France (EDF) basa su modelo de acuerdo a división directa entre un sumando de demanda relacionada con la tendencia y estacionalidad, y otro que relaciona la temperatura y el horario diurno para el ahorro, conocido como daylight saving time, DST (Bruhns, Deurveilher, y Roy 2005).

Otras vertientes utilizan splines donde se modelizan los periodos estacionales del año mediante un spline (Martín-Rodríguez y Cáceres-Hernández 2005). Taylor y Buizza (2003) utilizan un conjunto racional de variables climatológicas para ser incluidas en un modelo de regresión.

Otro método habitual es el uso de inteligencia artificial, y en concreto, el uso de redes neuronales. Una de las metodologías consiste en separar la previsión de la demanda, utilizando para la tendencia redes neuronales, mientras que para las fluctuaciones utilizan funciones paramétricas que incluyen variables climatológicas (Gonzalez-Romera, Jaramillo-Moran, y Carmona-Fernandez 2006; González-Romera, Jaramillo-Morán, y Carmona-Fernández 2008).

Moral-Carcedo y Vicéns-Otero (2005) determinan una ponderación entre las regiones españolas basado en la población. Para modelizar la no linealidad de la relación entre temperatura y demanda lleva a algunos autores determinar el efecto de la temperatura mediante modelos no lineales basados en umbrales (Cancelo, Espasa, y Grafe 2008). Otros autores incluyen la temperatura en sus modelos no paramétricos (Aneiros-Pérez, Cao, y Vilar-Fernández 2011; Vilar, Cao, y Aneiros 2012; Aneiros-Pérez y Vieu 2008; Vilar, Aneiros, y Raña 2018). En estos modelos incluyen las curvas de enfriamiento y calentamiento, y realizan combinaciones de previsiones. En ellas se utiliza variables como temperatura y horario solar (Aneiros, Vilar, y Raña 2016a; Vilar, Aneiros, y Raña 2018).

Sin embargo, la forma más habitual de modelizar la demanda eléctrica utilizando temperaturas es mediante modelos de regresión (OrtizBeviá y RuizdeElvira 2012; OrtizBeviá, RuizdeElvira, y Alvarez-García 2014).

Moral-Carcedo y Pérez-García (2015) analizan la demanda y el efecto que produce en ella la temperatura, distinguiendo por sector de trabajo. Determinan que el sector más afectado es el sector servicios, pero con variaciones del 1%.

López et al. (2017) realizan previsiones en las Islas Baleares utilizando variables climatológicas como el viento, nubosidad y radiación solar. Posteriormente, desarrollan una metodología para la previsión de la demanda utilizando redes

neuronales para modelizar la parte climatológica (López et al. 2018).

Redes neuronales

El uso de redes neuronales para el consumo eléctrico se remonta a finales de los años 80 y principios de los 90. Damborg, Peng, Hubele y otros autores utilizan las redes neuronales para el control y planificación de sistemas de potencia (Damborg et al. 1990; Peng, Hubele, y Karadi 1992).

El funcionamiento de las redes neuronales se describe en la Figura 9.1, adaptado de (Hippert, Pedreira, y Souza 2001). En la parte de la izquierda se muestra el esquema de una neurona, donde a partir de una serie de variables de entrada, se produce una combinación lineal asignando pesos w_i . Esta combinación lineal es utilizada dentro de la función de activación de la neurona, modelado de acuerdo a una función regresión logística (sigmoide).

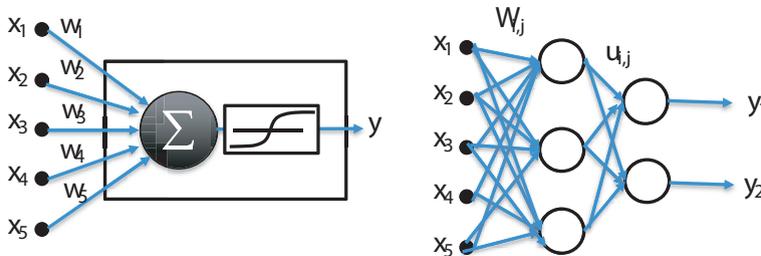


Figura 9.1. Esquema explicativo de una neurona (izquierda) y de una red neuronal (derecha) perceptrón multicapa.

Adaptado de Hippert et al. (2001)

Todas estas neuronas se organizan en capas que se relacionan mediante matrices de pesos $w_{i,j}$ y $u_{i,j}$ que proporcionan las salidas correspondientes. En el ejemplo de la figura, existen 5 variables de entrada, que sirven para alimentar a la red neuronal con 3 neuronas en la capa oculta (1 única capa) y dos neuronas en la capa de salida.

Así pues, la salida de una variable y_i tendría un modelo como el expresado en la ecuación (9.1):

$$y_i = \sum_{j=1}^3 \left(u_{kj} \cdot \frac{1}{1 + \exp(-\sum_{i=1}^5 w_{ji}x_i + \theta_j)} \right) + \theta_k \quad (9.1)$$

Siendo θ_j y θ_k los vectores de sesgo. Para estimar los valores de los parámetros, se realiza un proceso denominado “entrenamiento”, donde se ajustan los pesos minimizando el error de predicción de una parte del conjunto de datos. Posteriormente se realiza un proceso de “simulación” para realizar pronósticos.

El uso de redes neuronales se extiende a partir de ese momento. Darbellay y Slama (2000), sin embargo, encuentran que la utilización de redes neuronales incluyendo variables climáticas no supone una mejora con respecto de los modelos lineales cuando la relación entre la demanda y las variables climáticas son lineales, como es el caso de la demanda en la República Checa. Hippert, Pedreira y Souza (2001) analizan los métodos de redes neuronales y establece una serie de hechos notables a analizar :

- 1) muchas de las redes neuronales se sobreparametrizan;
- 2) existe una falta de comprobación con métodos estándar.

Fallah et al. (2019) recopilan los métodos habituales de inteligencia artificial aplicados a la previsión de demanda eléctrica en el corto plazo. Existen las técnicas de patrones similares, las de selección de variables jerarquizadas y de selección de la estación del año.

La mayor parte de los trabajos desarrollan modelos de patrones similares. Troncoso et al. (2004) aplican la utilización de redes neuronales para la predicción de la energía eléctrica en

España. Los trabajos de revisión acerca del uso de redes neuronales para la demanda eléctrica comprueban la aparición de nuevas técnicas basadas en el uso de lógica difusa, algoritmos genéticos y optimización por partículas flotantes, PSO (Baliyan, Gaurav, y Kumar Mishra 2015) .

9.4. Desarrollo del método de trabajo.

El modelo de Holt-Winters múltiple estacional aplicado a la demanda eléctrica en España incluye al menos dos estacionalidades: la estacionalidad diaria, y la estacionalidad semanal. La segunda modeliza el efecto de los días de trabajo durante la semana, permitiendo a la serie tener en cuenta que los fines de semana no se trabaja, y que el día cuya mayor producción se realiza es el miércoles. La estacionalidad diaria es la que modeliza el efecto del consumo diario, debido a la actividad diaria, pero asociado también a las condiciones climáticas habituales: luz solar, temperatura diaria del aire, y el resto de condiciones climáticas. De acuerdo a Engle (Engle, Hendry, y Richard 1983; Engle 1982), la inclusión en el modelo de una variable que introduzca el efecto de la temperatura tiene poca importancia débil en el ajuste del modelo, aunque puede significar una gran influencia en la previsión. Esto se incrementa si el modelo es además un modelo de Holt-Winters, muy estructurado, y resulta independiente de si la temperatura se incluye de forma lineal o de cualquier otro modo.

Es por ello que se ha recurrido a otras técnicas, similares a las detalladas en (Trull, García-Díaz, y Peiró-Signes 2017) y el uso de redes neuronales artificiales para el modelado de la temperatura.

Para el desarrollo del método, se ha recurrido a utilizar los datos de la demanda eléctrica en Mallorca (España). REE proporciona de forma desagregada la demanda eléctrica en las Islas Baleares. Esto permite utilizar la relación directa entre las temperaturas obtenidas en la Isla de Mallorca (en el aeropuerto

de Palma) con la demanda eléctrica. La demanda (Figura 9.2) y la temperatura del aire (Figura 9.3) están altamente relacionadas.

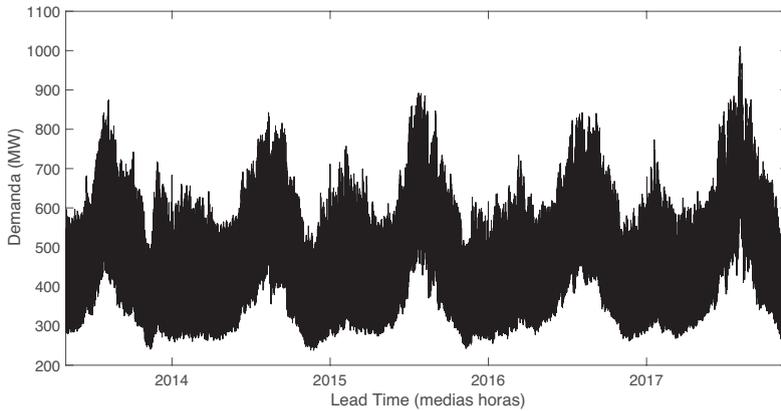


Figura 9.2. Demanda eléctrica en Mallorca.

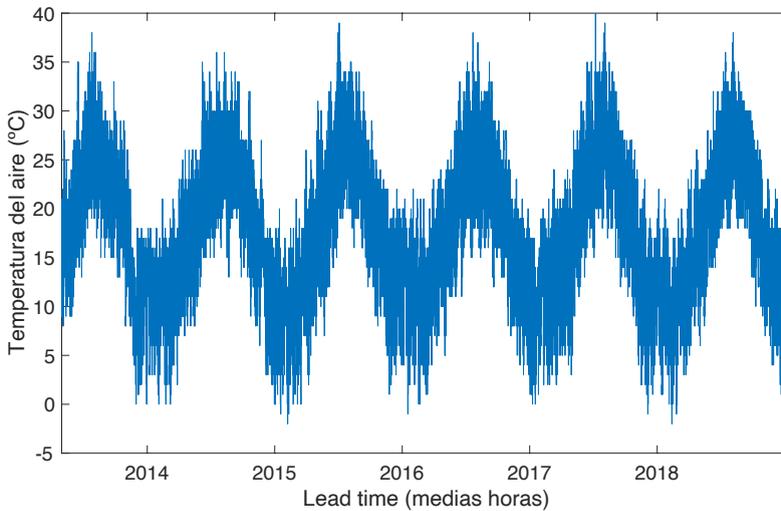


Figura 9.3. Temperatura del aire en Mallorca.

La temporada de mayor temperatura coincide con el mayor pico de demanda, aunque si bien es verdad, la demanda de la isla está muy relacionada con el turismo (véase capítulo

anterior), y, por lo tanto, se produce otro pico de demanda en las fechas de Pascua, estando relacionado con la llegada de turistas. Para comprobar esta relación, se recurre a la Figura 9.4, la cual muestra la relación demanda eléctrica-temperatura para la Isla de Mallorca. Esta relación pone de manifiesto una típica curva con forma de V (o en ocasiones U) denominada de enfriamiento y calentamiento alrededor de una temperatura de inflexión alrededor de 15-17 °C. Esta curva varía ligeramente dependiendo de la hora del día considerado. La parte izquierda de la curva se denomina zona de enfriamiento, y la de la derecha zona de calentamiento. La Isla, al ser de clima suave, incrementa el consumo energético a medida que aumenta la temperatura, puesto que el principal motivo de esta situación la genera el uso de sistemas de climatización.

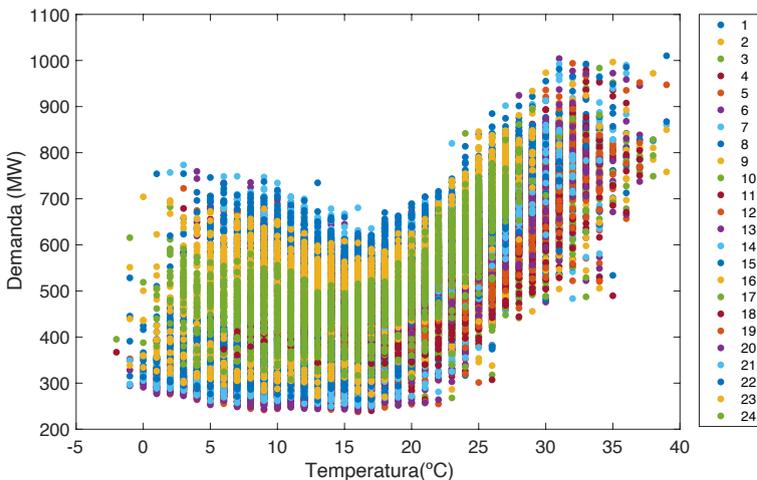


Figura 9.4. Curva V de demanda-temperatura para la Isla de Mallorca. Los puntos se distribuyen según la hora (1 a 24h).

Esta relación no se produce de modo lineal, y al tratar de incluirlo dentro del modelo nHWT resulta muy complicado obtener un método fiable. Siguiendo las pautas del capítulo anterior, resulta evidente que el patrón diario de estacionalidad está relacionado con las variables climáticas: depende de la luz del sol, y la temperatura del aire se relaciona con este valor. Por

lo tanto, no tiene sentido introducir una nueva estacionalidad o término que incluya esta variable, ya que resulta redundante y no se ajusta correctamente en el modelo. Sin embargo, las variaciones de la temperatura pueden aportar una información interesante, aunque difícil de modelar. El método adoptado para poder incluir la temperatura, de forma híbrida, se muestra en la Figura 9.5. El método consiste en realizar los siguientes pasos:

1. Se obtiene un modelo nHWT a partir de los datos de demanda provistos por REE, sin modificar la serie. Se evita aplicar cualquier tipo de filtro o suavizando de la serie.
2. Se entrena la red neuronal introduciendo los valores obtenidos con el modelo nHWT, además de las variables climáticas. En este caso se ha considerado únicamente la temperatura del aire. Para entrenar la red, es necesario establecer como valor objetivo la demanda eléctrica de REE. De este modo, la red trabaja a partir del modelo nHWT para intentar reproducir las de REE.
3. Finalmente, se produce su explotación. Se realizan previsiones con el modelo nHWT, se obtienen previsiones de las variables climáticas, y se introducen en la red neuronal para que proporcione los pronósticos definitivos.

Con el fin de comprobar el funcionamiento de la metodología, se han realizado muestras aleatorias dentro de la serie anteriormente mostrada. Se tomaron 45 muestras de 8 semanas para el ajuste, y dos más para la validación. Todas las muestras son aleatorias, y se han buscado en fechas que puedan abarcar todas las estaciones del año, aunque se ha evitado que coincida con un día festivo.

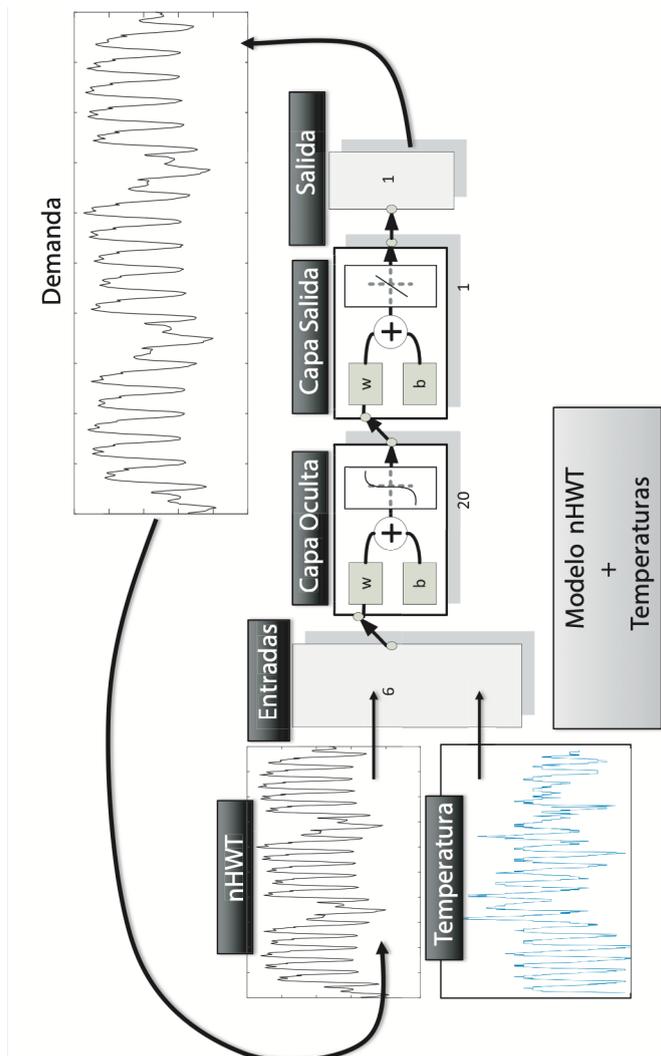


Figura 9.5. Método híbrido de previsión mediante el uso de modelos de Holt-Winters múltiple-estacionales con redes neuronales para la temperatura.

Para su implementación, se ha elaborado un script en el software MATLAB® R13b donde se ha implementado el modelo de Holt-Winters de acuerdo a los capítulos anteriores, y para la red neuronal se ha adaptado un script de MATLAB de acuerdo a Deoras (2010). La red neuronal utilizada cuenta con una capa oculta de 20 neuronas, y una capa de salida de una única neurona. El entrenamiento se ha realizado para cada periodo considerado, y las previsiones han sido realizadas para 24 horas.

La Tabla 9.1 muestra la comparativa para algunas de las muestras realizadas en el año 2014. En ellas se puede observar como el método en general mejora las previsiones, alcanzando en ocasiones un 0,18% de mejora en el MAPE. El promedio obtenido de mejor está alrededor del 0,1%.

Esta mejoría se realiza utilizando únicamente la variable temperatura del aire, quedando abierta la posibilidad de introducir nuevas variables.

Tabla 9.1. Comparativa de reducción del MAPE(%) de las previsiones realizadas con el método regular frente a las realizadas con la nueva metodología.

Comienzo	Final	Sin temp.	Con Temp.	Dif
24-2-2014	21-4-2014	3,136	3,145	-0,009
17-3-2014	12-5-2014	1,443	1,452	-0,008
12-4-2014	7-6-2014	3,383	3,238	0,144
21-5-2014	16-7-2014	2,452	2,328	0,123
14-6-2014	9-8-2014	3,556	3,424	0,132
29-7-2014	23-9-2014	2,031	2,022	0,009
13-7-2014	7-9-2014	1,409	1,389	0,020
25-8-2014	20-10-2014	1,656	1,687	-0,031
29-9-2014	24-11-2014	2,314	2,246	0,068
27-10-2014	22-12-2014	6,881	6,707	0,174
24-11-2014	19-1-2015	4,645	4,439	0,206

9.5. Aplicación a la demanda horaria en España

La metodología descrita se ha aplicado a la serie de demanda en España. Los datos utilizados han sido obtenidos por REE entre los años 2014 a 2018. Estos datos muestran la demanda agregada en toda la península, incluyendo los balances con Francia, Portugal, las islas y Marruecos. Al estar agregada, es necesario contar con una temperatura promedio que pueda ser de aplicación. Para ello, se ha utilizado los pesos otorgados en Moral-Carcedo y Vicéns-Otero (2005) y que se muestran en la Tabla 9.2.

