

# Universidad Miguel Hernández de Elche

Departamento de Ingeniería Mecánica y Energía



“Predicción de la demanda eléctrica utilizando técnicas de inteligencia artificial. Aplicación al mercado eléctrico español.”

Tesis Doctoral

*Memoria presentada para optar*

*al grado de Doctor por:*

D. Miguel López García

*Dirigida por:*

Dr. Sergio Valero Verdú

Dra. Carolina Senabre Blanes



Dr. SERGIO VALERO VERDÚ, Profesor Contratado Doctor de la Universidad Miguel Hernández de Elche y Dra. CAROLINA SENABRE BLANES, Profesor Contratado Doctor de la Universidad Miguel Hernández de Elche,

CERTIFICAN:

Que la presente memoria “*Predicción de la demanda eléctrica utilizando técnicas de inteligencia artificial. Aplicación al mercado eléctrico español.*”, ha sido realizada bajo su dirección, en el Departamento de Ingeniería Mecánica y Energía de la Universidad Miguel Hernández de Elche, por el Licenciado D. MIGUEL LÓPEZ GARCÍA, y constituye su tesis para optar al grado de Doctor.

Para que conste, en cumplimiento de la legislación vigente, autoriza la presentación de la referida tesis doctoral ante la Comisión de Doctorado de la Universidad Miguel Hernández de Elche, firmando el presente certificado.

Elche, 27 de Noviembre de 2015



Fdo. Dr. Sergio Valero Verdú

Fdo. Dra. Carolina Senabre Blanes

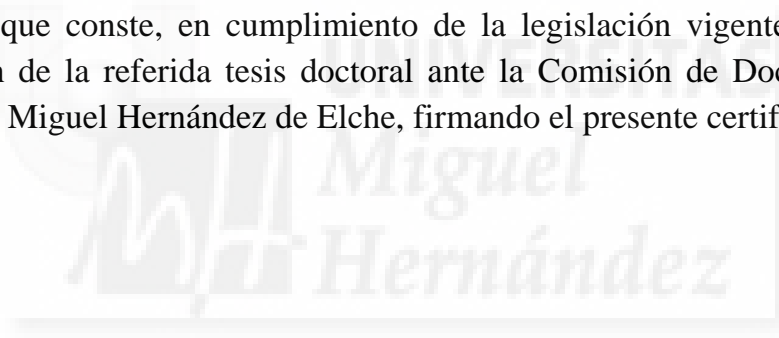


D. PIEDAD NIEVES de AZA MOYA, Catedrática de Universidad y director del Departamento de Ciencia de Materiales, Óptica y Tecnología Electrónica de la Universidad Miguel Hernández de Elche,

CERTIFICA:

Que la presente memoria *“Predicción de la demanda eléctrica utilizando técnicas de inteligencia artificial. Aplicación al mercado eléctrico español.”*, realizada bajo la dirección de Dr. SERGIO VALERO VERDÚ y Dra. CAROLINA SENABRE BLANES, en el Departamento de Ingeniería Mecánica y Energía de la Universidad Miguel Hernández de Elche, por el Licenciado D. MIGUEL LÓPEZ GARCÍA, constituye su tesis para optar al grado de Doctor.

Para que conste, en cumplimiento de la legislación vigente, autoriza la presentación de la referida tesis doctoral ante la Comisión de Doctorado de la Universidad Miguel Hernández de Elche, firmando el presente certificado.



Elche, 27 de Noviembre de 2015

Fdo. Dra. Piedad Nieves de Aza Moya



# Agradecimientos

*“—Amar, querido amigo, es un verbo. El amor —el sentimiento— es el fruto de amar, el verbo. De modo que ámela. Sírvala. Sacrifíquese por ella. Escúchela. Comparta sus sentimientos. Apréciela. Apóyela. ¿Está dispuesto a hacerlo?”*

S. R. Covey

Dedicado a mi familia.

Quiero agradecer a mis directores de tesis su labor de dirección de este trabajo, su amistad y su apoyo.

Quiero agradecer a todos los industriales su interés y su apoyo en las decisiones profesionales que han conducido a esta tesis. María Emilia, gracias por poner banda sonora a otro “histórico”.