Tabla 9.2. Pesos otorgados a las áreas indicadas en la tercera columna, con las provincias que se incluyen, utilizando como ciudad representativa de la temperatura, la indicada en la primera columna. Extraído de (Moral-Carcedo & Vicéns-Otero, 2005)

Ciudad Representativa	Peso	Provincias incluidas
Madrid	0,232	Albacete, Ciudad Real, Lérida, Toledo, Granada, Zaragoza, Madrid
Valencia	0,154	Alicante, Castellón, Valencia
Valladolid	0,112	Ávila, Burgos, León, Palencia, Soria, Álava, Cuenca, Guadalajara, Huesca, Logroño, Navarra, Segovia, Teruel, Valladolid, Zamora
Sevilla	0,110	Badajoz, Jaén, Cáceres, Sevilla, Córdoba
Bilbao	0,160	Lugo, Orense, Coruña, Pontevedra, Santander, Guipúzcoa, Oviedo, Vizcaya
Barcelona	0,157	Gerona, Tarragona, Barcelona
Málaga	0,075	Cádiz, Huelva, Málaga

En esta tabla se recoge la agrupación realizada en 7 regiones de similares características climáticas, y a las cuales se les otorga un peso de acuerdo a la población que comprende. De

cada región se selecciona la ciudad más importante que será la representativa para la ponderación. Con ella, se obtiene la gráfica de temperaturas mostrada en la Figura 9.6.

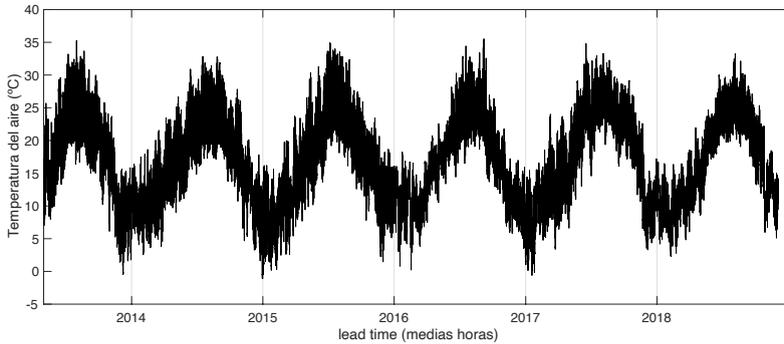


Figura 9.6. Temperatura ponderada en la Península Ibérica

Esta temperatura es la utilizada para la aplicación del método en la península. Los resultados se muestran en la Tabla 9.3. Se puede apreciar como las diferencias obtenidas indican que el MAPE ha mejorado respecto del método sin utilizar las temperaturas, aunque en valores pequeños De media se ha mejorado un 0,03%.

La mejora conseguida es menor en comparación con la obtenida con el método aplicado a la demanda en Mallorca. Esta situación se debe, sin duda, a que la relación de pesos no es la correcta en el cálculo de la temperatura de la península. No obstante, se produce una mejora de la previsión.

Tabla 9.3. Resumen de la mejora realizada en el MAPE de las previsiones al incluir la temperatura.

Comienzo	Fin	Sin Temp	Con Temp	Dif.
21-01-14	18-03-14	1,9633	1,97978	-0,01649
21-05-14	16-07-14	1,8997	1,92483	-0,02518
14-06-14	09-08-14	2,8453	2,87680	-0,03150
13-07-14	07-09-14	1,6187	1,63354	-0,01480
25-08-14	20-10-14	1,3963	1,42127	-0,02495
17-03-15	12-05-15	2,0872	2,09758	-0,01037
12-04-15	07-06-15	1,7573	1,78212	-0,02487
29-07-15	23-09-15	1,4172	1,46093	-0,04373
25-08-15	20-10-15	1,3124	1,33057	-0,01815
21-01-16	17-03-16	4,2838	4,31856	-0,03477
24-02-16	20-04-16	2,2503	2,27373	-0,02340
12-04-16	07-06-16	2,0406	2,04905	-0,00844
21-05-16	16-07-16	1,5115	1,53423	-0,02272
14-06-16	09-08-16	2,9739	2,98788	-0,01403
13-07-16	07-09-16	2,2412	2,24481	-0,00358
25-08-16	20-10-16	3,0452	3,08951	-0,04429
29-09-16	24-11-16	2,6039	2,63627	-0,03238
27-10-16	22-12-16	4,3378	4,34699	-0,00916
24-02-17	21-04-17	3,4908	3,56298	-0,07216
17-03-17	12-05-17	1,5002	1,59034	-0,09014
29-07-17	23-09-17	1,1848	1,19398	-0,00916
13-07-17	07-09-17	2,1400	2,14873	-0,00877
25-08-17	20-10-17	2,9036	2,93650	-0,03286
29-09-17	24-11-17	2,1775	2,24138	-0,06391

9.6. *Discusión de los resultados*

Los modelos de Holt-Winters múltiple-estacionales utilizan, en el corto plazo, la estacionalidad diaria para poder relacionar la demanda eléctrica con las variables climatológicas. Por tanto, resulta muy difícil poder integrarlas dentro del propio modelo.

Engle, Hendry y Richard indican como en el ajuste, una variable de exogeneidad débil no tiene casi influencia, mientras que para la realización de pronósticos, puede suponer una gran influencia (Engle, Hendry, y Richard 1983). Por ello, se ha optado por la realización de un método híbrido en conjunto con la utilización de redes neuronales, de modo que estas últimas modelicen la parte no lineal y mejoren los resultados de la previsión.

Primeramente, los modelos nHWT realizan una previsión, que luego, mediante la utilización de redes neuronales, alimentadas con esta previsión y añadiendo variables climatológicas.

Seguidamente, se ha utilizado el método con la demanda eléctrica en Mallorca, al existir datos que relacionan directamente la temperatura con la demanda. El resultado muestra una mejora de hasta un 0,18% en MAPE, siendo la media un 0,1%.

Finalmente, se ha realizado la misma técnica con la península, con el factor importante de tener que determinar una temperatura ponderada para la península. Se ha utilizado los pesos descritos en (Moral-Carcedo y Vicéns-Otero 2005) y se ha obtenido una mejora en la previsión de hasta un 0,1% en algún caso, siendo la media un 0,03%. Esto indica que el método está consiguiendo mejorar las previsiones, aunque en menor medida de lo esperado. Esto se debe a que la ponderación utilizada no es la idónea para esta tarea, y en futuras aplicaciones debe encontrarse una ponderación que permita realizar mejores previsiones.

10. Conclusiones

10

10.1. Introducción

En este capítulo se resumen las principales conclusiones alcanzadas en esta tesis. Éstas se organizan cronológicamente de acuerdo a los capítulos desarrollados. Posteriormente se comentan las posibles líneas de investigación abiertas por este trabajo.

10.2. Resumen de los resultados

Esta tesis ha investigado los modelos de Holt-Winters múltiple-estacionales aplicados a la demanda eléctrica horaria en España (en la península).

El análisis previo realizado en el **Capítulo 2** sobre la demanda eléctrica ha permitido conocer el funcionamiento de la demanda y establecer el marco de trabajo de la tesis. Ésta se centra en la demanda horaria a corto plazo (hasta 24 horas), utilizando los datos sin filtrar, con la única salvedad de filtrar la serie en los días que se produce el cambio horario (tercer sábado

de marzo, y de octubre). Se observa el comportamiento de la serie y la importancia de los días festivos.

Los métodos de Holt-Winters múltiple-estacionales han sido desarrollados en el **Capítulo 4**. Se ha comprobado su eficiencia en las previsiones, comparando con las propias dadas por REE, las cuales han superado. Este análisis se ha realizado tanto para dos como para el tres estacionalidades. Se extrae la conclusión de que los modelos triple estacionales no proporcionan mejores resultados que los doble estacionales si la serie no se filtra y se suavizan los días festivos cambiándolos por otros de días similares.

En el **Capítulo 5** se introducen los métodos de obtención de los valores iniciales – o semillas – adaptados para los modelos nHWT. Adicionalmente se han estudiado los métodos para poder determinar si alguno de ellos proporciona mejores valores frente al resto. Destacan los métodos “overall” para la tendencia, y el método NIST múltiple estacional para la estacionalidad. Sin embargo, no destaca ningún método en la obtención del nivel.

La optimización de los parámetros y el conocimiento de los mismos es parte fundamental de la explotación de los modelos. Es por ello que el **Capítulo 6** analiza los parámetros y su relación con las series trabajadas, además de analizar la estabilidad de los mismos.

La introducción de estacionalidades móviles de intervalo discreto en el **Capítulo 7** permite abordar la problemática de los eventos especiales en las series temporales, y, más en concreto, en la de demanda. Los eventos especiales siguen un patrón diferente al general de la serie, lo cual provoca un descenso drástico en la precisión de la previsión.

En este capítulo se presentan estas estacionalidades, denominadas DIMS (dicrete-interval moving seasonalities) y se muestra un caso de aplicación:

- 1) Para situaciones de huelga.
- 2) Para Pascua.
- 3) Para días festivos cortos.

El primer caso se trata de eventos especiales de muy poca frecuencia, mientras que los segundos y terceros aplican a efecto calendario.

Los resultados demuestran que la precisión en la previsión se mantiene en los mismos niveles que en el caso de situaciones normales, sin eventos especiales.

Con el objetivo de seguir mejorando la precisión de las predicciones, el **Capítulo 8** analiza la situación en las Islas Baleares, donde las características peculiares permiten establecer una relación entre la demanda y la afluencia de turistas.

Primeramente, se selecciona un indicador turístico que permite relacionar la población existente con la afluencia de turistas en la Isla.

Posteriormente, se introduce la relación entre el indicador y la demanda eléctrica, desarrollando un nuevo modelo que integra la información de ambas variables y se aplica a la demanda eléctrica en Mallorca y en Menorca.

Los resultados muestran que se produce una mejora de hasta el 0,3% en el MAPE respecto del modelo regular.

Por último, en el **Capítulo 9** se desarrolla un modelo híbrido basado en nHWT y redes neuronales que permite la introducción de variables climatológicas en el modelo.

Para comprobar la efectividad del modelo, se aplica el modelo a la demanda en Mallorca, y se comprueba que se produce una mejora en las previsiones de media un 0,1% en el MAPE.

Finalmente se aplica a la demanda eléctrica. Los resultados mejoran, siendo de media una mejora de 0,03%. Este

resultado se debe en gran medida al cálculo de la temperatura representativa de la península, donde cabe posibilidad de mejora afinando el cálculo.

10.3. Conclusiones

En respuesta a los objetivos planteados en esta tesis, podemos resumir las siguientes conclusiones, sin menoscabo de las conclusiones expuestas en los capítulos anteriores:

1. Esta tesis ha abordado el desarrollo de los modelos de Holt-Winters múltiple-estacionales, obteniendo previsiones que mejoran los métodos actuales.
 - a. Esta tesis ha tratado adicionalmente los métodos de inicialización del modelo. Se ha comprobado que existen diferencias significativas entre la utilización de tendencia aditiva y multiplicativa, al menos antes de optimizar. Este estudio ha encontrado que el mejor método de inicializar los modelos es mediante la metodología propuesta por el NIST adaptada a la múltiple estacionalidad.
 - b. El documento ha abordado la estabilidad de los parámetros. Es razonable concluir que los parámetros necesitan un conjunto de datos de gran tamaño para estabilizarse, y que primordialmente se debe al efecto calendario.
2. La investigación en el efecto calendario ha llevado a esta tesis a introducir estacionalidades discretas para mejorar las previsiones de demanda en situaciones de eventos especiales tales como Pascuas, festivivos, incluso huelgas.

3. Un segundo resultado ha sido como consecuencia de introducir indicadores exógenos, en este caso turísticos, en el modelo que permite la mejora de la previsión en las Islas Baleares. Es necesario considerar una serie de limitaciones importantes de este estudio: en primer lugar, sólo aplica a lugares turísticos de las características de las Islas Baleares, y, en segundo lugar, necesita de la utilización del indicador de presión humana en las islas.
4. Finalmente, la investigación en el campo de la utilización de la temperatura ha propiciado introducir un nuevo modelo híbrido basado en los modelos nHWT y redes neuronales que permite incluir en el modelo variables climatológicas y mejorar la previsión.

Esta investigación tiene varias aplicaciones prácticas: en primer lugar, disponer de modelos sencillos y con pocos parámetros para la determinación del consumo eléctrico en España de forma precisa; en segundo lugar, una aplicación de estos modelos a otros tipos de consumo.

Las futuras líneas de trabajo van dirigidas una mayor investigación en el campo de las estacionalidades discretas, y la utilización de modelos mixtos para mejorar los resultados de las previsiones.

Bibliografía referenciada

- Abraham, A. y Nath, B. 1996. «*A Neuro-Fuzzy Approach for Modelling Electricity Demand in Victoria*». *Applied Soft Computing*, 1(2), 127-138.
- Adams, G.; Allen, P. G. y Morzuch, B. J. 1991. «*Probability distributions of short-term electricity peak load forecasts*». *International Journal of Forecasting* 7 (3): 283-297. [https://doi.org/10.1016/0169-2070\(91\)90003-E](https://doi.org/10.1016/0169-2070(91)90003-E).
- Aguiló, E.; Alegre, J. y Sard, M. 2005. «*The persistence of the sun and sand tourism model*». *Tourism Management* 26 (2): 219-231. <https://doi.org/10.1016/j.tourman.2003.11.004>.
- Ahmad, A. S.; Hassan, M. Y.; Abdullah, M. P.; Rahman, H. A.; Hussin, F.; Abdullah, H. y Saidur, R. 2014. «*A review on applications of ANN and SVM for building electrical energy consumption forecasting*». *Renewable and Sustainable Energy Reviews* 33: 102-109. <https://doi.org/10.1016/j.rser.2014.01.069>.
- Al-Musaylh, M. S.; Deo, R. C.; Adamowski, J. F. y Li, Y. 2018. «*Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia*». *Advanced Engineering Informatics* 35: 1-16. <https://doi.org/10.1016/j.aei.2017.11.002>.
- Alfares, H. K. y Nazeeruddin, M. 2002. «*Electric load*

-
- forecasting: Literature survey and classification of methods». International Journal of Systems Science 33 (1): 23-34. <https://doi.org/10.1080/00207720110067421>.*
- Amjady, N. 2006. «*Day-Ahead Price Forecasting of Electricity Markets by a New Fuzzy Neural Network*». *IEEE Transactions on Power Systems* 21 (2): 887-896. <https://doi.org/10.1109/TPWRS.2006.873409>.
- Aneiros-Pérez, G.; Cao, R. y Vilar-Fernández, J. M. 2011. «*Functional methods for time series prediction: a nonparametric approach*». *Journal of Forecasting* 30 (4): 377-392. <https://doi.org/10.1002/for.1169>.
- Aneiros-Pérez, G. y Vieu, P. 2008. «*Nonparametric time series prediction: a semifunctional partial linear modeling*». *J. Multivar Anal* 99: 834-857. <https://doi.org/10.1016/j.jmva.2007.04.010>.
- Aneiros, G.; Vilar, J. M.; Cao, R. y Muñoz San Roque, A. 2013. «*Functional Prediction for the Residual Demand in Electricity Spot Markets*». *IEEE Transactions on Power Systems* 28 (4): 4201-4208. <https://doi.org/10.1109/TPWRS.2013.2258690>.
- Aneiros, G.; Vilar, J. M. y Raña, P. 2016a. «*Short-term forecast of daily curves of electricity demand and price*». *International Journal of Electrical Power & Energy Systems* 80: 96-108. <https://doi.org/10.1016/j.ijepes.2016.01.034>.
- Aneiros, G.; Vilar, J. M. y Raña, P. 2016b. «*Short-term forecast of daily curves of electricity demand and price*». *International Journal of Electrical Power & Energy Systems* 80 (septiembre): 96-108. <https://doi.org/10.1016/J.IJEPES.2016.01.034>.
- Antoch, J.; Prchal, L.; Rosa, M. R. y Sarda, P. 2008. «*Functional Linear Regression with Functional Response: Application to Prediction of Electricity Consumption*». En *International Workshop on Functional and Operatorial Statistics*, 23-29. Heidelberg: Physica-Verlag HD.
- Aoki, M. 1989. «*A two-step state space time series modeling*

- method*». *Computers & Mathematics with Applications* 17 (8-9): 1165-1176. [https://doi.org/10.1016/0898-1221\(89\)90087-4](https://doi.org/10.1016/0898-1221(89)90087-4).
- Archer, B.; Cooper, C. y Ruhanen, L. 2005. «*The positive and negative impacts of tourism.*» En *Global tourism*, 3rd editio, 79-102. Burlington, MA: Elsevier.
- Archibald, B. C. 1990. «*Parameter space of the Holt–Winters’ model*». *International Journal of Forecasting* 6: 199-210.
- Archibald, B. C. y Koehler, A. B. 2003. «*Normalization of seasonal factors in Winters’ methods*». *Int. J. Forecast.* 19: 143-148. <https://doi.org/10.1039/a809703h>.
- Aries, M. B.C. y Newsham, G. R. 2008. «*Effect of daylight saving time on lighting energy use: A literature review*». *Energy Policy* 36 (6): 1858-1866. <https://doi.org/10.1016/j.enpol.2007.05.021>.
- Armstrong, J. S. y Fildes, R. 2006. «*Making progress in forecasting*». *International Journal of Forecasting* 22 (3): 433-441. <https://doi.org/10.1016/J.IJFORECAST.2006.04.007>.
- Arocena, P.; Kühn, K. U. y Regibeau, P. 1999. «*Regulatory reform in the Spanish electricity industry: A missed opportunity for competition*». *Energy Policy* 27 (7): 387-399. [https://doi.org/10.1016/S0301-4215\(99\)00024-5](https://doi.org/10.1016/S0301-4215(99)00024-5).
- Arora, S. y Taylor, J. W. 2013. «*Short-term forecasting of anomalous load using rule-based triple seasonal methods*». *IEEE Transactions on Power Systems* 28 (3): 3235-3242. <https://doi.org/10.1109/TPWRS.2013.2252929>.
- Arora, S. y Taylor, J. W. 2018a. «*Short-term Load Forecasting for Special Days Using Rule-based Models: A Case Study for France*». *European Journal of Operational Research*. <http://eureka.sbs.ox.ac.uk/6796/>.
- Arora, S. y Taylor, J. W. 2018b. «*Rule-based autoregressive moving average models for forecasting load on special days: A case study for France*». *European Journal of*

Operational Research 266 (1): 259-268.
<https://doi.org/10.1016/j.ejor.2017.08.056>.

Asbury, C. E. 1975. «Weather load model for electric demand and energy forecasting». *IEEE Transactions on Power Apparatus and Systems* 94 (4): 1111-1116.
<https://doi.org/10.1109/T-PAS.1975.31945>.

Athanasopoulos, G. y Hyndman, R. J. 2011. «The value of feedback in forecasting competitions». *International Journal of Forecasting* 27 (3): 845-849.
<https://doi.org/10.1016/j.ijforecast.2011.03.002>.

Bajet, C.; García, M. y Mundó, J. 2018. «El precio de la energía, factor clave en el aumento de la pobreza energética». *Dossier Catalunya Social*. Barcelona.

Bakhat, M. y Rosselló, J. 2011. «Estimation of tourism-induced electricity consumption: The case study of Balearics Islands, Spain». *Energy Economics* 33 (3): 437-444.
<https://doi.org/10.1016/J.ENECO.2010.12.009>.

Baliyan, A.; Gaurav, K. y Kumar Mishra, S. 2015. «A review of short term load forecasting using artificial neural network models». *Procedia Computer Science* 48 (C): 121-125.
<https://doi.org/10.1016/j.procs.2015.04.160>.

Barman, M. y Dev Choudhury, N. B. 2019. «Season specific approach for short-term load forecasting based on hybrid FA-SVM and similarity concept». *Energy* 174: 886-896.
<https://doi.org/10.1016/j.energy.2019.03.010>.

Barman, M.; Dev Choudhury, N. B. y Sutradhar, S. 2018. «A regional hybrid GOA-SVM model based on similar day approach for short-term load forecasting in Assam, India». *Energy* 145: 710-720. <https://doi.org/10.1016/j.energy.2017.12.156>.

Barnett, S. y Cameron, R.G. 1985. *Introduction to Mathematical Control Theory*. 2nd editio. Oxford: Oxford University Press.