Quiero agradecer a Aída su ejemplo y su guía. Gracias por mantenerte cerca.

Quiero agradecer a Carolina y Manuel, mis padres, su fe inquebrantable en que al final el niño hace las cosas bien.

Quiero agradecer a Ana su infinito amor, apoyo y comprensión en todos los momentos. Porque tenerla en mi vida hace que sólo se pueda disfrutar de cada minuto. Gracias Victoria por ayudarme a trabajar con tu sonrisa en mi despacho y en mi nuevo despacho. Gracias Carlos por... dormir, dejar dormir y... ser una fuente de alegría para todos.





# Resumen

La evolución de los mercados hacia una economía más libre en la que los roles del productor y el consumidor se solapan e incluso llegan a confundirse está llegando al sector eléctrico. La diversificación de la producción o la capacidad de alterar los patrones de consumo hacen que la participación en los mercados eléctricos y la operación de los sistemas deban dar un paso adelante para gestionar de forma eficiente esta dinamización de los comportamientos.

La tecnología ha permitido incrementar el número de decisiones posibles que pueden tomar tanto productores como consumidores. Aumenta el número de tecnologías capaces de producir energía pero se incrementa el número de restricciones sobre los horarios de funcionamiento de los mismos. Aumenta el número de tecnologías que consumen electricidad pero también la capacidad de programar los consumos e incluso de almacenar energía. En este entorno tan cambiante, los agentes participantes necesitan sistemas de gestión de datos que sirvan de apoyo a su proceso de toma de decisiones para asegurar que éstas nos llevan a un sector más eficiente del que nos beneficiaremos todos.

La predicción de la demanda es una información crucial a la hora de gestionar la realización de ofertas tanto de compra como de venta en el mercado eléctrico y también para operar de forma eficiente el mercado eléctrico y reducir los sobrecostos de ajustes técnicos. Existen múltiples horizontes de predicción para la demanda eléctrica. En esta tesis nos centraremos en la predicción a corto plazo, que incluye desde la predicción de las próximas horas a las de los próximos 10 días.

El problema de la predicción a corto plazo es complejo ya que el número y tipo de variables que influyen en la demanda varía de un caso a otro y las relaciones que se establecen entre estas variables y la demanda suelen presentar un marcado carácter no lineal. Por eso, el proceso de diseño requiere tanto la selección y el procesado de la información más relevante como el diseño de un motor de predicción capaz de captar las relaciones complejas entre demanda e información de entrada.

El trabajo de investigación que aquí se presenta se divide en dos bloques. En primer lugar, se han planteado los sistemas y procesos necesarios para estandarizar el diseño modular de modelos de predicción. Este tipo de diseño permite, además de obtener un modelo de predicción, que cada uno de las etapas en las que consiste en modelo pueda analizarse por separado de manera que se entienda la aportación que realiza a la mejora de la precisión de la predicción. Este trabajo se ha llevado a cabo a través del diseño de un modelo de ejemplo basado en un motor de predicción que utiliza redes neuronales en forma de mapa autoorganizados. Se trata de una técnica cuya aplicación se había circunscrito hasta ahora al ámbito de la clasificación y agrupación de datos pero que en este caso se innova en su aplicación al propio proceso de predicción.

El segundo bloque pretende mejorar el propio proceso de investigación y de colaboración de la comunidad científica. Los resultados de un modelo de predicción son

relevantes pero desgraciadamente dependen en gran medida de las características de la base de datos a la que se apliquen. Por tanto, es imposible conocer si un modelo concreto es aplicable a una base de datos diferente a aquella con la que fue testado o diseñado. Para facilitar este proceso, se han diseñado indicadores de predictibilidad de las bases de datos que permitan caracterizar las relaciones entre la demanda y las variables más relevantes de cada base de datos. De este modo, es posible conocer a qué tipo de base de datos pertenece aquella con la que se han obtenido los resultados reportados y, por tanto, si es similar a aquella con la que el usuario desea trabajar. Se trata de un proceso de *benchmark* fundamental a la hora de establecer un proceso de desarrollo colaborativo.