Mercado Mayorista de Electricidad : El Caso de España».

- Beato Blanco, P. 2005. «*La Liberalización Del Sector Eléctrico En España ¿Un Proceso Incompleto O Frustrado?*» 75 AÑOS DE POLÍTICA ECONÓMICA ESPAÑOLA Noviembre 2005. N.º 826, 2005.
- Becken, S. y Simmons, D. G. 2002. «*Understanding energy consumption patterns of tourist attractions and activities in New Zealand*». *Tourism management* 23 (4): 343-354. [https://doi.org/10.1016/S0261-5177\(01\)00091-7](https://doi.org/10.1016/S0261-5177(01)00091-7).
- Bel, G.; Calzada, J. y Fageda, X. 2006. «*Liberalización y competencia en España: ¿dónde estamos?*» *Información Comercial Española, ICE: Revista de economía*, n.º 829 (enero): 123-144.
- Bell, W. R. y Hillmer, S. C. 1984. «*Issues Involved With the Seasonal Adjustment of Economic Time Series*». *Journal of Business & Economic Statistics* 2 (4): 291-320. <https://doi.org/10.1080/07350015.1984.10509398>.
- Bermúdez, J. D. 2013. «*Exponential smoothing with covariates applied to electricity demand forecast*». *European Journal of Industrial Engineering* 7 (3): 333-349. <https://doi.org/10.1504/EJIE.2013.054134>.
- Bermúdez, J. D.; Corberán-Vallet, A. y Vercher, E. 2009a. «*Multivariate exponential smoothing: A Bayesian forecast approach based on simulation*». *Mathematics and Computers in Simulation* 79 (5): 1761-1769. <https://doi.org/10.1016/j.matcom.2008.09.004>.
- Bermúdez, J. D.; Corberán-Vallet, A. y Vercher, E. 2009b. «*Forecasting time series with missing data using Holt's model*». *Journal of Statistical Planning and Inference* 139 (8): 2791-2799. <https://doi.org/10.1016/j.jspi.2009.01.004>.
- Bianco, V.; Manca, O. y Nardini, S. 2009. «*Electricity consumption forecasting in Italy using linear regression models*». *Energy* 34 (9): 1413-1421. <https://doi.org/10.1016/J.ENERGY.2009.06.034>.

-
- Billah, B.; Hyndman, R. J. y Koehler, A. B. 2005. «*Empirical information criteria for time series forecasting model selection*». *Journal of Statistical Computation and Simulation* 75 (10): 831-840.
- Billah, B.; King, M. L.; Snyder, R. D. y Koehler, A. B. 2006. «*Exponential smoothing model selection for forecasting*». *International Journal of Forecasting* 22 (2): 239-247. <https://doi.org/10.1016/j.ijforecast.2005.08.002>.
- BOIB. 2005. «*Aprobación definitiva de la revisión del Plan Director Sectorial Energético de las Illes Balears*». SPAIN: CONSEJERÍA DE COMERCIO, INDUSTRIA Y ENERGÍA.
- Booranawong, T. y Booranawong, A. 2018. «*Double exponential smoothing and Holt-Winters methods with optimal initial values and weighting factors for forecasting lime, Thai chili and lemongrass prices in Thailand*». *Engineering and Applied Science Research* 45 (1): 32-38. https://doi.org/10.1007/978-3-319-04093-6_7.
- Bordignon, S.; Bunn, D. W.; Lisi, F. y Nan, F. 2013. «*Combining forecasts for electricity prices*». *Energy Economics* 35: 88-103. <https://doi.org/10.1016/j.eneco.2011.12.001>.
- Bowerman, B. L.; Koehler, A. B. y Pack, D. J. 1990. «*Forecasting time series with increasing seasonal variation*». *Journal of Forecasting* 9: 419-436. <https://doi.org/10.1002/for.3980090502>.
- Bowerman, B. L.; O'Connell, R. T. y Koehler, A. B. 2005. *Forecasting, time series, and regression: an applied approach*. Thomson Brooks/Cole.
- Box, G. E. P. y Jenkins, G. M. 1976. *Time series analysis: forecasting and control*. Holden-Day.
- Box, G. E. P.; Jenkins, G. M.; Reinsel, G. C. y Ljung, G. M. L. 1994. *Time Series Analysis: Forecasting & Control*. Prentice Hall.
- Boylan, J. E.; Goodwin, P.; Mohammadipour, M. y Syntetos, A.

- A. 2015. «*Reproducibility in forecasting research*». *International Journal of Forecasting* 31 (1): 79-90. <https://doi.org/10.1016/j.ijforecast.2014.05.008>.
- Brockwell, P. J. y Davis, R. A. 1991. *Time Series: Theory and Methods*.
- Brockwell, P. J. y Davis, R. A. 2002. *Introduction to Time Series and Forecasting. Technometrics*. <https://doi.org/10.2307/1271510>.
- Brown, R. G. 1959. *Statistical forecasting for inventory control*. New York: McGraw-Hill.
- Bruhns, A.; Deurveilher, G. y Roy, J.S. 2005. «*A non-linear regression model for mid-term load forecasting and improvements in seasonality*». En *Proceedings from PSCC'05 in Liège*, 22-26.
- Bunn, D. W. y Farmer, E.D. 1985. «*Comparative models for electrical load forecasting*». John Wiley and Sons Inc., New York, NY. <https://www.osti.gov/scitech/biblio/6256333>.
- Caiado, J.; Crato, N. y Peña, D. 2006. «*A periodogram-based metric for time series classification*». *Computational Statistics & Data Analysis* 50 (50): 2668-2684. <https://doi.org/10.1016/j.csda.2005.04.012>.
- Cancelo, J. R. y Espasa, A. 1991a. «*Forecasting daily demand for electricity with multiple-input nonlinear transfer function models: a case study*». 91-121. Madrid, Spain.
- Cancelo, J. R. y Espasa, A. 1991b. «*Threshold modelling of nonlinear dynamic relationships: an application to a daily series of economic activity*». 91-105. Madrid, Spain.
- Cancelo, J. R. y Espasa, A. 1995. «*Modelización del efecto temperatura en el consumo de electricidad: un ejercicio de búsqueda de especificación en relaciones dinámicas no lineales*». *ESTADÍSTICA ESPAÑOLA* 37 (139): 183-200.
- Cancelo, J. R. y Espasa, A. 1996. «*Modelling and Forecasting Daily Series of Electricity Demand*». *Investigaciones Economicas* 20: 359-376.

-
- Cancelo, J. R.; Espasa, A. y Grafe, R. 2008. «*Forecasting the electricity load from one day to one week ahead for the Spanish system operator*». *International Journal of Forecasting* 24 (4): 588-602. <https://doi.org/http://dx.doi.org/10.1016/j.ijforecast.2008.07.005>.
- Castaño, E. 2007. «*Reconstrucción de datos de series de tiempo: una aplicación a la demanda horaria de la electricidad*». *Revista Colombiana de Estadística* 30: 247-263.
- Chatfield, C. 1978. «*The Holt-Winters forecasting procedure*». *Applied Statistics* 27: 264-279.
- Chatfield, C. 1996. «*Model uncertainty and forecast accuracy*». *Journal of Forecasting* 15 (7): 495-508. [https://doi.org/10.1002/\(SICI\)1099](https://doi.org/10.1002/(SICI)1099)
- Chatfield, C. 2000. *Time-Series Forecasting*. Chapman & Hall/CRC. www.crcpress.com.
- Chatfield, C. y Yar, M. 1991. «*Prediction intervals for multiplicative Holt-Winters*». *International Journal of Forecasting* 7 (1): 31-37. [https://doi.org/10.1016/0169-2070\(91\)90030-Y](https://doi.org/10.1016/0169-2070(91)90030-Y).
- Chen, B.-J.; Chang, M.-W. y Lin, C.-J. 2004. «*Load forecasting using support vector Machines: a study on EUNITE competition 2001*». *Power Systems, IEEE Transactions on* 19 (4): 1821-1830. <https://doi.org/10.1109/TPWRS.2004.835679>.
- Chicco, G.; Napoli, R. y Piglione, F. 2001. «*Load pattern clustering for short-term load forecasting of anomalous days*». En *2001 IEEE Porto Power Tech Proceedings*, 2:217-222. <https://doi.org/10.1109/PTC.2001.964745>.
- Christiaanse, W. R. 1971. «*Short-term load forecasting using general exponential smoothing*». *IEEE Transactions on Power Apparatus and Systems* PAS-90 (2): 900-911. <https://doi.org/10.1109/TPAS.1971.293123>.
- Cifter, A. 2013. «*Forecasting electricity price volatility with the*

- Markov-switching GARCH model: Evidence from the Nordic electric power market*». *Electric Power Systems Research* 102: 61-67. <https://doi.org/10.1016/j.epsr.2013.04.007>.
- Cipra, T. 1989. «*Some problems of exponential smoothing*». *Aplikace matematiky* 34 (2): 161-169.
- Cipra, T. y Hanzák, T. 2011. «*Exponential smoothing for time series with outliers*». *Kybernetika* 47 (1): 165-178. <http://dml.cz/dmlcz/141565>.
- Cipra, T.; Trujillo, J. y Robio, A. 1995. «*Holt-Winters Method with Missing Observations*». *Management Science* 41 (1): 174-178. <https://doi.org/10.1287/mnsc.41.1.174>.
- Cleveland, R. B.; Cleveland, W.S.; McRae, J. E. y Terpenning, I. 1990. «*STL: A seasonal-trend decomposition procedure based on loess*». *Journal of Official Statistics* 6 (1): 3-73.
- Čobanov, A. 2018. «*Seasonal Adjustment of Time Series and Calendar Influence on Economic Activity*». *Surveys*. <https://www.hnb.hr/documents/20182/2431070/s-033.pdf/e3ea1025-7dc1-4307-b6c7-2f4928dfc078>.
- Conejo, A. J.; Contreras, J.; Espínola, Rosa y Plazas, M. A. 2005. «*Forecasting electricity prices for a day-ahead pool-based electric energy market*». *Int. J. Forecast.*, n.º 21: 435-462.
- Contreras, J.; Espinola, R.; Nogales, F. J. y Conejo, A. J. 2003. «*ARIMA models to predict next-day electricity prices*». *IEEE Transactions on Power Systems* 18 (3): 1014-1020. <https://doi.org/10.1109/TPWRS.2002.804943>.
- Contreras, J. y Santos, J. R. 2006. «*Short-term Demand and Energy Price Forecasting*». En *MELECON 2006 - 2006 IEEE Mediterranean Electrotechnical Conference*, 924-927. IEEE. <https://doi.org/10.1109/MELCON.2006.1653249>.
- Cooper, P. 1973. «*Time-Varying Regression Coefficients: A mixed estimation approach and operational limitations of the general markov structure*». *Anns. Econ. Soc. Meas.* 2

(4): 397-428.

Corberán-Vallet, A.; Bermúdez, J. D. y Vercher, E. 2011. «*Forecasting correlated time series with exponential smoothing models*». *International Journal of Forecasting* 27 (2): 252-265. <https://doi.org/10.1016/j.ijforecast.2010.06.003>.

Corpening, S.; Reppen, N.D. y Ringlee, R.J. 1973. «*Experience with Weather Sensitive Load Models for Short and Long-Term Forecasting*». *IEEE Transactions on Power Apparatus and Systems* PAS-92 (6): 1966-1972. <https://doi.org/10.1109/TPAS.1973.293576>.

Cortés, C. y Vapnik, V. 1995. «*Support Vector Networks*». *Machine Learning* 20 (3): 273-297. <https://doi.org/10.1007/BF00994018>.

Croux, C.; Gelper, S. y Fried, R. 2008. «*Computational aspects of robust Holt-Winters smoothing based on M-estimation*». *Applications of mathematics* 53 (3): 163-176.

Czernichow, T.; Piras, A.; Imhof, K.; Caire, P.; Jaccard, Y.; Dorizzi, B. y Germond, A. 1996. «*Short term electrical load forecasting with artificial neural networks*». *Engineering Intelligent Systems for Electrical Engineering and Communications* 4 (85): 85-99. <https://infoscience.epfl.ch/record/102189>.

Damborg, M. J.; El-Sharkawi, M. A.; Aggoune, M. E. y Marks, R. J. 1990. «*Potential of artificial neural networks in power system operation*». En *IEEE International Symposium on Circuits and Systems*, 2933-2937.

Darbellay, G.s A. y Slama, M. 2000. «*Forecasting the short-term demand for electricity: Do neural networks stand a better chance?*». *International Journal of Forecasting* 1 (16): 71-83.

Deoras, A. 2010. «*Electricity Load and Price Forecasting with MATLAB [Webinar]*». 2010. <https://www.mathworks.com/videos/electricity-load-and-price-forecasting-with-matlab-81765.html>.

- Diebold, F. X. y Mariano, R. S. 1995. «*Comparing Predictive Accuracy*». *Journal of Business & Economic statistics* 13: 253-263.
- Diebold, F. X. y Mariano, R. S. 2002. «*Comparing predictive accuracy*». *Journal of Business & Economic Statistics* 20 (1).
- Dilaver, Z. y Hunt, L. C. 2011. «*Industrial electricity demand for Turkey: A structural time series analysis*». *Energy Economics* 33 (3): 426-436. <https://doi.org/10.1016/J.ENECO.2010.10.001>.
- Domínguez, E. Fernández y Bernat, J. X. 2007. «*Restructuring and generation of electrical energy in the Iberian Peninsula*». *Energy Policy* 35 (10): 5117-5129. <https://doi.org/10.1016/j.enpol.2007.04.028>.
- Dordonnat, V.; Koopman, S. J. y Ooms, M. 2012. «*Dynamic factors in periodic time-varying regressions with an application to hourly electricity load modelling*». *Computational Statistics & Data*.
- Dordonnat, V.; Koopman, S. J.; Ooms, M; Dessertaine, A. y Collet, J. 2008. «*An hourly periodic state space model for modelling French national electricity load*». *International Journal of Forecasting* 24 (4): 566-587. <https://doi.org/10.1016/j.ijforecast.2008.08.010>.
- Dudek, G. 2015a. «*Pattern similarity-based methods for short-term load forecasting – Part 1 : Principles*». *Applied Soft Computing* 37: 277-287. <https://doi.org/10.1016/j.asoc.2015.08.040>.
- Dudek, G. 2015b. «*Pattern similarity-based methods for short-term load forecasting – Part 2 : Models*». *Applied Soft Computing Journal* 36: 422-441. <https://doi.org/10.1016/j.asoc.2015.07.035>.
- Dudek, G. 2016. «*Pattern-based local linear regression models for short-term load forecasting*». *Electric Power Systems Research* 130. <https://doi.org/10.1016/j.ejpsr.2015.09.001>.

-
- Durbin, J. 1960. «*The fitting of time-series models*». *JSTOR* 28 (3): 233-244. <https://doi.org/10.2307/1401322>.
- Engle, R. F. 1982. «*Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation*». *Econometrica* 50 (4): 987-1007.
- Engle, R. F.; Hendry, D. F. y Richard, J.-F. 1983. «*Exogeneity*». *Econometrica* 51 (2): 277-304. <https://doi.org/10.2307/1911990>.
- Engle, R. F. y Mustafa, C. 1992. «*Implied ARCH models from options prices*». *Journal of Econometrics* 52 (1-2): 289-311. [https://doi.org/10.1016/0304-4076\(92\)90074-2](https://doi.org/10.1016/0304-4076(92)90074-2).
- Engle, R. F.; Mustafa, C. y Rice, J., 1992. «*Modelling peak electricity demand*». *Journal of Forecasting* 11 (3): 241-251. <https://doi.org/10.1002/for.3980110306>.
- Ernoul, M.; Mattatia, R.; Meslier, F. y Rabut, P. 1983. «*Estimation of the sensitivity of the electrical energy demand to variations in meteorological conditions: History of methods and development of new approaches at EDF*». *International Journal of Electrical Power & Energy Systems* 5 (3): 189-198.
- Espasa, A. 1980. *La predicción económica*. Banco de España, Servicio de Estudios.
- Espasa, A.; Revuelta, J. M. y Cancelo, J. R. 1996. «*Automatic modelling of daily series of economic activity*». En *Computational Statistics 12th Symposium*, 51-63.
- Espínola, R.; Contreras, J.; Nogales, F. J y Conejo, A. J. 2002. «*Day-ahead electricity price forecasting based on time series models: a comparison*». En *14th Power Systems Computation Conferece*. https://www.psc-central.org/uploads/tx_ethpublications/s15p06.pdf.
- Fabra, N. y Toro, J. 2005. «*Price wars and collusion in the Spanish electricity market*». *International Journal of Industrial Organization* 23 (3-4): 155-181. <https://doi.org/10.1016/j.ijindorg.2005.01.004>.

- Fallah, S.; Ganjkhani, M.; Shamshirband, S.; Chau, K.-W.; Fallah, S. N.; Ganjkhani, M.; Shamshirband, S. y Chau, K.-W. 2019. «*Computational Intelligence on Short-Term Load Forecasting: A Methodological Overview*». *Energies* 12 (3): 393. <https://doi.org/10.3390/en12030393>.
- Faraway, J. y Chatfield, C. 1995. «*Time Series Forecasting with Neural Networks: A Case Study*».
- Faraway, J. y Chatfield, C. 1998. «*Time series forecasting with neural networks: a comparative study using the air line data*». *Applied Statistics* 47 (2): 231-250. <https://doi.org/10.1111/1467-9876.00109>.
- Felice, M.; Alessandri, A. y Catalano, F. 2015. «*Seasonal climate forecasts for medium-term electricity demand forecasting*». *Applied Energy* 137: 435-444. <https://doi.org/10.1016/j.apenergy.2014.10.030>.
- Felice, M.; Alessandri, A. y Ruti, P. M. 2013. «*Electricity demand forecasting over Italy: Potential benefits using numerical weather prediction models*». *Electric Power Systems Research* 104 (noviembre): 71-79. <https://doi.org/10.1016/j.epsr.2013.06.004>.
- Feng, Y. y Ryan, S. M. 2016. «*Day-ahead hourly electricity load modeling by functional regression*». *Applied Energy* 170: 455-465. <https://doi.org/10.1016/j.apenergy.2016.02.118>.
- Fidalgo, J.N. N y Lopes, J.A. 2005. «*Load Forecasting Performance Enhancement When Facing Anomalous Events*». *IEEE Transactions on Power Systems* 20 (1): 408-415. <https://doi.org/10.1109/TPWRS.2004.840439>.
- Fildes, R.; Nikolopoulos, K.; Crone, S. F. y Syntetos, A. A. 2008. «*Forecasting and operational research: A review*». *Journal of the Operational Research Society* 59 (9): 1150-1172. <https://doi.org/10.1057/palgrave.jors.2602597>.
- Findley, D. F.; Monsell, B. C.; Bell, W.R.; O., M. C. y Chen, B.-C. 1996. «*New Capabilities and Methods of the X-1 2-ARIMA Seasonal-Adjust*». *Journal of Business & Economic statistics* 16 (2): 127-152.

-
- Flores, B. E. y Whybark, D. C. 1986. «*A Comparison of focus forecasting with averaging and exponential smoothing.*» *Production and Inventory Management Journal* 27: 96-103.
- Gaillard, P.; Goude, Y. y Nedellec, R. 2016. «*Additive models and robust aggregation for GEFCom2014 probabilistic electric load and electricity price forecasting.*» *International Journal of Forecasting* 32 (3). <https://doi.org/10.1016/j.ijforecast.2015.12.001>.
- García-Díaz, J. C. y Trull, O. 2016. «*Competitive Models for the Spanish Short-Term Electricity Demand Forecasting.*» En *Time Series Analysis and Forecasting: Selected Contributions from the ITISE Conference*, editado por Rojas, I. y Pomares, H., 217-231. Cham: Springer International Publishing. https://doi.org/10.1007/978-3-319-28725-6_17.
- García, Reinaldo C.; Contreras, J.; Akkeren, M. y Garcia, J.B. C. 2005. «*A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices.*» *IEEE Transactions on Power Systems* 20 (2): 867-874. <https://doi.org/10.1109/TPWRS.2005.846044>.
- Gardner Jr., E. S. 1985. «*Exponential smoothing: The state of the art.*» *Journal of Forecasting*, n.º 4: 1-28.
- Gardner Jr., E. S. 1988. «*A Simple Method of Computing Prediction Intervals for Time Series Forecasts.*» *Management Science* 34 (4): 541-546. <https://doi.org/10.1287/mnsc.34.4.541>.
- Gardner Jr., E. S. 2006. «*Exponential smoothing: The state of the art - Part II.*» *International Journal of Forecasting* 22 (4): 637-666. <https://doi.org/10.1016/j.ijforecast.2006.03.005>.
- Gardner Jr., E. S.; Anderson-Fletcher, E. A. y Wicks, A. M. 2001. «*Further results on focus forecasting vs. exponential smoothing.*» *International Journal of Forecasting* 17 (2): 287-293.
- Gardner Jr., E. S. y McKenzie, E. 1985. «*Forecasting Trends in Time Series.*» *Management Science* 31 (10): 1237-1246.

- <https://doi.org/10.2307/2631713>.
- Gardner Jr., E. S. y McKenzie, E. 1989. «*Seasonal Exponential Smoothing with Damped Trends*». *Management Science* 35 (3): 372-376. <https://doi.org/10.1287/mnsc.35.3.372>.
- Gardner Jr., E. S. y McKenzie, E. 2011. «*Why the damped trend works*». *Journal of the Operational Research Society* 62 (6): 1177-1180. <https://doi.org/10.1057/jors.2010.37>.
- Gardner Jr., E. S. y Mckenzie, E. 1988. «*Model Identification in Exponential Smoothing*». *Source: The Journal of the Operational Research Society J. Opi Res. Soc* 39 (9): 863-867. <https://doi.org/10.2307/2583529>.
- Garrués-Irurzun, J. y López-García, S. 2009. «*Red Eléctrica de España S.A.: Instrument of regulation and liberalization of the Spanish electricity market (1944-2004)*». *Renewable and Sustainable Energy Reviews* 13 (8): 2061-2069. <https://doi.org/10.1016/j.rser.2009.01.028>.
- Gelper, S.; Fried, R. y Croux, C. 2010. «*Robust forecasting with exponential and holt-winters smoothing*». *Journal of Forecasting* 29 (3): 285-300. <https://doi.org/10.1002/for.1125>.
- Gilchrist, W. 1976. *Statistical forecasting*. Vol. 322. Wiley London.
- Göb, R.; Lurz, K. y Pievatolo, A. 2015. «*More Accurate Prediction Intervals for Exponential Smoothing with Covariates with Applications in Electrical Load Forecasting and Sales Forecasting*». *Quality and Reliability Engineering International* 31 (4): 669-682. <https://doi.org/10.1002/qre.1625>.
- Gobierno de España. Ministerio de Industria Energía y Turismo. 2014. «*Real Decreto 216/2014, de 28 de marzo, por el que se establece la metodología de cálculo de los precios voluntarios para el pequeño consumidor de energía eléctrica y su régimen jurídico de contratación*». *Boletín Oficial del Estado* 77 (Sec. I): 27397-27428. <https://www.boe.es/boe/dias/2014/03/29/pdfs/BOE-A->

2014-3376.pdf.

Gobierno de España. 1994. «*Ley 40/1994, de 30 de diciembre, de ordenación del Sistema Eléctrico Nacional*», 39362-39386.

Gobierno de España. 1997. «*Ley 54/1997, de 27 noviembre. del Sector Eléctrico.*»

Gobierno de España. 2007. «*Ley 17/2007, de 4 de julio, por la que se modifica la Ley 54/1997, de 27 de noviembre, del Sector Eléctrico, para adaptarla a lo dispuesto en la Directiva 2003/54/CE, del Parlamento Europeo y del Consejo, de 26 de junio de 2003, sobre normas comunes para*».

Gobierno de España. 2013. «*Ley 24/2013, de 26 de Diciembre, del Sector Eléctrico.*» *Boletín Oficial de Estado* 310: 105198-294. https://doi.org/Ley_24/2013, de 26 de diciembre, del Sector Eléctrico.

Gómez, V. y Maravall, A. 2011. «*Automatic Modeling Methods for Univariate Series*». En , 171-201. Wiley-Blackwell. <https://doi.org/10.1002/9781118032978.ch7>.

Gómez, V. y Maravall, A. 1994. «*Estimation, prediction, and interpolation for nonstationary series with the kalman filter*». *Journal of the American Statistical Association* 89 (426): 611-624. <https://doi.org/10.1080/01621459.1994.10476786>.

Gómez, V. y Maravall, A. 1997. «*Programs TRAMO(Time Series Regression with ARIMA Noise, Missing Observations and Outliers) and SEATS (Signal Extractions ARIMA Time Series). Instructions for the user (beta version: junio 1997)*». <http://www.bde.es>.

Gómez, V. y Maravall, A. 1998. «*Seasonal Adjustment and Signal Extraction in Economic Time Series*». *Working Papers*. <https://ideas.repec.org/p/bde/wpaper/9809.html>.

Gómez, V.; Maravall, A. y Peña, D. 1999. «*Missing observations in ARIMA models: Skipping approach versus additive outlier approach*». *Journal of Econometrics* 88 (2): 341-

363. [https://doi.org/10.1016/S0304-4076\(98\)00036-0](https://doi.org/10.1016/S0304-4076(98)00036-0).
- Gonzalez-Romera, E.; Jaramillo-Moran, M.A. y Carmona-Fernandez, D. 2006. «*Monthly Electric Energy Demand Forecasting Based on Trend Extraction*». *IEEE Transactions on Power Systems* 21 (4): 1946-1953. <https://doi.org/10.1109/TPWRS.2006.883666>.
- González-Romera, E.; Jaramillo-Morán, M.A. y Carmona-Fernández, D. 2008. «*Monthly electric energy demand forecasting with neural networks and Fourier series*». *Energy Conversion and Management* 49 (11): 3135-3142. <https://doi.org/10.1016/J.ENCONMAN.2008.06.004>.
- González, V.; Contreras, J. y Bunn, D. W. 2012. «*Forecasting power prices using a hybrid fundamental-econometric model*». *IEEE Transactions on Power Systems* 27 (1): 363-372. <https://doi.org/10.1109/TPWRS.2011.2167689>.
- Gössling, S. 2002. «*Global environmental consequences of tourism*». *Global Environmental Change* 12 (4): 283-302. [https://doi.org/10.1016/S0959-3780\(02\)00044-4](https://doi.org/10.1016/S0959-3780(02)00044-4).
- Gössling, S.; Hansson, C.B.; Hörstmeier, O. y Saggel, S. 2002. «*Ecological footprint analysis as a tool to assess tourism sustainability*». *Ecological Economics* 43 (2-3): 199-211. [https://doi.org/10.1016/S0921-8009\(02\)00211-2](https://doi.org/10.1016/S0921-8009(02)00211-2).
- Gould, P. G.; Koehler, A. B.; Ord, J. K.; Snyder, R. D.; Hyndman, R. J. y Vahid-Araghi, F. 2008. «*Forecasting time series with multiple seasonal patterns*». *European Journal of Operational Research* 191 (1): 207-222.
- Granger, C. W. J. y Newbold, P. 1977. «*Forecasting economic time series*». *Economic theory and mathematical economics*, Academic Press.
- Granger, C. W. J. y Newbold, P. 1986. *Forecasting economic time series*. Academic Press.
- Gray, R. y Bebbington, J. 2001. *Accounting for the environment*. Second. London: Sage Publications.
- Greer, M. 2011. «*Electricity Cost Modeling Calculations*». En

ELECTRICITY COST MODELING CALCULATIONS, xv.
Academic Press. <https://doi.org/10.1016/b978-1-85617-726-9.00015-7>.

Groff, G.K. 1973. «*Empirical comparison of models for short range forecasting*». *Management Science* 20 (1): 22-31.

Gross, G. y Galiana, F.D. 1987. «*Short-term load forecasting*». *Proceedings of the IEEE* 75 (12): 1558-1573. <https://doi.org/10.1109/PROC.1987.13927>.

Hahn, H.; Meyer-Nieberg, S. y Pickl, S. 2009. «*Electric load forecasting methods: Tools for decision making*». *European Journal of Operational Research* 199 (3): 902-907. <https://doi.org/10.1016/j.ejor.2009.01.062>.

Harvey, A. C. 1990. *Forecasting, structural time series models and the Kalman filter*. Cambridge university press.

Harvey, A. y Koopman, S. J. 1993. «*Forecasting Hourly Electricity Demand Using Time-Varying Splines*». *Journal of the American Statistical Association* 88 (424): 1228-1253. <https://doi.org/10.1080/01621459.1993.10476402>.

Haykin, S. 1994. *Neural networks : a comprehensive foundation*. Macmillan. <https://dl.acm.org/citation.cfm?id=541500>.

Herce, J. A. 2008. «*La economía de Illes Balears: diagnóstico estratégico*». Barcelona.

Hickey, E.; Loomis, D. G. y Mohammadi, H. 2012. «*Forecasting hourly electricity prices using ARMAX–GARCH models: An application to MISO hubs*». *Energy Economics* 34 (1): 307-315. <https://doi.org/10.1016/J.ENECO.2011.11.011>.

Hill, S.I.; Desobry, F.; Garnsey, E.W. y Chong, Y.-F. 2010. «*The impact on energy consumption of daylight saving clock changes*». *Energy Policy* 38 (9): 4955-4965. <https://doi.org/10.1016/j.enpol.2010.03.079>.

Hippert, H. S.; Bunn, D. W. y Souza, R. C. 2005. «*Large neural networks for electricity load forecasting: Are they overfitted?*» *International Journal of Forecasting* 21 (3): 425-434. <https://doi.org/10.1016/j.ijforecast.2004.12.004>.

- Hippert, H.S.; Pedreira, C.E. y Souza, R.C. 2001. «*Neural networks for short-term load forecasting: a review and evaluation*». *IEEE Transactions on Power Systems* 16 (1): 44-55. <https://doi.org/10.1109/59.910780>.
- Hobbs, B. F. 1999. «*Analysis of the value for unit commitment of improved load forecasts*». *IEEE Transactions on Power Systems* 14 (4): 1342-1348. <https://doi.org/10.1109/59.801894>.
- Holt, C. C. 1957. «*Forecasting seasonals and trends by exponentially weighted averages*». En *O.N.R. Memorandum*. Vol. 52. Carnegie Institute of Technology.
- Holt, C. C. 2004. «*Forecasting seasonals and trends by exponentially weighted moving averages*». *International Journal of Forecasting* 20 (1): 5-10. <https://doi.org/10.1016/J.IJFORECAST.2003.09.015>.
- Hong, T. 2015. «*Crystal Ball Lessons in Predictive Analytics*». *Energybiz* 12 (2): 35-37.
- Hong, T. y Fan, S. 2016. «*Probabilistic electric load forecasting: A tutorial review*». *International Journal of Forecasting* 32 (3): 914-938. <https://doi.org/10.1016/j.ijforecast.2015.11.011>.
- Hong, T.; Pinson, P.; Fan, S.; Zareipour, H.; Troccoli, A. y Hyndman, R. J. 2016. «*Probabilistic energy forecasting: Global Energy Forecasting Competition 2014 and beyond*». *International Journal of Forecasting*. <https://doi.org/10.1016/j.ijforecast.2016.02.001>.
- Hong, T.; Xie, J. y Black, J. 2019. «*Global energy forecasting competition 2017: Hierarchical probabilistic load forecasting*». *International Journal of Forecasting*. <https://doi.org/10.1016/j.ijforecast.2019.02.006>.
- Hong, W. C.; Dong, Y.; Zang, W. Y.; Chen, L. Y. y Panigrahi, B. K. 2013. «*Electrical Power and Energy Systems Cyclic electric load forecasting by seasonal SVR with chaotic genetic algorithm*». *International Journal of Electrical Power and Energy Systems* 44 (1): 604-614.

<https://doi.org/10.1016/j.ijepes.2012.08.010>.

Hong, W. C. y Fan, G. F. 2019. «*Hybrid Empirical Mode Decomposition with Support Vector Regression Model for Short Term Load Forecasting*». *Energies* 12 (6): 1093. <https://doi.org/10.3390/en12061093>.

Hor, C. L.; Watson, S. J. y Majithia, S. 2006. «*Daily load forecasting and maximum demand estimation using ARIMA and GARCH*». 2006 9th International Conference on Probabilistic Methods Applied to Power Systems, PMAPS, n.º May. <https://doi.org/10.1109/PMAPS.2006.360237>.

Hyde, O. y Hodnett, P. F. 1997. «*An adaptable automated procedure for short-term electricity load forecasting*». *IEEE Transactions on Power Systems* 12 (1): 84-94. <https://doi.org/10.1109/59.574927>.

Hyndman, R. J. 2010. «*Initializing the Holt-Winters method*». Hyndsight. 2010.

Hyndman, R. J. 2019. «*A brief history of forecasting competitions*». *International Journal of Forecasting*, n.º xxxx. <https://doi.org/10.1016/j.ijforecast.2019.03.015>.

Hyndman, R. J.; Akram, M. y Archibald, B. C. 2003. «*Invertibility Conditions for Exponential Smoothing Models*». 3/2003.

Hyndman, R. J.; Akram, M. y Archibald, B. C. 2008. «*The admissible parameter space for exponential smoothing models*». *Annals of the Institute of Statistical Mathematics* 60: 407-426. <https://doi.org/10.1007/s10463-006-0109-x>.

Hyndman, R. J. y Athanasopoulos, G. 2018. *Forecasting: principles and practice*. 2nd Editio. Melbourne, Australia: OTexts.

Hyndman, R. J. y Fan, S. 2010. «*Density Forecasting for Long - Term Peak Electricity Demand*». *Ieee Transactions on Power Systems* 25 (2): 1142-53. <https://doi.org/10.1109/TPWRS.2009.2036017>.

- Hyndman, R. J. y Khandakar, Y. 2008. «Automatic time series forecasting: The forecast package for R». *Journal Of Statistical Software* 27 (3).
<https://doi.org/10.18637/jss.v027.i03>.
- Hyndman, R. J.; Koehler, A. B.; Ord, J. K. y Snyder, R. D. 2005. «Prediction intervals for exponential smoothing using two new classes of state space models». *Journal of Forecasting* 24 (1): 17-37. <https://doi.org/10.1002/for.938>.
- Hyndman, R. J.; Koehler, A. B.; Ord, J. K. y Snyder, R. D. 2008. *Forecasting with exponential smoothing: The State Space Approach*. Editado por Springer. Berlin Heidelberg: Springer.
- Hyndman, R. J. y Kostenko, Andrey V. 2007a. «Minimum sample size requirements for seasonal forecasting models». *Foresight*.
http://www.bishophill.com/admin/sidebar_images/1741759940_test.pdf.
- Hyndman, R. J. y Kostenko, Andrey V. 2007b. «Minimum sample size requirements for seasonal forecasting models». *Foresight* 6 (Spring): 12-15.
- Hyndman, R. J. y Shang, Han Lin. 2009. «Forecasting functional time series». *Journal of the Korean Statistical Society* 38 (3): 199-221.
<https://doi.org/https://doi.org/10.1016/j.jkss.2009.06.002>.
- Hyndman, R. J. y Ullah, Md Shahid. 2007. «Robust forecasting of mortality and fertility rates: A functional data approach». *Computational Statistics and Data Analysis* 51 (10): 4942-4956. <https://doi.org/10.1016/j.csda.2006.07.028>.
- Hyndman, R. J; Koehler, A. B.; Snyder, R. D. y Grose, Simone. 2002. «A state space framework for automatic forecasting using exponential smoothing methods». *International Journal of Forecasting* 18 (3): 439-454.
- Jebaraj, S. y Iniyar, S. 2006. «A review of energy models». *Renewable and Sustainable Energy Reviews* 10 (4): 281-311. <https://doi.org/10.1016/j.rser.2004.09.004>.

-
- Juberias, G.; Yunta, R.; Garcia Moreno, J. y Mendivil, C. 1999. «A new ARIMA model for hourly load forecasting». En 1999 *IEEE Transmission and Distribution Conference (Cat. No. 99CH36333)*, 314-319 vol.1. IEEE. <https://doi.org/10.1109/TDC.1999.755371>.
- Kalekar, P. 2004. «Time series forecasting using Holt-Winters exponential smoothing». *Kanwal Rekhi School of Information Technology*, 1-13. http://www.it.iitb.ac.in/~praj/acads/seminar/04329008_ExponentialSmoothing.pdf.
- Kalman, R. E. 1960. «A New Approach to Linear Filtering and Prediction Problems». *Journal of Basic Engineering* 82 (1): 35. <https://doi.org/10.1115/1.3662552>.
- Karakatsani, N. V. y Bunn, D. W. 2008. «Forecasting electricity prices: The impact of fundamentals and time-varying coefficients». *International Journal of Forecasting* 24 (4): 764-785. <https://doi.org/10.1016/j.ijforecast.2008.09.008>.
- Karanta, I. y Ruusunen, J. 1992. «Modelling the Temperature Factor in Short-term Electrical Load Forecasting». *IFAC Proceedings Volumes* 25 (1): 269-272. [https://doi.org/10.1016/S1474-6670\(17\)50465-6](https://doi.org/10.1016/S1474-6670(17)50465-6).
- Katircioglu, S. T.; Feridun, M. y Kilinc, C. 2014. «Estimating tourism-induced energy consumption and CO2 emissions: The case of Cyprus». *Renewable and Sustainable Energy Reviews* 29 (enero): 634-640. <https://doi.org/10.1016/J.RSER.2013.09.004>.
- Kim, M. S. 2013. «Modeling special-day effects for forecasting intraday electricity demand». *European Journal of Operational Research* 230 (1): 170-180. <https://doi.org/http://dx.doi.org/10.1016/j.ejor.2013.03.039>.

- Koehler, A. B.; Snyder, R. D. y Ord, J. K. 2001. «*Forecasting models and prediction intervals for the multiplicative Holt–Winters method*». *International Journal of Forecasting* 17 (2): 269-286.
[https://doi.org/http://dx.doi.org/10.1016/S0169-2070\(01\)00081-4](https://doi.org/http://dx.doi.org/10.1016/S0169-2070(01)00081-4).
- Koprinska, I.; Rana, M.; Troncoso, A. y Martínez-Álvarez, F. 2013. «*Combining pattern sequence similarity with neural networks for forecasting electricity demand time series*». En *The 2013 International Joint Conference on Neural Networks (IJCNN)*, 1-8.
<https://doi.org/10.1109/IJCNN.2013.6706838>.
- Kotchen, M. J. y Grant, L. E. 2010. «*Does Daylight Saving Time Save Energy? Evidence from a Natural Experiment in Indiana*». *Review of Economics and Statistics* 93 (4): 1172-1185. https://doi.org/10.1162/REST_a_00131.
- Lagarias, J. C.; Reeds, J. A; Wright, M. H y Wright, P. 1998. «*Convergence properties of the nelder--mead simplex method in low dimensions.*» *SIAM Journal on optimization* 9 (1): 112-147.
- Lakhani, H. G. y Bumb, B. 1978. «*Forecasting demand for electricity in Maryland: An econometric approach*». *Technological Forecasting and Social Change* 11 (3): 237-259. [https://doi.org/10.1016/0040-1625\(78\)90064-1](https://doi.org/10.1016/0040-1625(78)90064-1).
- Larrañeta, J.C.; Onieva, L. Y Lozano, S., 1995. *Métodos modernos de gestión de la producción*. Alianza Universidad Textos.
- Latham, J. H.; Nordman, Dean A.; Plant, E. Curtis y Voorhis, J, S. 1968. «*Probability Approach to Electric Utility Load Forecasting*». *IEEE Transactions on Power Apparatus and Systems* PAS-87 (2): 496-504.
<https://doi.org/10.1109/TPAS.1968.292045>.
- Lawton, R. 1998. «*How should additive Holt–Winters estimates be corrected?*» *International Journal of Forecasting* 14 (3): 393-403.