Finalmente y como aplicación real del trabajo desarrollado, se incluye el diseño de una herramienta de predicción diseñada a petición del operador del sistema eléctrico español, Red Eléctrica de España. Para esta aplicación se incluyen los detalles del diseño y los resultados de funcionamiento para un periodo de 315 días en condiciones reales dentro de las instalaciones de REE. Además se incluyen los resultados de los propios sistemas de REE y se concluye que la inclusión del sistema diseñado en el proceso de predicción de REE produciría reducciones significativas del error de predicción especialmente en los días que actualmente su sistema predice de forma más defectuosa.

Esta tesis se ha realizado bajo la modalidad de presentación de tesis doctorales con un conjunto de publicaciones, recogida en la normativa de la Universidad Miguel Hernández de Elche. En cumplimiento de dicha normativa se han incorporado las publicaciones que la componen como anexo y se han incluido las secciones correspondientes a la descripción general de los trabajos, el resumen global de los resultados obtenidos y las conclusiones finales.

# Índice general

<b>1. Introducción general</b>	<b>1</b>
<b>1.1 Motivación</b>	<b>2</b>
<b>1.2 Estado del arte</b>	<b>4</b>
<b>1.3 Objetivos de la tesis</b>	<b>6</b>
<b>1.4 Publicaciones</b>	<b>7</b>
1.4.1 <i>Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study</i>	<b>8</b>
1.4.2 <i>Short-term predictability of load series: characterization of load data bases</i>	<b>9</b>
1.4.3 <i>New online load forecasting tool for the Spanish national system operator (pendiente de publicación)</i>	<b>10</b>
<b>2. Resultados de investigación</b>	<b>13</b>
<b>2.1 Introducción</b>	<b>14</b>
<b>2.2</b> <i>Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study</i>	<b>14</b>
<b>2.3</b> <i>Short-term predictability of load series: characterization of load data bases</i>	<b>21</b>
<b>2.4</b> <i>New online load forecasting tool for the Spanish national system operator (pendiente de publicación)</i>	<b>26</b>
<b>2.5 Resumen</b>	<b>33</b>
<b>3. Conclusiones</b>	<b>35</b>
<b>3.1 Conclusiones</b>	<b>36</b>
<b>3.2 Trabajo futuro</b>	<b>38</b>
<b>3.3 Otras publicaciones</b>	<b>39</b>
<b>I. Artículos</b>	<b>41</b>
<b>Bibliografía</b>	<b>65</b>



# Índice de figuras

2.1	Agrupaciones de variables para predecir cada uno de los periodos del día.	15
2.2	Resultado de predicción de las agrupaciones óptimas de variables para cada uno de los periodos.	15
2.3	Error de predicción de los últimos 30 días en función del error del día de predicción.	16
2.4	Error de predicción en cada una de las iteraciones del proceso de optimización de variables para 4 puntos de inicio diferentes.	16
2.5	Resultado de predicción en función del periodo de entrenamiento empleado.	17
2.6	Resultado de predicción y tiempo de ejecución en función del tamaño de mapa.	18
2.7	Resultado de predicción a lo largo del año.	18
2.8	Resultado de predicción final agrupado por años.	19
2.9	Potencia de la señal en las frecuencias diaria y semanal	20
2.10	Configuración del filtro gaussiano empleado para extraer las señales predecibles.	22
2.11	Error de predicción de cada señal filtrada en función de la diferencia con la señal original.	22
2.12	Diferencia de la señal filtrada con la señal original en función del valor de $s$ .	23
2.13	Error de predicción de los modelos individuales y combinados y volumen de demanda horaria.	28
2.14	Error de predicción en función de la hora del día.	32
2.15	Error de predicción en función del día de la semana.	32
2.16	Error de predicción en función de la antelación.	33



# Índice de tablas

2.1	Resultados de la aplicación del modelo SOM al mercado eléctrico español	20
2.2	Periodos de las componentes más relevantes de la señal de demanda.	24
2.3	Error de predicción y valores de los diferentes indicadores de predictibilidad empleados.	24
2.4	Parámetros de correlación entre la el error de predicción y los principales indicadores de predictibilidad.	25
2.5	Error de predicción con temperatura y valores de los indicadores propuestos de predictibilidad y su interacción.	25
2.6	Parámetros de correlación entre la el error de predicción con temperatura y los indicadores propuestos de predictibilidad.	26
2.7	Error de predicción de los modelos individuales y combinados. Peso de cada uno de los modelos en la combinación optimizada de referencia.	27
2.8	Error de predicción de los modelos individuales nacionales y su combinación. Peso de cada uno de los modelos en la combinación optimizada de referencia.	28
2.9	Error de predicción de los modelos actuales, modelo propuesto y combinaciones de referencia. Peso de cada uno de los modelos en la combinación optimizada	29
2.10	Error de predicción de los modelos actuales, modelo propuesto y combinaciones de referencia en los días de difícil predicción.	31