-
- Li, Y.; Che, J. y Yang, Y. 2018. «*Subsampled support vector regression ensemble for short term electric load forecasting*». *Energy* 164: 160-70. <https://doi.org/10.1016/j.energy.2018.08.169>.
- Liebl, D. 2013. «*Modeling and forecasting electricity spot prices: A functional data perspective*». *The Annals of Applied Statistics* 7 (3): 1562-1592. <https://doi.org/10.1214/13-AOAS652>.
- Livera, A.; Hyndman, R. J. y Snyder, R. D. 2011. «*Forecasting time series with complex seasonal patterns using exponential smoothing*». *Journal of the American Statistical Association* 106 (496): 1513-27. <http://www.buseco.monash.edu.au/ebs/pubs/wpapers/2009/wp9-09.pdf>.
- López, M.; Sans, C.; Valero, S. y Senabre, C. 2019. *Classification of Special Days in Short-Term Load Forecasting: The Spanish Case Study*. *Energies*. Vol. 12. <https://doi.org/10.3390/en12071253>.
- López, M.; Valero, S.; Rodríguez, A.; Veiras, I. y Senabre, C. 2018. «*New online load forecasting system for the Spanish Transport System Operator*». *Electric Power Systems Research* 154: 401-412. <https://doi.org/10.1016/j.epsr.2017.09.003>.
- López, M.; Valero, S.; Senabre, C. y Gabaldón, A. 2017. «*Analysis of the Influence of Meteorological Variables on Real-Time Short-Term Load Forecasting in Balearic Islands*». En *11th IEEE International Conference on Compatibility, Power Electronics and Power Engineering, CPE-POWERENG 2017*, 10-15. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/CPE.2017.7915137>.
- Makridakis, S. 1993. «*Accuracy measures: theoretical and practical concerns*». *International Journal of Forecasting* 9 (4): 527-529. [https://doi.org/https://doi.org/10.1016/0169-2070\(93\)90079-3](https://doi.org/https://doi.org/10.1016/0169-2070(93)90079-3).

- Makridakis, S.; Andersen, A.; Carbone, R.; Fildes, R.; Hibon, M.; Lewandowski, R.; Newton, J.; Parzen, E. y Winkler, R. 1982. «*The Accuracy of Extrapolative (Time Series) Methods - Results of a Forecasting Competition*». *Journal of Forecasting* 1 (2): 111-153. <https://doi.org/10.1002/for.3980010202>.
- Makridakis, S.; Assimakopoulos, V. y Spiliotis, E. 2018. «*Objectivity, reproducibility and replicability in forecasting research*». *International Journal of Forecasting* 34 (4): 835-838. <https://doi.org/10.1016/j.ijforecast.2018.05.001>.
- Makridakis, S.; Chatfield, C.; Hibon, M.; Lawrence, M.; Mills, T.; Ord, K. y Simmons, L. F. 1993. «*The M2-competition: A real-time judgmentally based forecasting study*». *International Journal of Forecasting* 9 (1): 5-22. [https://doi.org/10.1016/0169-2070\(93\)90044-N](https://doi.org/10.1016/0169-2070(93)90044-N).
- Makridakis, S. y Hibon, M. 1991. «*Exponential smoothing: The effect of initial values and loss functions on post-sample forecasting accuracy*». *International Journal of Forecasting* 7: 317-330.
- Makridakis, S. y Hibon, M. 2000. «*The M3-Competition: results, conclusions and implications*». *International Journal of Forecasting* 16 (4): 451-476. [https://doi.org/http://dx.doi.org/10.1016/S0169-2070\(00\)00057-1](https://doi.org/http://dx.doi.org/10.1016/S0169-2070(00)00057-1).
- Makridakis, S.; Hibon, M.; Lusk, E. y Belhadjali, M. 1987. «*Confidence intervals. An empirical investigation of the series in the M-competition*». *International Journal of Forecasting* 3 (3-4): 489-508. [https://doi.org/10.1016/0169-2070\(87\)90045-8](https://doi.org/10.1016/0169-2070(87)90045-8).
- Makridakis, S.; Spiliotis, E. y Assimakopoulos, V. 2018. «*The M4 Competition: Results, findings, conclusion and way forward*». *International Journal of Forecasting* 34 (4): 802-808. <https://doi.org/10.1016/j.ijforecast.2018.06.001>.

-
- Makridakis, S.; Wheelwright, S.C. y Hyndman, R. J. 1998. *Forecasting : Methods and Applications*. John Willey and Sons, Inc.
- Manera, C. 2009. «*El creixement de l' economia turística a les Illes*». *Recerques* 59: 151-192.
- Martín-Rodríguez, G. y Cáceres-Hernández, J. J. 2005. «*Modelling the hourly Spanish electricity demand*». *Economic Modelling* 22 (3): 551-569. <https://doi.org/10.1016/J.ECONMOD.2004.09.003>.
- Martínez-Álvarez, F.; Troncoso, A.; Riquelme, J. C. y Aguilar-Ruiz, J.S. 2011. «*Energy Time Series Forecasting Based on Pattern Sequence Similarity*». *IEEE Transactions on Knowledge and Data Engineering* 23 (8): 1230-43. <https://doi.org/10.1109/TKDE.2010.227>.
- Mayer, W. J.; Liu, F. y Dang, X. 2017. «*Improving the power of the Diebold–Mariano–West test for least squares predictions*». *International Journal of Forecasting* 33 (3): 618-26. <https://doi.org/10.1016/j.ijforecast.2017.01.008>.
- Mitra, S. y Hayashi, Y. 2000. «*Neuro-fuzzy rule generation: survey in soft computing framework*». *IEEE Transactions on Neural Networks*. <https://doi.org/10.1109/72.846746>.
- Mohamed, N.; Ahmad, M. H. y Ismail, Z. 2011. «*Improving Short Term Load Forecasting Using Double Seasonal Arima*» 15 (2): 223-231.
- Mohamed, N.; Ahmad, M.H.; Ismail, Z. y Suhartono, S. 2010. «*Double Seasonal ARIMA Model for Forecasting Load Demand*». *Matematika* 26 (2): 217-231.
- Mohamed, N.; Ahmad, M.H.; Suhartono y Ahmad, W. M. 2012. «*Forecasting short term load demand using multilayer feed-forward (MLFF) neural network model*». *Applied Mathematical Sciences* 6 (108): 5359-5368.

- Mohandes, M. 2002. «*Support vector machines for short-term electrical load forecasting*». *International Journal of Energy Research* 26 (4): 335-345. <https://doi.org/10.1002/er.787>.
- Montgomery, D. C.; Jennings, C. y Kulahci, M. 2008. *Introduction to Time Series Analysis and Forecasting*. New Jersey: John Wiley & Sons, Inc.
- Moore, B. 1981. «*Principal component analysis in linear systems: Controllability, observability, and model reduction*». *IEEE Transactions on Automatic Control* 26 (1): 17-32. <https://doi.org/10.1109/TAC.1981.1102568>.
- Moral-Carcedo, J. y Pérez-García, J. 2015. «*Temperature effects on firms' electricity demand: An analysis of sectorial differences in Spain*». *Applied Energy* 142: 407-425. <https://doi.org/10.1016/j.apenergy.2014.12.064>.
- Moral-Carcedo, J. y Vicéns-Otero, J. 2005. «*Modelling the non-linear response of Spanish electricity demand to temperature variations*». *Energy Economics* 27 (3): 477-494. <https://doi.org/10.1016/j.eneco.2005.01.003>.
- Mount, T. D.; Ning, Y. y Cai, X. 2006. «*Predicting price spikes in electricity markets using a regime-switching model with time-varying parameters*». *Energy Economics* 28 (1): 62-80. <https://doi.org/10.1016/j.eneco.2005.09.008>.
- Muñoz, A.; Sánchez-Úbeda, E. F.; Cruz, A. y Marín, J. 2010. «*Short-Term Forecasting in Power Systems: A Guided Tour*». En *Handbook of Power Systems II*, editado por Steffen Rebennack, Panos M Pardalos, Mario V F Pereira, y Niko A Iliadis, 129-60. Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-12686-4_5.
- Muth, J. F. 1960. «*Optimal properties of exponentially weighted forecasts*». *Journal of the American Statistical Association* 55: 299-306.
- Naumova, E. N. 2006. «*Mystery of seasonality: Getting the rhythm of nature*». *Journal of Public Health Policy* 27 (1): 2-12. <https://doi.org/10.1057/palgrave.jphp.3200061>.

-
- Nelder, J.A., y Mead, R. 1965. «A Simplex Method for Function Minimization». *The computer journal* 7 (4): 308-313.
- NIST/SEMATECH. 2012. «*e-Handbook of Statistical Methods*». <http://www.itl.nist.gov/div898/handbook/>.
- Nogales, F. J.; Contreras, J.; Conejo, A.J. y Espinola, R. 2002. «Forecasting next-day electricity prices by time series models». *IEEE Transactions on Power Systems* 17 (2): 342-348. <https://doi.org/10.1109/TPWRS.2002.1007902>.
- Nogales, F. J. y Conejo, A. J. 2006. «Electricity price forecasting through transfer function models». *Journal of the Operational Research Society* 57 (4): 350-356. <https://doi.org/10.1057/palgrave.jors.2601995>.
- Nowotarski, J.; Liu, B.; Weron, R. y Hong, T. 2016. «Improving short term load forecast accuracy via combining sister forecasts». *Energy* 98: 40-49. <https://doi.org/10.1016/j.energy.2015.12.142>.
- Ohtsuka, Y.; Oga, T. y Kakamu, K. 2010. «Forecasting electricity demand in Japan: A Bayesian spatial autoregressive ARMA approach». *Computational Statistics and Data Analysis* 54 (11): 2721-2735. <https://doi.org/10.1016/j.csda.2009.06.002>.
- Omie. 2018. «*omie. Informe anual*». <https://doi.org/10.1192/bjp.111.479.1009-a>.
- Ord, J. K.; Koehler, A. B. y Snyder, R. D. 1997. «Estimation and prediction for a class of dynamic nonlinear statistical models». *Journal of the American Statistical Association* 92: 1621-1629.
- Ortiz, M.; Ukar, O.; Azevedo, F. y Múgica, A. 2016. «Price forecasting and validation in the Spanish electricity market using forecasts as input data». *International Journal of Electrical Power & Energy Systems* 77: 123-127. <https://doi.org/10.1016/j.ijepes.2015.11.004>.
- OrtizBeviá, M. J. y RuizdeElvira, A. 2012. «Evolution of heating and cooling degree-days in Spain : Trends and interannual

- variability». *Global and Planetary Change* 92-93: 236-247.
<https://doi.org/10.1016/j.gloplacha.2012.05.023>.
- OrtizBeviá, M. J.; RuizdeElvira, A. y Alvarez-García, F.J. 2014. «*The influence of meteorological variability on the mid-term evolution of the electricity load*». *Energy* 76: 850-856.
<https://doi.org/https://doi.org/10.1016/j.energy.2014.08.084>
- Osman, A.F. y King, M. L. 2015. «*A new approach to forecasting based on exponential smoothing with independent regressors*». *Department of Econometrics and Business Statistics*.
<http://econpapers.repec.org/paper/mshebswps/2015-2.htm>.
- Osman, A.F. y King, M. L. 2018. «*Stability and Forecastability Characteristics of Exponential Smoothing with Regressors Methods*». En *Regional Conference on Science, Technology and Social Sciences (RCSTSS 2016)*, editado por Nor Azizah Yacob, Nur Asmaliza Mohd Noor, Nor Yuziah Mohd Yunus, Rahmah Lob Yussof, y Shaikh Abdul Karim Yamani Zakaria, 1029-1038. Singapore: Springer Singapore.
- Otter, P. W. 1984. «*Dynamic feature space modelling, filtering and self-tuning control of stochastic systems*». s.n.
[https://www.rug.nl/research/portal/en/publications/dynamic-feature-space-modelling-filtering-and-selftuning-control-of-stochastic-systems\(87d954be-d94a-4b12-8f1c-daed8bbd7941\).html](https://www.rug.nl/research/portal/en/publications/dynamic-feature-space-modelling-filtering-and-selftuning-control-of-stochastic-systems(87d954be-d94a-4b12-8f1c-daed8bbd7941).html).
- Pablo-Romero, M. P.; Pozo-Barajas, R. y Sánchez-Rivas, J. 2017. «*Relationships between tourism and hospitality sector electricity consumption in Spanish Provinces (1999-2013)*». *Sustainability (Switzerland)* 9 (4).
<https://doi.org/10.3390/su9040480>.
- Pahasa, J y Theera-Umporn, N. 2007. «*Short-term load forecasting using wavelet transform and support vector machines*». En *2007 International Power Engineering Conference (IPEC 2007)*, 47-52.
- Papalexopoulos, A.D. y Hesterberg, T.C. 1990. «*A regression-*

based approach to short-term system load forecasting». *IEEE Transactions on Power Systems* 5 (4): 1535-1547. <https://doi.org/10.1109/59.99410>.

Pappas, S. Sp; Ekonomou, L.; Karamousantas, D. Ch; Chatzarakis, G. E.; Katsikas, S. K. y Liatsis, P. 2008. «*Electricity demand loads modeling using AutoRegressive Moving Average (ARMA) models*». *Energy* 33 (9): 1353-1360. <https://doi.org/10.1016/j.energy.2008.05.008>.

Pappas, S. Sp; Ekonomou, L.; Karampelas, P.; Karamousantas, D. C.; Katsikas, S. K.; Chatzarakis, G. E. y Skafidas, P. D. 2010. «*Electricity demand load forecasting of the Hellenic power system using an ARMA model*». *Electric Power Systems Research* 80 (3): 256-264. <https://doi.org/10.1016/j.epsr.2009.09.006>.

Pardo, A.; Meneu, V. y Valor, E. 2002. «*Temperature and seasonality influences on Spanish electricity load*». *Energy Economics* 24 (1): 55-70. [https://doi.org/10.1016/S0140-9883\(01\)00082-2](https://doi.org/10.1016/S0140-9883(01)00082-2).

Pegels, C. C. 1969. «*Exponential forecasting: some new variations*». *Management Science* 15: 311-15.

Peirson, J, y Henley, A. 1994. «*Electricity load and temperature*». *Energy Economics* 16 (4): 235-243. [https://doi.org/10.1016/0140-9883\(94\)90021-3](https://doi.org/10.1016/0140-9883(94)90021-3).

Peng, T. M.; Hubele, N. F. y Karadi, G. G. 1992. «*Advancement in the application of neural networks for short-term load forecasting*». *IEEE Transactions on Power Systems* 7 (1): 250-257.

Pérez-Arriaga, J. I. 2005. «*Libro blanco sobre la reforma del marco regulatorio de la generación eléctrica en España*».

Pérez-García, J. y Moral-Carcedo, J. 2016. «*Analysis and long term forecasting of electricity demand trough a decomposition model: A case study for Spain*». *Energy* 97: 127-143. <https://doi.org/10.1016/j.energy.2015.11.055>.

Pfeffermann, D. y Allon, J. 1989. «*Multivariate exponential*

- smoothing: method and practice*». *International Journal of Forecasting* 5 (1): 83-98.
- Pfenniger, S. y Keirstead, J. 2015. «*Renewables, nuclear, or fossil fuels? Scenarios for Great Britain's power system considering costs, emissions and energy security*». *Applied Energy* 152: 83-93.
<https://doi.org/10.1016/j.apenergy.2015.04.102>.
- Pierrot, A, y Goude, Y. 2014. «*Short-Term Electricity Load Forecasting With Generalized Additive Models*». En *Proceedings of ISAP power*, 593-600.
- Rahman, S. y Hazim, O. 1993. «*A Generalized Knowledge-Based Short-Term Load-Forecasting Technique*». *IEEE Transactions on Power Systems* 8 (2): 508-14.
<https://doi.org/10.1109/59.260833>.
- Ramanathan, R.; Engle, R.; Granger, C. W. J.; Vahid-Araghi, F. y Brace, C. 1997. «*Short-run forecasts of electricity loads and peaks*». *International Journal of Forecasting* 13 (2): 161-174.
- Rana, M.; Koprinska, I. y Troncoso, A. 2014. «*Forecasting hourly electricity load profile using neural networks*». En *2014 International Joint Conference on Neural Networks (IJCNN)*, 824-831.
<https://doi.org/10.1109/IJCNN.2014.6889489>.
- Rasmussen, R. 2004. «*On time series data and optimal parameters*» 32: 111-120.
<https://doi.org/10.1016/j.omega.2003.09.013>.
- Red Eléctrica de España. 2015. «*El sistema eléctrico español 2014*». Vol. 000. www.ree.es.
- Reid, D. J. 1975. «*A review of short-term projection techniques*». Editado por Operational Research Society. *Practical Aspects of Forecasting*, 8-25.
- Rendon-Sanchez, J. F. y Menezes, L.M. de. 2019. «*Structural combination of seasonal exponential smoothing forecasts applied to load forecasting*». *European Journal of*

Operational Research 275 (3): 916-924.
<https://doi.org/https://doi.org/10.1016/j.ejor.2018.12.013>.

Riera Font, A. y Mateu Sbert, J. 2007. «Aproximación al volumen de turismo residencial en la Comunidad Autónoma de las Illes Balears a partir del cómputo de la carga demográfica real». *Estudios Turísticos* 174: 59-71.

Rock, B. A. 1997. «Impact of daylight saving time on residential energy consumption and cost». *Energy and Buildings* 25 (1): 63-68. [https://doi.org/10.1016/S0378-7788\(96\)00990-5](https://doi.org/10.1016/S0378-7788(96)00990-5).

Romero, Á.; Dorronsoro, J. y Díaz, J. 2018. «Day-Ahead Price Forecasting for the Spanish Electricity Market.» *International Journal of Interactive Multimedia and Artificial Intelligence* 5 (4).

Rubio Gil, M.A. y Mazón Martínez, T. 2009. «El capital social como factor coadyuvante de los procesos de desarrollo turístico y socioeconómico de los destinos de interior». *Papers de Turisme* 45: 41-55.
http://www.turisme.gva.es/opencms/opencms/turisme/es/files/pdf/observatorio/publicaciones/Nxm._45.pdf.

Rutty, M.; Gössling, S.; Scott, D. y Hall, C. M. 2015. «The global effects and impacts of tourism». En *The Routledge Handbook of Tourism and Sustainability*. Abingdon: Routledge. <https://doi.org/10.4324/9780203072332.ch3>.

Scott, D.; Gössling, S.; Hall, C. M. y Peeters, P. 2016. «Can tourism be part of the decarbonized global economy? The costs and risks of alternate carbon reduction policy pathways». *Journal of Sustainable Tourism* 24 (1): 52-72.
<https://doi.org/10.1080/09669582.2015.1107080>.

Scott, D.; Hall, C. M. y Gössling, S. 2016. «A report on the Paris Climate Change Agreement and its implications for tourism: why we will always have Paris». *Journal of Sustainable Tourism* 24 (7): 933-948.
<https://doi.org/10.1080/09669582.2016.1187623>.

Segura, J. V. y Vercher, E. 2001. «A spreadsheet modeling approach to the Holt–Winters optimal forecasting».

- European Journal of Operational Research* 131 (2): 375-388. [https://doi.org/http://dx.doi.org/10.1016/S0377-2217\(00\)00062-X](https://doi.org/http://dx.doi.org/10.1016/S0377-2217(00)00062-X).
- Setiawan, A.; Koprinska, I. y Agelidis, V. G. 2009. «*Very short-term electricity load demand forecasting using support vector regression*». *2009 International Joint Conference on Neural Networks*, junio, 2888-2894. <https://doi.org/10.1109/IJCNN.2009.5179063>.
- Shang, H. L. 2013. «*Functional time series approach for forecasting very short-term electricity demand*». *Journal of Applied Statistics* 40 (1): 152-168. <https://doi.org/10.1080/02664763.2012.740619>.
- Sigauke, C. y Chikobvu, D. 2011. «*Prediction of daily peak electricity demand in South Africa using volatility forecasting models*». *Energy Economics* 33 (5): 882-888. <https://doi.org/10.1016/j.eneco.2011.02.013>.
- Smith, M. 2000. «*Modeling and Short-Term Forecasting of New South Wales Electricity System Load*». *Journal of Business & Economic Statistics* 18 (4): 465-478. <https://doi.org/10.1080/07350015.2000.10524885>.
- Snyder, R. D.; Koehler, A. B.; Hyndman, R. J. y Ord, J. K. 2004. «*Exponential smoothing models: Means and variances for lead-time demand*». *European Journal of Operational Research* 158 (2): 444-455. [https://doi.org/10.1016/s0377-2217\(03\)00360-6](https://doi.org/10.1016/s0377-2217(03)00360-6).
- Souza, R. C.; Barros, M. y Miranda, C. V. C. 2007. «*Short term load forecasting using double seasonal exponential smoothing and interventions to account for holidays and temperature effects*». *TLAIO II-2 do Taller Latino Iberoamericano de Investigación de Operaciones, Acapulco, México*.
- Srinivasan, D.; Chang, C. S. y Liew, A. C. 1995. «*Demand Forecasting Using Fuzzy Neural Computation, With Special Emphasis On Weekend And Public Holiday Forecasting*». *IEEE Transactions on Power Systems* 10 (4): 1897-1903.

<https://doi.org/10.1109/59.476055>.

Stanton, K. y Gupta, P. 1970. «*Forecasting Annual or Seasonal Peak Demand in Electric Utility Systems*». *IEEE Transactions on Power Apparatus and Systems* PAS-89 (5): 951-959. <https://doi.org/10.1109/TPAS.1970.292658>.

Suganthi, L. y Samuel, A. A. 2012. «*Energy models for demand forecasting—A review*». *Renewable and Sustainable Energy Reviews* 16 (2): 1223-1240. <https://doi.org/10.1016/j.rser.2011.08.014>.

Suhartono, S. S. y Endharta, A. J. 2009. «*Short Term Electricity Load Demand Forecasting in Indonesia by Using Double Seasonal Recurrent Neural Networks*» 3 (3): 171-178.

Suppalakpanya, K.; Nikhom, R.; Booranawong, A. y Booranawong, T. 2019. «*An evaluation of holt-winters methods with different initial trend values for forecasting crude palm oil production and prices in Thailand*». *Suranaree J. Sci. Technol.* 26 (1): 13-22.

Sweet, A. L. 1985. «*Computing the variance of the forecast error for the holt-winters seasonal models*». *Journal of Forecasting* 4 (2): 235-243. <https://doi.org/10.1002/for.3980040210>.

Tan, Z.; Zhang, J.; W., J. y Xu, J. 2010. «*Day-ahead electricity price forecasting using wavelet transform combined with ARIMA and GARCH models*». *Applied Energy* 87 (11): 3606-3610. <https://doi.org/10.1016/j.apenergy.2010.05.012>.

Taylor, J. W. 2003a. «*Exponential smoothing with a damped multiplicative trend*». *International Journal of Forecasting* 19 (4): 715-725. [https://doi.org/10.1016/s0169-2070\(03\)00003-7](https://doi.org/10.1016/s0169-2070(03)00003-7).

Taylor, J. W. 2003b. «*Short-term electricity demand forecasting using double seasonal exponential smoothing*». *Journal of the Operational Research Society* 54 (8): 799-805.

Taylor, J. W. 2007. «*Forecasting daily supermarket sales using exponentially weighted quantile regression*». *European*

- Journal of Operational Research* 178 (1): 154-167.
<https://doi.org/10.1016/j.ejor.2006.02.006>.
- Taylor, J. W. 2008. «An evaluation of methods for very short-term load forecasting using minute-by-minute British data». *International Journal of Forecasting* 24 (4): 645-658.
<https://doi.org/10.1016/j.ijforecast.2008.07.007>.
- Taylor, J. W. 2010a. «Exponentially weighted methods for forecasting intraday time series with multiple seasonal cycles». *International Journal of Forecasting* 26 (4): 627-646. <https://doi.org/10.1016/j.ijforecast.2010.02.009>.
- Taylor, J. W. 2010b. «Triple seasonal methods for short-term electricity demand forecasting». *European Journal of Operational Research* 204 (1): 139-152.
<https://doi.org/10.1016/j.ejor.2009.10.003>.
- Taylor, J. W. y Buizza, R. 2003. «Using weather ensemble predictions in electricity demand forecasting». *International Journal of Forecasting* 19 (1): 57-70.
[https://doi.org/10.1016/S0169-2070\(01\)00123-6](https://doi.org/10.1016/S0169-2070(01)00123-6).
- Taylor, J. W. y Bunn, D. W. 1999. «A quantile regression approach to generating prediction intervals». *Management Science* 45 (2): 225-237.
- Taylor, J. W. y McSharry, P. E. 2007. «Short-term load forecasting methods: An evaluation based on european data». *Power Systems, IEEE Transactions on* 22 (4): 2213-2219.
- Taylor, J. W.; Menezes, L.M. de y McSharry, P. E. 2006. «A comparison of univariate methods for forecasting electricity demand up to a day ahead». *International Journal of Forecasting* 22 (1): 1-16.
<https://doi.org/10.1016/j.ijforecast.2005.06.006>.
- Taylor, J. W. y Snyder, R. D. 2012. «Forecasting intraday time series with multiple seasonal cycles using parsimonious seasonal exponential smoothing». *Omega* 40 (6): 748-757.
<https://doi.org/10.1016/j.omega.2010.03.004>.

-
- Theil, H. 1958. *Economic forecasts and policy*. Amsterdam: North-Holland. citeulike-article-id:553361.
- Thompson, R. P. 1976. «Weather sensitive electric demand and energy analysis on a large geographically diverse power system. Application to short term hourly electric demand forecasting». *IEEE Transactions on Power Apparatus and Systems* 95 (1): 385-393. <https://doi.org/10.1109/T-PAS.1976.32116>.
- Tranchita, C. y Torres, A. 2004. «Soft computing techniques for short term load forecasting». *Power Systems Conference and Exposition, 2004. IEEE PES*, 497-502.
- Tratar, L. F. 2014. «Improved Holt-Winters Method: A Case of Overnight Stays of Tourists in Republic Of Slovenia». *Economic and Business Review* 16 (1): 5-17.
- Tratar, L. F. 2015. «Forecasting method for noisy demand». *International Journal of Production Economics* 161: 64-73. <https://doi.org/10.1016/j.ijpe.2014.11.019>.
- Tratar, L. F.; Mojškerc, B. y Toman, A. 2016. «Demand forecasting with four-parameter exponential smoothing». *International Journal of Production Economics* 181: 162-173. <https://doi.org/10.1016/j.ijpe.2016.08.004>.
- Troncoso, A.; Riquelme Santos, J.M.; Riquelme, J. Cristóbal; Gómez Expósito, A. y Martínez Ramos, J. Luís. 2004. «Time-Series Prediction: Application to the Short-Term Electric Energy Demand». En *Conference on Technology Transfer*, 577-586. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-540-25945-9_57.
- Trull, O.; García-Díaz, J. C. y Peiró-Signes, A. 2017. «Improvement using very-short term electricity demand forecasting with multiple seasonal Holt-Winters methods». En *TOURISM, ECONOMY AND ENVIRONMENT NEW TRENDS AND RESEARCH PERSPECTIVES*, 181-90.
- Trull, O.; García-Díaz, J. C. y Troncoso, A. 2019. «Application of Discrete-Interval Moving Seasonalities to Spanish Electricity Demand Forecasting during Easter». *Energies*

- 12 (6): 1083. <https://doi.org/10.3390/en12061083>.
- Valor, E.; Climent, F. J.; Meneu, V. y Caselles, V. 2002. «*El modelo español de consumo sectorial de electricidad*». *Revista Española de Física* 16 (3): 1-22.
- Valor, E.; Meneu, V. y Caselles, V. 2001. «*Daily Air Temperature and Electricity Load in Spain*». *Journal of Applied Meteorology* 40 (8): 1413-1421.
- Vilar, J. M.; Aneiros, G. y Raña, P. 2018. «*Prediction intervals for electricity demand and price using functional data*». *International Journal of Electrical Power and Energy Systems* 96 (April 2017): 457-472. <https://doi.org/10.1016/j.ijepes.2017.10.010>.
- Vilar, J. M.; Cao, R. y Aneiros, G. 2012. «*Forecasting next-day electricity demand and price using nonparametric functional methods*». *International Journal of Electrical Power & Energy Systems* 39 (1): 48-55. <https://doi.org/10.1016/j.ijepes.2012.01.004>.
- Vrablecová, P.; B. E., A.; Rozinajová, V.; Šárik, S. y Sangaiah, A. K. 2018. «*Smart grid load forecasting using online support vector regression*». *Computers and Electrical Engineering* 65 (2018): 102-117. <https://doi.org/10.1016/j.compeleceng.2017.07.006>.
- Wang, S. 2006. «*Exponential Smoothing for Forecasting and Bayesian Validation of Computer Models*».
- Welch, G. y Bishop, G. 2006. «*An Introduction to the Kalman Filter*». Editado por Addison-Wesley Editor Acm Press. *In Practice* 7 (1): 1-16.
- Weron, R. 2006. *Modeling and Forecasting Electricity Loads and Prices: A Statistical Approach*. Chichester, England: John Wiley & Sons, Ltd.
- Weron, R. 2014. «*Electricity price forecasting: A review of the state-of-the-art with a look into the future*». *International Journal of Forecasting* 30 (4): 1030-81. <https://doi.org/10.1016/j.ijforecast.2014.08.008>.

-
- Williams, D. W. y Miller, D. 1999. «*Level-adjusted exponential smoothing for modeling planned discontinuities*». *International Journal of Forecasting* 15 (3): 273-289. [https://doi.org/http://dx.doi.org/10.1016/S0169-2070\(98\)00083-1](https://doi.org/http://dx.doi.org/10.1016/S0169-2070(98)00083-1).
- Winters, P. R. 1960. «*Forecasting sales by exponentially weighted moving averages*». *Management* 6 (6): 324-342. <https://doi.org/10.1287/mnsc.6.3.324>.
- Yar, M. y Chatfield, C. 1990. «*Prediction intervals for the Holt-Winters forecasting procedure*». *International Journal of Forecasting* 6 (1): 127-137. [https://doi.org/10.1016/0169-2070\(90\)90103-I](https://doi.org/10.1016/0169-2070(90)90103-I).
- Zhang, M.; Li, J. ; Pan, B. y Zhang, G. 2018. «*Weekly hotel occupancy forecasting of a tourism destination*». *Sustainability (Switzerland)* 10 (12). <https://doi.org/10.3390/su10124351>.
- Zivanovic, R. 2002. «*Nonparametric trend model for short term electricity demand forecasting*». En *Fifth International Conference on Power System Management and Control*, 2002:347-52. IEE. <https://doi.org/10.1049/cp:20020060>.
- Zolfaghari, M. y Sahabi, B. 2019. «*A hybrid approach to model and forecast the electricity consumption by NeuroWavelet and ARIMAX-GARCH models*».

Bibliografía complementaria

- Box, G. E. P.; Jenkins, G. M.; Reinsel, G. C. y Ljung, G. M. 2015. «*Time Series Analysis: Forecasting and Control*». John Wiley & Sons.
- Chatfield, C. (2000). «*Time-Series Forecasting*». Chapman & Hall/CRC.

- García-Díaz, J. C. (2016). “*Predicción en el dominio del tiempo. Análisis de series temporales para ingenieros*”. Editorial de la Universitat Politècnica de València. 9788490484388
- Hyndman, R. J. y Athanasopoulos, G. (2018). “*Forecasting : principles and practice*” (2nd Edition). Melbourne, Australia: OTexts.
- Hyndman, R. J., & Kostenko, A. V. (2007). “*Minimum sample size requirements for seasonal forecasting models*”. *Foresight*.
- Hyndman, R. J.; Koehler, A. B.; Ord, J. K. y Snyder, R. D. (2008). “*Forecasting with Exponential Smoothing: The State Space Approach*”. Edited by Springer. Berlin Heidelberg: Springer.
- Makridakis, S.; Wheelwright, S.C. y Hyndman, R. J. (1998). “*Forecasting : Methods and Applications*”. John Willey and Sons, Inc.
- Montgomery, D. C., Jennings, C., y Kulahci, M. (2008). “*Introduction to Time Series Analysis and Forecasting*”. New Jersey: John Wiley & Sons, Inc.
- Peña, D. (2010). “*Análisis de series temporales*” (Segunda Ed). Alianza.

Anexo I: Software de implementación

A1

Introducción

El desarrollo de esta tesis ha ido acompañado del desarrollo de un software específico para la implementación de los modelos, de las variantes de optimización, inicialización, etc.

Este software, desarrollado sobre la plataforma MATLAB® R13b, permite realizar todas las pruebas y pronósticos descritos en esta tesis, además de una funcionalidad completa para su explotación posterior. La necesidad de desarrollar este software surge debido a que no existe ningún software comercial que implemente este tipo de desarrollos. Ni siquiera el software estadístico libre R incluye las alternativas necesarias para el estudio.

Se barajaron varias alternativas para el desarrollo de la aplicación, y se eligió MATLAB® por los siguientes motivos:

- Es una plataforma para desarrollo rápido de software científico, con un lenguaje de programación de alto nivel, y con una serie de librerías específicas que permiten

realizar muchas de las tareas más tediosas de programar, y que no aportan valor añadido a la programación del software.

- La utilización con series temporales requiere del manejo de grandes volúmenes de datos, organizados en vectores de grandes tamaños. No existe otro software que pueda gestionar vectores de tan semejante tamaño de forma tan eficiente como MATLAB®. Se hicieron pruebas con R con series temporales de tamaño semejante, pero éste no es capaz de gestionarlas y el programa quiebra y no se puede realizar el análisis.
- La Universidad Politécnica de Valencia dispone de licencias y las renueva constantemente, apostando por este software científico.

En este capítulo se describe el funcionamiento y organización del software, así como las rutinas más importantes utilizadas en esta tesis.

Funcionamiento

El desarrollo de la aplicación se ha realizado de acuerdo a tres principios necesarios para la tesis: flexibilidad, funcionalidad y objetividad. Es necesario que la aplicación pueda utilizar modelos diferentes, con variaciones programadas – de acuerdo al objetivo de ese momento en el desarrollo – y que proporcione un funcionamiento eficaz. El usuario de la aplicación dispone de un modelo a elegir entre los 30 modelos implementados, y a partir del cual podrá realizar diferentes estudios. En la Figura I.0.1 se muestra el esquema de la aplicación.

La aplicación tiene como eje central el modelo, el cual permite la introducción de datos de forma directa, o mediante un preprocesado. Posteriormente los modelos pueden ser alimentados con valores iniciales a demanda del usuario. Todas las variantes explicadas en el capítulo anterior y otras adicionales pueden ser utilizadas.

Para el modelo, se pueden introducir de forma manual los valores de los parámetros de suavizado, o puede recurrirse a un ajuste del mismo. Para esta función, se disponen de diferentes métodos de optimización y se dispone de diferentes estadísticos o indicadores para conseguir minimizar el error cometido por el modelo. A partir de aquí, la aplicación produce pronósticos y salidas gráficas con los modelos utilizados. Estos modelos además disponen de modificadores para poder introducir variables exógenas, o DIMS.

Por último, la aplicación cuenta con una serie de bases de datos para disponer de la información requerida en el trabajo. Esta base de datos ha sido construida con datos provenientes de REE, así como datos provenientes de plataformas de climatología. Adicionalmente, se ha desarrollado una base de datos de festivivos y día especiales para su utilización con los DIMS.

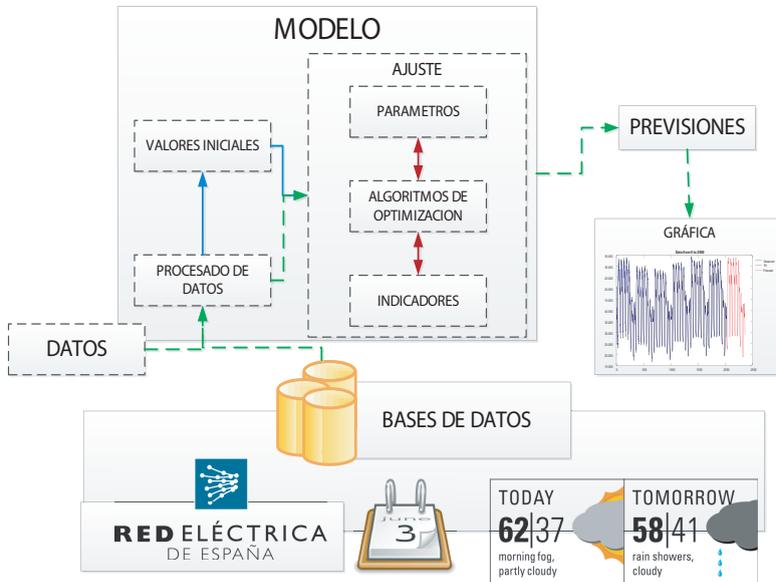


Figura I.0.1. Esquema del funcionamiento de la aplicación.

La salida de la aplicación ha sido otro elemento importante. Por norma general, la aplicación proporciona valores de las

previsiones, aunque ofrece la posibilidad de visualizar valores intermedios utilizados en el desarrollo. Sin embargo, se dispone de una salida gráfica opcional que proporciona ayuda a una interpretación de los valores. Ejemplos de esta salida gráfica se muestran en la Figura I.0.2.

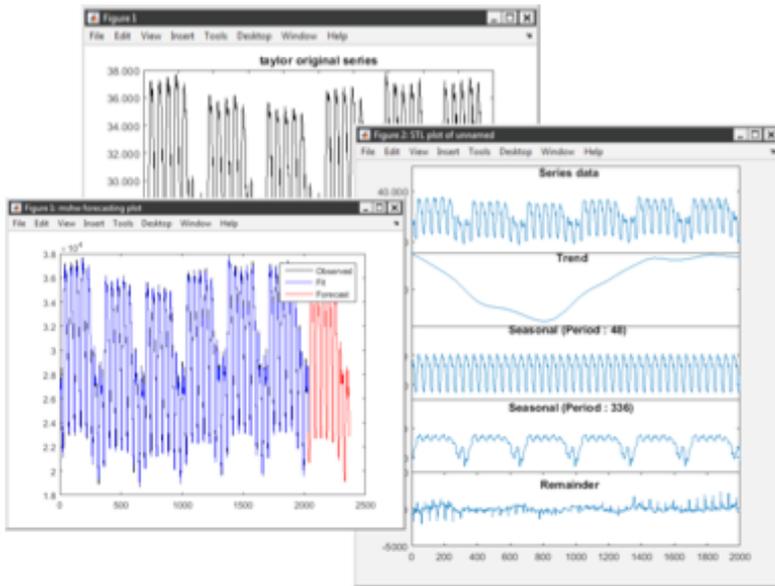


Figura I.0.2. Ejemplos de salidas ofrecidas por la aplicación.

Estructura de la aplicación

La aplicación se ha realizado mediante programación orientada a objetos. Ello permite una versatilidad y flexibilidad que de otra forma no sería posible. El esquema de la aplicación se muestra en la Figura I.0.3. Está organizada alrededor de una clase base, denominada *mts*. Esta clase es la encargada de contener los datos, la información acerca del tiempo y las estacionalidades, y de contener información adicional extra, como variables exógenas, etc. Esta clase dispone además de métodos para poder obtener funciones básicas de la serie temporal. Permite realizar

descomposiciones STL, realizar periodogramas, análisis de las funciones de correlación y de las parciales, además de gestionar la entrada y salida de los datos.