# Capítulo 1

## Introducción general

### Índice

<b>1.1</b>	<b>Motivación</b>	<b>2</b>
<b>1.2</b>	<b>Estado del arte</b>	<b>4</b>
<b>1.3</b>	<b>Objetivos de la tesis</b>	<b>6</b>
<b>1.4</b>	<b>Publicaciones</b>	<b>7</b>
1.4.1	<i>Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study</i>	<b>8</b>
1.4.2	<i>Short-term predictability of load series: characterization of load data bases</i>	<b>9</b>
1.4.3	<i>New online load forecasting tool for the Spanish national system operator</i>	<b>10</b>

## 1.1.- Motivación

La gestión de los sistemas eléctricos es compleja y requiere tomar decisiones que pueden afectar en gran medida tanto a la disponibilidad de energía como al coste de la misma. Además, estas decisiones han de tomarse puntualmente y en un entorno de incertidumbre que dificulta el establecimiento de criterios objetivos. Por tanto, es importante contar con herramientas que reduzcan en la medida posible la incertidumbre y proporcionen una base de información fiable y que permita una optimización de los recursos.

El tipo de decisiones al que nos referimos depende del horizonte de tiempo que se considere e incluiría desde las inversiones a realizar en las infraestructuras del sistema como mantenimiento, desmantelamiento o creación de nuevas instalaciones si consideramos plazos tan largos como años o décadas hasta la modificación de los niveles de generación instantánea si los plazos son de pocos minutos pasando por la implementación de estrategias de ofertas de mercado en plazos de horas hasta unos días.

La información que el operador del sistema, los productores de energía o los comercializadores necesitan para mantener un sistema eléctrico operativo y eficiente es variada e incluye valoraciones correctas de los costes de generación, evolución de los precios de mercado, planes de producción y mantenimiento o estimaciones de consumo, entre otros.

Las estimaciones o predicciones de demanda son extremadamente importantes para generadores y comercializadores a la hora de diseñar sus estrategias e participación en el mercado eléctrico y también para el operador del sistema para garantizar la disponibilidad y la eficiencia del sistema. Las predicciones de demanda suelen dividirse en cuatro tipos según el horizonte de predicción:

- Muy corto plazo: de unos minutos a pocas horas.
- Corto plazo: de unas horas a varios días.
- Medio plazo: de una semana a un año.
- Largo plazo: varios años.

Cada una de estas predicciones tiene diferente utilidad y difiere también tanto en la precisión de la predicción como en el detalle de la misma. Mientras que en las predicciones a largo plazo suele estimarse únicamente el pico de demanda o el nivel medio diario, las predicciones de corto plazo requieren un perfil normalmente horario completo que defina toda la curva de demanda del sistema.

La predicción de la demanda ha sido siempre un factor relevante pero ha cobrado una importancia aun mayor con la desregulación de los mercados y de las industrias eléctricas. Las variaciones de precios y de las condiciones meteorológicas provocan fluctuaciones del consumo y la producción que, si no son previstas adecuadamente pueden provocar inestabilidades del sistema. Por eso es necesario que tanto el operador del sistema como las empresas que operan en el mercado cuenten con sistemas capaces

de predecir de forma precisa y puntual la evolución futura de la demanda horaria con un horizonte de varios días.

Existen diversas maneras de elaborar estos sistemas de predicción que pueden estar basados en técnicas estadísticas o en inteligencia artificial como regresiones, redes neuronales, lógica difusa o sistemas expertos. A lo largo de los años, el desarrollo de modelos ha ido adoptando de forma mayoritaria el uso de modelos basados en diferentes técnicas de inteligencia artificial, especialmente por su capacidad de modelar comportamientos no lineales y también por la mejora de la capacidad de computación de la tecnología disponible.