Esta clase dispone, además, de las funciones básicas para realizar la evaluación de la precisión en los pronósticos y los ajustes.

De ella derivan las clases de trabajo. La más interesante es la clase *mshw*, que integra las funciones necesarias para realizar previsiones con modelos de Holt-Winters múltiple-estacionales. Por otro lado, existen unas clases derivadas que se encargan de obtener la información de las bases de datos y la integran en los objetos de tipo *mts*. De estas clases destacan *REEmts* y *Weathermts*, que se encargan de proporcionar los datos obtenidos de REE y los datos obtenidos de las plataformas de información climática respectivamente.

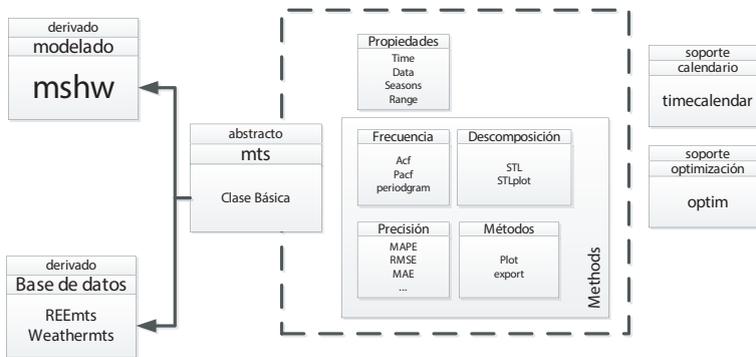


Figura I.0.3. Esquema de la estructura de la aplicación, organizada en clases.

Por último, se dispone de varias clases soporte. Ajenas a la clase principal, realizan funciones externas o aportan información puntual. Destaca la clase *optim*, que proporciona todos los algoritmos de optimización. La clase *timecalendar* proporciona el calendario de festivos y eventos especiales utilizados en la aplicación.

Resumen de código de la aplicación

A continuación, se muestran datos relevantes acerca de la aplicación.

Base de programación: MATLAB® R2011b, R2013b, R2015b y R2018b.

Líneas de código: 48659 (agosto de 2019).

Dependencias:

Signal Processing Toolbox
Statistics and Machine Learning Toolbox
Financial Toolbox
Global Optimization Toolbox
Parallel Computing Toolbox
MATLAB Distributed Computing Server

Datos de la serie de Electricidad.

Fuente	Zona	Fechas	Resolución
REE	Península	1998-2004	Horarios
		2007-2019	Horarios
	Baleares	2013-2017	Diez minutos
	Canarias	2013-2017	Diez minutos
DNO	England & Wales	2005-2018	Horarios y media hora

Datos de otras series

Fuente	Zona	Fechas	Resolución
Weather underground	Climatología	2013-2017	Medio Horarios
IBESTAT	IPH Baleares	1997-2017	Diario / Mensual
AENA	Tráfico de aeropuertos	1990-2018	Mensual

Ejemplos de utilización

A continuación, se muestran ejemplo de cómo utilizar la aplicación para obtener los estudios que se han visto en la tesis.

a) Creación de un objeto *mts*, y su posterior salida gráfica.

El siguiente ejemplo carga en memoria datos de un fichero, y crea un objeto *mts* y lo muestra en una gráfica. Se utiliza la clase *mts.mts* para ello.

```
>> load taylor
>> taylormts = mts.mts(taylor,[48 336])
```

```
taylormts =
```

```
Multiple Seasonal Time Series class with...
```

```
-----
Name : unnamed
Seasonal 1 with Length : 48
Seasonal 2 with Length : 336
Data length : 4032
-----
```

```
Time Info
```

```
Uniform Time:
```

Length 4032
Increment 1 units

Time Range:

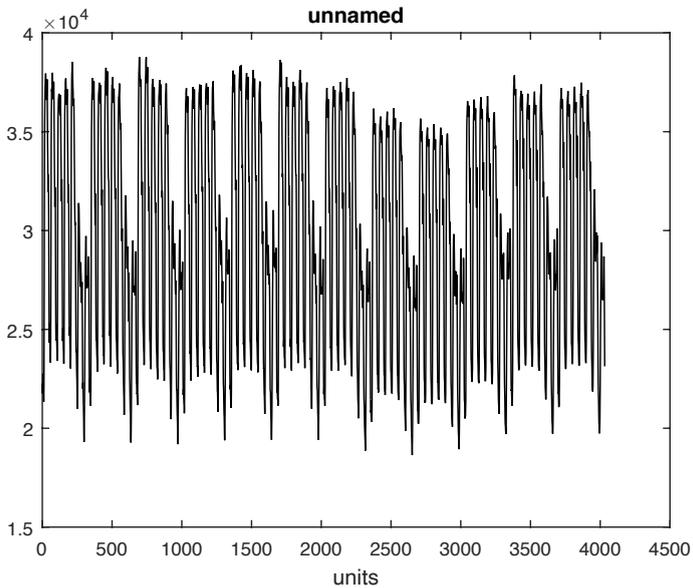
Start 1 units
End 4032 units

Common Properties:

Units: 'units'
Format: "
StartDate: "

>> taylormts.plot

>>



b) Carga desde la base de datos de la demanda de MALLORCA y su posterior salida gráfica.

El ejemplo siguiente carga los datos desde la base de datos de electricidad, conectada a e-sios de REE. Posteriormente se muestra la serie.

```
>> emts = REEmts;  
>> emts.LoadData('db','balears','serie',  
'MALLORCA_demandafina','rebuilt','missings');  
No dates provided. The complete series will be loaded.  
>> emts
```

```
emts =
```

Multiple Seasonal Time Series class with...

```
-----  
Name : demandafina  
Seasonal periods empty  
Data length : 239040  
-----
```

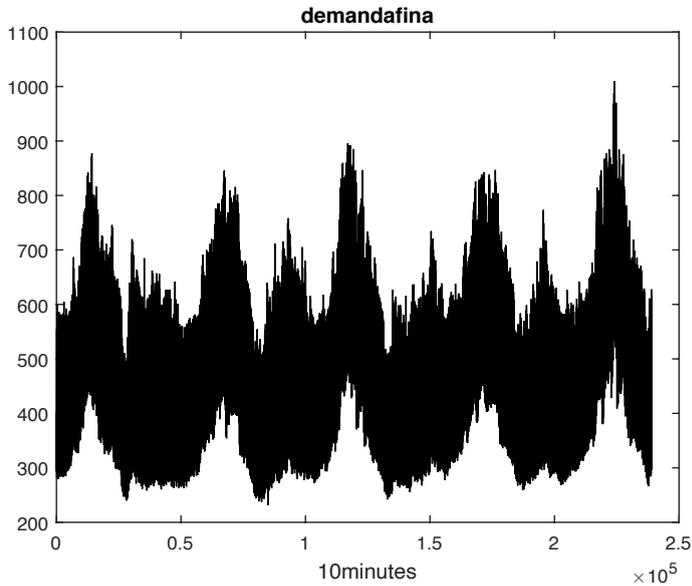
Time Info

```
Non-Uniform Time:  
Length    239040
```

```
Time Range:  
Start    01-May-2013 00:10:00  
End      16-Nov-2017 00:00:00
```

```
Common Properties:  
Units: '10minutes'  
Format: 'yyyy-mm-dd HH:MM'  
StartDate: '01-May-2013 00:10:00'  
-----
```

```
>> emts.plot
```



- c) Creación de un objeto mshw a partir de un objeto de las bases de datos, y su optimización mediante el algoritmo simplex.

A continuación se carga una serie temporal de la base de datos de electricidad, y se obtienen los parámetros tras la optimización mediante el método simplex de Nelder-Mead (Nelder, Mead, y Nelder R. 1965; Lagarias et al. 1998). Se realiza posteriormente una previsión de 336 medias-horas y se muestra el resultado gráficamente.

```
>> emts = REEmts;
>> emts.LoadData('db','peninsula','serie','hor_demanda',
'start','2007-07-02 00:00','end','2008-07-02 00:00');
>> mmts = mshw(emts);
>> mmts.Seasons = [24 168];
>> mmts.FindParams('multiseeding','no')
>> y = mmts.forecast(336,'plot','yes');
>> mmts
```

```
mmts =
```

Multiple Seasonal Time Series class with...

Name : demanda
Seasonal 1 with Length : 24
Seasonal 2 with Length : 168
Data length : 8785

Time Info

Non-Uniform Time:
Length 8785

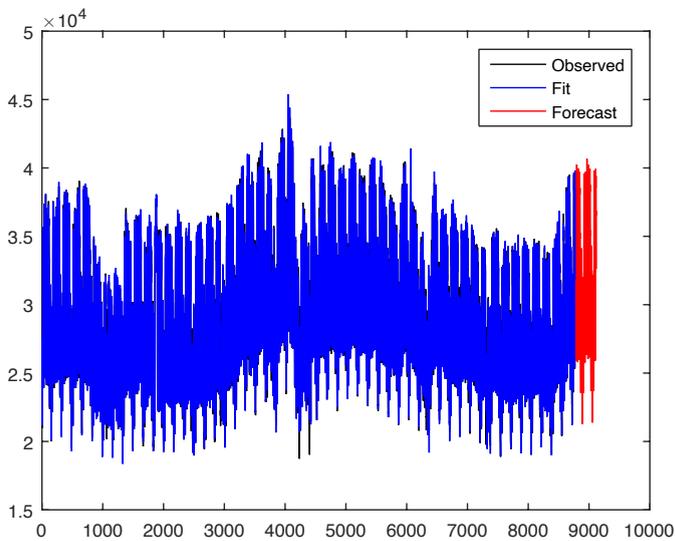
Time Range:
Start 02-Jul-2007 00:00:00
End 02-Jul-2008 00:00:00

Common Properties:
Units: 'hours'
Format: 'yyyy-mm-dd HH:MM'
StartDate: '02-Jul-2007 00:00:00'

Multiple Holt Winters Taylor exponential smoothing params...

MODEL : AMC
Statistic used for optimisation: RMSE
Method used for optimisation: SIMPLEX
Methods used for initialisation: Level:moving average,
Trend: twoseasons and Seasonal : normal
alpha : 0.011965
gamma : 0.000674
delta(24): 0.242530
delta(168): 0.211448
AR1 Adjustment : 0.953036

>>



d) Inclusión de DIMS en el modelo

Este ejemplo crea un objeto DIMS a partir de la información de calendario de España. Lo integra dentro de un objeto *mshw* que contiene información cargada de una base de datos.

```
>> hmts = mts.timecalendar('spain')
```

```
hmts =
```

```
TimeCalendar class with...
```

```
-----  
Location: spain  
-----
```

```
>> emts = REEmts;  
>> emts.LoadData('db','peninsula','serie','hor_demanda',  
'start','2007-07-02 00:00','end','2011-07-02 00:00');
```

```
>> h = hmts.makeDIMS('dims','easter','time',  
emts.getabstime,'format','yyyy-mm-dd HH:MM')
```

280

h =

```
name: 'Easter DIMS'  
length: 192  
pos: [4x1 double]
```

```
>> mmts = mshw(emts);  
>> mmts.Seasons = [24 168];  
>> mmts.addDIMS(h)
```

ans =

Multiple Seasonal Time Series class with...

```
-----  
Name : demanda  
Seasonal 1 with Length : 24  
Seasonal 2 with Length : 168  
Data length : 34948  
-----
```

Time Info

```
Non-Uniform Time:  
Length    34948
```

```
Time Range:  
Start     02-Jul-2007 00:00:00  
End       02-Jul-2011 00:00:00
```

```
Common Properties:  
Units: 'hours'  
Format: 'yyyy-mm-dd HH:MM'  
StartDate: '02-Jul-2007 00:00:00'  
-----
```

Multiple Holt Winters Taylor exponential smoothing params...

MODEL : AMC

Statistic used for optimisation: RMSE

Method used for optimisation: SIMPLEX

Methods used for initialisation: Level:moving average,

Trend: twoseasons and Seasonal : normal

DIMS present:

1) Name:Easter DIMS, Length:192

>>

e) Carga de la temperatura de una ciudad en un objeto
mshw

El siguiente ejemplo carga los datos climáticos de la ciudad de Valencia y los introduce como variables exógenas en un objeto *mshw*.

```
>> emts = REEmts;
```

```
>> emts.LoadData('db','peninsula','serie','hor_demanda',  
'start','2015-07-02 00:00','end','2016-07-02 00:00',  
'rebuilt','missings');
```

```
>> emts
```

```
emts =
```

```
Multiple Seasonal Time Series class with...
```

```
Name : demanda
```

```
Seasonal periods empty
```

```
Data length : 8785
```

```
Time Info
```

Uniform Time:

Length 8785

Increment 1 hours

Time Range:

Start 02-Jul-2015 00:00:00

End 02-Jul-2016 00:00:00

Common Properties:

Units: 'hours'

Format: 'yyyy-mm-dd HH:MM'

StartDate: '02-Jul-2015 00:00:00'

```
>> wmts = Weathermts;
>> wmts.LoadData('db','europe','serie','sp_valencia',
'rebuilt', 'missings');
Warning: Must provide initial and final dates to load. The
complete series will be
loaded.
> In Weathermts.manageTables (line 188)
  In Weathermts/LoadData (line 137)
>> wmts

wmts =
```

Multiple Seasonal Time Series class with...

Name : sp_valencia

Seasonal periods empty

Data length : 76753

Detected missing values: 76753

Time Info

Uniform Time:

Length 76753

Increment 1 halfhour

Time Range:

Start 01-May-2013 00:00:00

End 16-Sep-2017 00:00:00

Common Properties:

Units: 'halfhour'

Format: 'yyyy-mm-dd HH:MM'

StartDate: '01-May-2013 00:00:00'

Regressors available

tempm, tempi, dewptm, dewpti, hum, wspdm, wspdi, wgustm,
wgusti, wdird, wdire,

vism, visi, pressurem, pressurei, windchillm, windchilli,
heatindexm,

heatindexi, precipm, precipi, conds, icon, fog, rain, snow, hail,
thunder,

tornado

Attention: time series must be synchronised.

>> **emts.XReg = wmts**

emts =

Multiple Seasonal Time Series class with...

Name : demanda

Seasonal periods empty

Data length : 8785

Time Info

Uniform Time:

Length 8785

Increment 1 hours

Time Range:

Start 02-Jul-2015 00:00:00

End 02-Jul-2016 00:00:00

Common Properties:

Units: 'hours'

Format: 'yyyy-mm-dd HH:MM'

StartDate: '02-Jul-2015 00:00:00'

Regressors available

tempm, tempi, dewptm, dewpti, hum, wspdm, wspdi, wgustm,
wgusti, wdird, wdire,

vism, visi, pressurem, pressurei, windchillm, windchilli,
heatindexm,

heatindexi, precipm, precipi, conds, icon, fog, rain, snow, hail,
thunder,

tornado

Attention: time series must be synchronised.

>> **emts.synchronise**

The synchronisation of the values may damage the current data.

Continue Y/N? [Y]?

>> **emts**

emts =

Multiple Seasonal Time Series class with...

Name : demanda

Seasonal periods empty

Data length : 8785

Time Info

Uniform Time:

Length 8785
Increment 1 hours

Time Range:

Start 02-Jul-2015 00:00:00
End 02-Jul-2016 00:00:00

Common Properties:

Units: 'hours'
Format: 'yyyy-mm-dd HH:MM'
StartDate: '02-Jul-2015'

Regressors available

tempm, tempi, dewptm, dewpti, hum, wspdm, wspdi, wgustm,
wgusti, wdird, wdire,
vism, visi, pressurem, pressurei, windchillm, windchilli,
heatindexm,
heatindexi, precipm, precipi, conds, icon, fog, rain, snow, hail,
thunder,
tornado

>>

Modelo mixto con indicadores turísticos
Script de MATLAB.

```
% Electricidad en horas  
emts = REEmts;  
emts.LoadData('db', 'balears', 'serie', 'MALLORCA_dem  
andafina', 'rebuilt', 'outliers');  
  
% Datos Temperatura  
wmts = Weathermts;  
wmts.LoadData('db', 'europe', 'serie', 'sp_mallorca', '  
rebuilt', 'missings');  
emts.XReg = wmts;
```

```

emts.synchronise('silent');

emts.resample('hours');

%tpoly = emts.VShape('tempm','distributed');

% Datos IPH
dbmts = DBmts;
dbmts.LoadData('db','offline','serie','IBS_DIPH','data','mallorca');
dbmts.addRegressor(dbmts.getabstime,'time');
dbmts.addRegressor(dbmts.Data,'iph');

iphmts = mshw(dbmts);
iphmts.Seasons = 365;
iphmts.Range = [5965 5964+1660];
iphmts.FindParams;

e_iph = iphmts.Data - iphmts.forecast(0);

(...)

for n=1:24

    mmts = mshw(emts.Data,[7
365],'time',emts.getabstime,'units','hours');
    mmts.resample('days',n);
    mmts.Range = [1495 1660]; % Mallorca

    test = mmts.Data;

    mmts.Model = modelo;
    mmts.Range = [1 td]; % Mallorca

    p = mmts.FindParams;
    y = mmts.forecast(7);
    fc_7_365 (n,:) = y(end-6:end);
    tmape = mmts.rmape(7,test,false);
    mmape_7_365(n) = mean(tmape);
    mmts.addRegressor(iphmts.getabstime,'time');
    mmts.addRegressor(e_iph,'eiph');
    mmts.synchronise('silent')
    mmts.Range = [1 td]; % Mallorca
    p =
mmts.FindParams('verbose','yes','xreg','eiph');

```

```
y = mmts.forecast(7);
fc_2_7_365 (n,:) = y(end-6:end);
tmape = mmts.rmape(7,test,false,'xreg','eiph');
imape_7_365(n) = mean(tmape);
piph_7_365(n,:) = p;

xmts = mshw(emts.Data,[7
365], 'time',emts.getabstime, 'units', 'hours');
xmts.resample('days',n);
xmts.addRegressor(iphmts.getabstime, 'time');
xmts.addRegressor(e_iph, 'eiph');
xmts.synchronise('silent');
xmts.Model = modelo;
xmts.Range = [1 td]; % Mallorca
p =
xmts.FindParams('verbose','yes','xreg','eiph');
y = mmts.forecast(7);
fc_x_7_365 (n,:) = y(end-6:end);
tmape = xmts.rmape(7,test,false,'xreg','eiph');
xmape_7_365(n) = mean(tmape);
xiph_7_365(n,:) = p;

end
```

Modelo híbrido con Redes Neuronales

Script de MATLAB

```
% Cargamos los datos de electricidad. Se utilizan
los datos m*s actuales
% obtenidos directamente de REE. No los de esios.
% Se utilizan únicamente los que se ha corregido el
DST y los faltantes, si
% los hubiera. No se ha filtrado la serie.

emts = REEmts;
emts.LoadData('db','peninsula','serie','hor_demanda
','rebuilt','missings');

% Cargamos los datos de temperaturas, que se
proporcionan por Wunderground.
% Aunque esta web ha dejado de hacerlo, tenemos los
suficientes. Se aplica
```

```

% la ponderaciÙn de Moral-Carcedo y Vicens-Otero
(2005)
wmts = Weathermts;
wmts.MCVO('rebuilt','missings');

% Debemos ahora incluir los datos de temperatura en
la serie de demanda
% elÈctrica antes de hacer nada, para que los datos
se sincronicen.
emts.XReg = wmts;
emts.synchronise('silent');

temp = emts.XReg;

% desde Julio del 2007 hasta Julio 2015. Fechas
al azar, donde se han
% eliminado las fechas en dÌas festivos.
fechas = {...
    '21-01-2014','24-02-2014','17-03-
2014','12-04-2014','21-05-2014','14-06-2014','29-
07-2014','13-07-2014','25-08-2014','29-09-
2014','27-10-2014','24-11-2014',...
    '21-01-2015','24-02-2015','17-03-
2015','12-04-2015','21-05-2015','14-06-2015','29-
07-2015','13-07-2015','25-08-2015','29-09-
2015','27-10-2015','20-11-2015',...
    '21-01-2016','24-02-2016','17-03-
2016','12-04-2016','21-05-2016','14-06-2016','29-
07-2016','13-07-2016','25-08-2016','29-09-
2016','27-10-2016','20-11-2016',...
    '21-01-2017','24-02-2017','17-03-
2017','12-04-2017','21-05-2017','14-06-2017','29-
07-2017','13-07-2017','25-08-2017','29-09-
2017','27-10-2017','20-11-2017'};

nfechas = numel(fechas);
nmodelos = numel(modelos);

%Preparado datos para la Red Neuronal
sdata = mmts.Data;
wdata = cell2mat(wmts.XReg(2,2:end));

prevDSHE = [nan(24,1); sdata];
prevWSHE = [nan(168,1); sdata];

t = emts.getabstime;

```

```
tDoW = weekday(t);
t = datevec(t);
tHour = t(:,4);

(...)

for n=1:nmax

    fechaR = fechas{n};

    for l = 1:1

        mmts.clear;
        nfecha = datenum(fechaR, 'dd-mm-yyyy');
        nfecha = nfecha+(l-1)*randi(35,1);
        efecha = datestr(nfecha+7*8, 'yyyy-mm-dd
HH:MM');
        tfechal = mmts.index(efecha);
        tfechal = tfechal + 1;
        tfecha2 = tfechal + 168*2 -1;
        nfecha = datestr(nfecha, 'yyyy-mm-dd
HH:MM');

        mmts.Range = [tfechal tfecha2];
        test = mmts.Data;

        for m=1:1

            % pos = (n-1)*3+1;
            pos = n;

            result_24_168 = cell(8,1);

            % Establecemos rango y obtenemos
par.metros
            mmts.clear;
            mmts.Range = {nfecha efecha};

            mmts.Model = modelos{m};

            %Mensaje
            fprintf('Analizando result_24_168_%s
para %d hasta %d\n', mmts.Model, nfecha, efecha);

            r = mmts.getabstime;
```

```

result_24_168{1,1} = nfecha;
result_24_168{2,1} = efecha;
result_24_168{8,1} = modelos{m};

tic
p = mmts.FindParams();
result_24_168{3,1} = p;
t = toc;

result_24_168{4,1} = {sprintf('elapsed
time: %d',t)};

m1 = mmts.rmape(24,test,false);
result_24_168{5,1} = m1;

t1f = emts.index(nfecha);

t1 = numel(test);
fc = nan(24,t1);

for nfore = 1:t1

    t2f = emts.index(efecha)+nfore-1;

    mmts.Range = [];
    mmts.Range = [t1f t2f];

% Ahora comparamos una los valores del ajuste
y = mmts.forecast(0,'params',p);

edata = sdata(t1f:t2f);

%
r_tHour = tHour(t1f:t2f);
r_tDoW = tDoW(t1f:t2f);
r_wdata = wdata(t1f:t2f,:);

r_prevDSHE = prevDSHE(t1f:t2f);
r_prevWSHE = prevWSHE(t1f:t2f);

%
X = [y r_wdata r_prevDSHE
r_prevWSHE r_tDoW r_tHour]';
%
trainFcn = 'trainlm'; % Levenberg-
Marquardt backpropagation.

```

```
%
%           % Create a Fitting Network
           hiddenLayerSize = 40;
           net =
fitnet(hiddenLayerSize,trainFcn);
%
%           % Setup Division of Data for
Training, Validation, Testing
           net.divideParam.trainRatio =
70/100;
           net.divideParam.valRatio = 15/100;
           net.divideParam.testRatio = 15/100;
%
%           % For a list of all performance
functions type: help nnperformance
           net.performFcn = 'mse'; % Mean
Squared Error
%
%           % Train the Network
           net.trainParam.showWindow = false;
           [net,tr] = train(net,X,edata');
           tf2 = (t2f+1):(t2f+24);
           r_tHour = tHour(tf2);
           r_tDoW = tDoW(tf2);
           r_wdata = wdata(tf2,:);

           r_prevDSHE = prevDSHE(tf2);
           r_prevWSHE = prevWSHE(tf2);

           y = mmts.forecast(24);

           X = [y(end-23:end)
r_wdata r_prevDSHE r_prevWSHE r_tDoW r_tHour]';
           y = sim(net,X);

           fc(:,nfore) = y(end-23:end);

           end
           m2 = nan(24,1);
           for nfore = 1:24
               m2(nfore) =
mean(abs((test(nfore:end)-fc(nfore,1:(end-
nfore+1)))') ./test(nfore:end))) *100;
           end
```

(...)

```
    end  
  end  
end
```


INDICE DE FIGURAS

Figura 2.1. Esquema de funcionamiento de la determinación de los precios en función de la demanda por parte de OMIE.....	16
Figura 2.2. Demanda eléctrica horaria agregada en España. Periodo desde julio del 2007 hasta finales del 2017.....	19
Figura 2.3. Demanda eléctrica horaria en España entre 1998 y mediados de 2004.	20
Figura 2.4. Demanda mensual de la electricidad en España. Los datos corresponden al periodo de 1998 a 2004.....	22
Figura 2.5. Demanda mensual de electricidad en España en el periodo de 2007 hasta 2017.	23
Figura 2.6. Demanda diaria en el periodo 1998-2004	24
Figura 2.7. Demanda eléctrica diaria en España. Se presentan los años 2000 y 2008, como parte de dos ciclos económicos diferentes.	25
Figura 2.8. Demanda máxima diaria en el año 2008.....	27
Figura 2.9. Demanda eléctrica horaria en las diferentes estaciones del año. La media es la línea central, mientras que la variabilidad se expresa en la zona sombreada. Las abscisas reflejan las horas desde el inicio de la estación y las ordenadas la demanda horaria en MW.	29
Figura 2.10. Evolución de la demanda eléctrica horaria en tres semanas del año 2008. Se aprecia una componente que se repite los días laborables, y en menor medida los fines de semana. Esta componente es la estacionalidad intradiaria, mientras que el patrón que se repite todas las semanas es la estacionalidad intrasemanal.....	31

Figura 2.11. Análisis espectral de la serie basado en un modelo AR(48)..... 33

Figura 2.12. Distribución de la luz solar según el calendario de verano e invierno. En azul las horas de oscuridad, y en rojo las de luz. Se aprecia cómo el cambio del horario supone un salto en la continuidad de la evolución de la salida y puesta de sol..... 34

Figura 2.13. Efecto del adelanto y retraso horario en el calendario (DST) sobre la serie de demanda eléctrica. 35

Figura 2.14. Efecto que se produce en la demanda cuando ocurre un día festivo. Se muestra el ejemplo de la Asunción. El día 15 de agosto es festivo en toda España. Se aprecia como la línea negra – demanda real - tiene una irregularidad ese día comparado con lo que sería un día normal (línea roja). Esta irregularidad se denomina efecto calendario. 37

Figura 3.1. Evolución de los artículos publicados relacionados con la previsión de electricidad. La línea de puntos representa las publicaciones en general, y la línea continua representa los trabajos específicos para la previsión de demanda eléctrica. ... 40

Figura 3.2. Evolución de las publicaciones relacionadas con la previsión eléctrica en España. 41

Figura 3.3. Artículos publicados en WoS relacionados con el suavizado exponencial, modelos de Holt-Winters y HW para previsión de demanda. 42

Figura 3.4. Estructura propuesta para la clasificación de las técnicas de previsión de demanda eléctrica..... 50

Figura 3.5. Diagrama de una red neuronal. Las entradas (6 en este caso) se conectan con una red de neuronas en una capa oculta (de 20 neuronas), y una capa de salida (1 neurona)..... 64

Figura 4.1. Representación de la semana 24 en varios años. Se aprecia como existe un patrón que se repite diariamente, y otro que se repite de forma semanal..... 85

Figura 4.2. Representación de la demanda diaria en dos años diferentes. La forma descrita por ambas representaciones es similar, porque comparten un patrón estacional..... 86

Figura 4.3. Evolución del MAPE en las previsiones “dentro de la muestra” utilizadas por los diferentes modelos doble estacionales. Los resultados prácticamente se superponen. Además, se contrasta con los resultados de las previsiones de REE. 101

Figura 4.4. Comparación de las previsiones realizadas por el modelo AMC24,168 y por los datos de previsión de REE. Las fechas de la previsión se indican en la gráfica..... 103

Figura 5.1. Demanda eléctrica horaria en España entre los años 1999 y 2004. 118

Figura 5.2. Gráfico de medias LSD correspondiente al ensayo realizado. Se muestra el MAPE (%) con los parámetros sin optimizar..... 121

Figura 5.3. Gráfico de medias para el tiempo en segundos de optimización según modelo..... 123

Figura 5.4. Gráficos de medias para el MAPE según los métodos de inicialización analizados. De arriba abajo: nivel, tendencia y estacionalidad. Los niveles utilizados son los descritos en la Tabla 3 del capítulo. 124

Figura 5.5. Distribución del valor inicial de tendencia (T0) para los modelos con tendencia aditiva AMC24,168 y AAC24,168 en función de los métodos utilizados para su obtención, descritos en la Tabla 5.3. Los valores que se muestran son el valor de T0.126

Figura 5.6. Distribución del valor inicial de nivel S_0 para el modelo AMC24,168 y AAC24,168 en función del método utilizado. Los valores mostrados son los valores de S_0 127

Figura 5.7. Distribución de los índices estacionales iniciales para el modelo AMC24,168 utilizando el método simple. En la parte

superior la estacionalidad de 24 horas, y en la inferior la de 168. La línea central representa la media de los valores, independientemente de la época del año, mientras que la zona sombreada representa la variabilidad con +/- una desviación estándar. 128

Figura 5.8. Distribución de los índices estacionales iniciales para el modelo AMC24,168 utilizando el método Winters. En la parte superior la estacionalidad de 24 horas, y en la inferior la de 168. La línea central representa la media de los valores, independientemente de la época del año, mientras que la zona sombreada representa la variabilidad con +/- una desviación estándar. 129

Figura 6.1. Desglose de las ventanas utilizadas para el análisis de los parámetros. El periodo global se divide en años, y dentro de cada año se divide en 4 ventanas según la estación del año. Para cada ventana, se utilizan diferentes réplicas aleatorizadas de 5 semanas. 135

Figura 6.2. Distribución de los tiempos necesarios para realizar la optimización de los modelos. Este tiempo se mide en segundos, y ha sido generado en la obtención de los parámetros utilizando la serie de demanda eléctrica en el periodo de 1998 a 2004... 138

Figura 6.3. Distribución de los parámetros de suavizado estacionales intradiario e intrasemanal para el conjunto de datos 1998-2004. 141

Figura 6.4. Diagrama de radar para los parámetros de suavizado asociados a la estacionalidad. 142

Figura 6.5. Diagrama de radar del MAPE de las previsiones para el modelo NMC24,168 en el conjunto de datos 2008-2017... 145

Figura 6.6. Diagrama de radar para la representación de la media de los parámetros en función del tiempo para el modelo NMC24,168. 147

Figura 6.7. MAPE de la pevisión a 24 horas en función del tamaño del conjunto de datos utilizado.	148
Figura 6.8. Evolución de los parámetros frente al tamaño del conjunto de datos.....	149
Figura 6.9. Evolución del MAPE de la previsión a 24 horas con el tamaño del conjunto de datos.	153
Figura 7.1. Comparativa del efecto producido por un evento especial (Pascuas en este caso) sobre la serie de demanda horaria eléctrica en España. La serie sufre una demanda anómala (línea llena) que el modelo de series temporales (línea a trazos) no es capaz de reproducir, al ser diferente del patrón observado anteriormente.....	159
Figura 7.2. Efecto provocado por una huelga sobre la demanda eléctrica horaria en España. Se aprecia como el patrón que siguen las series temporales se trunca con un descenso el día de la huelga. No obstante, este descenso sigue un patrón similar...	164
Figura 7.3. Diagrama de flujo para la utilización de los DIMS. En la parte izquierda se encuentra el diagrama troncal, y a su derecha se muestran los desarrollos de cada una de las macro etapas.	168
Figura 7.4. Comparativa de previsión a 24 horas para el modelo AAC24,168 (línea discontinua) frente al modelo AAC24,168, DIMS que incluye los DIMS (línea llena). La demanda real se muestra con la línea gruesa. Se aprecia fácilmente como la previsión realizada por el modelo que utiliza DIMS es mucho más precisa que la que no lo lleva.....	173
Figura 7.5. Comportamiento especial de la demanda eléctrica horaria en España en periodos de Pascua en los últimos años. Cada gráfica muestra la demanda en periodos adyacentes a las Pascuas y en dicho periodo.....	175
Figura 7.6. Previsiones de 24 horas en delante de los modelos nHWT regulares y los modelos nHWT con DIMS propuestos.	

Las previsiones se muestran a partir del inicio de la previsión (IdP).....	180
Figura 7.7a. Comparativa de la previsión de 16 de agosto de 2014, domingo.....	184
Figura 8.1. Demanda eléctrica horaria en la isla de Mallorca.	193
Figura 8.2. Comparativa y evolución del PIB turístico en España y en las Islas Baleares. Fuente: Elaboración propia a partir de datos de Exceltur.	194
Figura 8.3. Emisiones de CO ₂ en las Islas Baleares en el periodo de 2014 a 2018 debido a la generación de electricidad. El factor de emisión se mide como el cociente entre las emisiones por energía conseguida.	195
Figura 8.4. Mix energético de la producción eléctrica en la Islas Baleares.	196
Figura 8.5. Balance de entradas y salidas anuales a las islas mediante transporte marítimo (izquierda) y aéreo (derecha). Fuente: IBESTAT.....	197
Figura 8.6. Evolución del indicador diario de presión humana en las islas de Mallorca y Menorca. El eje de la izquierda es la escala para Mallorca, mientras que el de la derecha es para Menorca. Fuente: IBESTAT.....	198
Figura 8.7. Esquema de aplicación del modelo HW con la introducción del IDPH.....	202
Figura 8.8. Media de las previsiones realizadas con el modelo HW-IDPH frente al modelo HW y los datos reales.....	205
Figura 9.1. Esquema explicativo de una neurona (izquierda) y de una red neuronal (derecha) perceptron multicapa.	211
Figura 9.2. Demanda eléctrica en Mallorca.....	214

Figura 9.3. Temperatura del aire en Mallorca.	214
Figura 9.4. Curva V de demanda-temperatura para la Isla de Mallorca. Los puntos se distribuyen según la hora (1 a 24h). 215	
Figura 9.5. Método híbrido de previsión mediante el uso de modelos de Holt-Winters múltiple-estacionales con redes neuronales para la temperatura.	217
Figura 9.6. Temperatura ponderada en la Península Ibérica ..	220
Figura I.0.1. Esquema del funcionamiento de la aplicación...	271
Figura I.0.2. Ejemplos de salidas ofrecidas por la aplicación.	272
Figura I.0.3. Esquema de la estructura de la aplicación, organizada en clases.	273

INDICE DE TABLAS

Tabla 2.1. Desglose accionarial de participación en OMEL holding.....	14
Tabla 2.2. Datos financieros de Red Eléctrica de España.	17
Tabla 2.3. Clasificación de los horizontes de previsión y sus características principales.	21
Tabla 4.1. Resumen de los modelos Holt-Winters múltiple-estacionales implementados.	93
Tabla 4.2. Modelos Múltiple-estacionales de Holt-Winters (nHWT). En filas se organiza por métodos de tendencia, mientras que en columnas por estacionalidad.	94
Tabla 4.3. Comparativa del MAPE simétrico (sMAPE %) de los modelos que han resultado ser los más precisos. Los resultados se organizan según los modelos y alternativas de estudio. Se muestra únicamente un día de cada periodo estudiado.....	100
Tabla 5.1. Métodos propuestos para la obtención del valor inicial el nivel.	111
Tabla 5.2. Métodos propuestos para la estimación del valor inicial de la tendencia en métodos múltiple-estacionales, adaptando los métodos actuales.....	113
Tabla 5.3. Resumen de los factores y niveles analizados.....	120
Tabla 5.4. Análisis de la varianza para los factores estudiados utilizando los modelos con tendencia multiplicativa, sin realizar ajuste.....	122
Tabla 5.5. Análisis de la varianza para los factores estudiados utilizando los modelos con tendencia aditiva, sin ajuste.....	122

Tabla 6.1. Desglose de la distribución del MAPE para el ajuste y el sMAPE de la previsión realizada a 24 y 168 horas para los modelos a estudiar. El desglose se realiza de acuerdo a la estación del año.....	139
Tabla 6.2. Parámetros de suavizado para el modelo <i>AMC24,168</i> y el MAPE en el ajuste.	140
Tabla 6.3. Resumen del MAPE de previsión a 24 horas en los modelos doble estacionales desglosado por años.	144
Tabla 6.4. Distribución de los parámetros del modelo <i>NMC24,168</i>	146
Tabla 6.5. Distribución de los valores de los parámetros de suavizado para el modelo <i>AMC24,168,8766</i>	150
Tabla 7.1. Cálculo de los pesos de los valores de la serie sobre la serie reconstruida. En las columnas se encuentra cada aparición del DIMS, y en las filas cada instante de tiempo dentro de la estacionalidad discreta.	169
Tabla 7.2. Obtención de los índices estacionales a partir de las medias aritméticas de los pesos en cada instante de tiempo...	170
Tabla 7.3. Comparativa de previsiones a 24 horas utilizando los DIMS frente a los modelos regulares. En esta comparación, se utiliza el MAPE(%) a 24 horas para comparar la precisión de los modelos.....	172
Tabla 7.4. Periodos de Pascua en España. Comienza con el domingo de ramos y termina con el domingo de resurrección. En la tabla se muestran las fechas de estos eventos desde el 2008 hasta el 2015.	174
Tabla 7.5. Marco del análisis. Dos tipos de optimización, y diferentes fechas de inicio y longitud de la estacionalidad. Adicionalmente, dos métodos son estudiados.	176

Tabla 7.6. MAPE obtenido en previsiones a 24 horas durante las Pascuas. Las cabeceras de las columnas indican el modelo, AMC o AAC, y las variantes. Estas son 0 para el modelo regular (sin DIMS), mientras que el resto se corresponde al periodo utilizado. Sólo se muestran el caso 1 y 2 porque el resto no ha proporcionado mejores resultados. Dentro de cada caso, además se muestra el resultado según el método utilizado. En la Tabla 7.5 se muestran las descripciones para cada caso..... 177

Tabla 7.7. Comparativa del MAPE para previsiones de 168 horas en adelante entre los modelos regulares nHWT y los nuevos propuestos con DIMS. La columna de cabecera indica el día para el cual se realizó la previsión..... 178

Tabla 7.8. Resumen de los MAPE de previsión a 24 horas obtenidos en las fechas indicadas. 182

Tabla 8.1. Mejora de la precisión de los modelos propuestos frente al modelo original. Valores de MAPE a 24h en 7 días. 204

Tabla 8.2. Reducción del MAPE de acuerdo a la hora 204

Tabla 9.1. Comparativa de reducción del MAPE(%) de las previsiones realizadas con el método regular frente a las realizadas con la nueva metodología. 218

Tabla 9.2. Pesos otorgados a las áreas indicadas en la tercera columna, con las provincias que se incluyen, utilizando como ciudad representativa de la temperatura, la indicada en la primera columna. Extraído de (Moral-Carcedo & Vicéns-Otero, 2005) 219

Tabla 9.3. Resumen de la mejora realizada en el MAPE de las previsiones al incluir la temperatura..... 221