Sin embargo, aunque la mayor o menor complejidad de las técnicas empleadas puede resolver alguno de los problemas que surgen en la predicción de demanda, existen otros factores de igual o mayor importancia como la selección de la información relevante o el pre-procesamiento de la misma. De hecho, para el correcto funcionamiento de un sistema real, será necesario no solo disponer de un modelo matemático que realice predicciones precisas en base a la información proporcionada, sino que además deberá hacerlo dentro de un margen de tiempo definido e incluso en ausencia de alguna de las fuentes de información empleadas.

Los factores que afectan a la demanda son muy variados. En primer lugar existe una clara dependencia horaria a lo largo del día relacionada con los hábitos de comportamiento tanto personales como industriales, pero también existe una variable temporal semanal en la que se distingue no solo una diferencia en las curvas horarias de los fines de semana y los días laborables sino también entre los propios días laborables, especialmente los lunes y los viernes. Las vacaciones y los días festivos también influyen en gran medida sobre el consumo y conllevan una mayor dificultad en su predicción debido principalmente a la singularidad de cada uno. Los días adyacentes a un día festivo o los puentes también poseen características propias que dificultan la predicción.

Otro factor fundamental para la demanda eléctrica es la meteorología. Resulta difícil distinguir entre la variación temporal anual vinculada únicamente a factores de calendario de la variación vinculada a factores meteorológicos pero ambas son indiscutiblemente relevantes. La principal variable que influye sobre la demanda es la temperatura aunque en muchos casos puede emplearse con mayor éxito un índice que combine temperatura y humedad.

Por supuesto, existen otros factores relevantes relacionados con eventos socioculturales o sociopolíticos (p.ej. eventos deportivos o huelgas) cuyo impacto es en general impredecible y que suelen tenerse en cuenta a través de la supervisión de un experto.

La influencia de todos estos factores sobre la demanda depende de los hábitos de consumo y, en general, del volumen de demanda que se pretenda predecir. Con esto nos referimos a que el efecto meteorológico puede ser muy relevante al considerar zonas de tamaño reducido en las que la temperatura sea constante mientras que si consideramos

territorios más extensos, este impacto se diluye y es más difícil de detectar. Lo mismo sucede con los festivales locales o cualquier otro factor de índole territorial y cuyo efecto no se extienda al total del territorio considerado.

La manera en que se traslade la información sobre estos factores relevantes al modelo también tiene una gran importancia en el diseño del sistema de predicción. Las variables socioeconómicas relacionadas con el tipo de día suelen expresarse como variables binarias en las que se codifican las distintas categorías en las que puede caer un día determinado. Las variables meteorológicas presentan la problemática de, en general, no mantener una relación lineal con la demanda, ya que tanto temperaturas muy frías como muy cálidas incrementan el consumo respecto a las temperaturas moderadas. Sin embargo, habitualmente este comportamiento puede linealizarse mediante el empleo de variables derivadas que asociadas a cada uno de los tramos de la función de temperatura. También es importante determinar cuál es la información verdaderamente significativa ya que cuanto más información redundante o simplemente irrelevante incluyamos en el modelo, más dificultamos que el proceso de aprendizaje capte las dependencias reales de la demanda respecto de las variables consideradas.

Por tanto, se hace patente que el diseño de un sistema de predicción de demanda a corto plazo no es un problema de solución sencilla, pero tampoco de una única solución ya que es necesario entender las relaciones de la demanda y el resto de variables que se dan en la zona a predecir, y estas serán diferentes a las que se establecen para otras zonas e incluso, serán variantes en el tiempo, por lo que un mismo modelo puede quedar obsoleto con el paso de los años.

## 1.2.- Estado del arte

En este apartado realizaremos una revisión de las principales técnicas de predicción empleadas en los últimos años. La revisión se centra fundamentalmente en los motores de predicción empleados aunque también incluiremos técnicas de tratamiento de datos como la descomposición por *wavelets* por la atención recibida en los últimos años:

- Regresión: Las técnicas de predicción basadas en modelos de regresión son las más antiguas [1-3] aunque han recibido mucha atención hasta periodos recientes. En general, este tipo de métodos consisten en formular una ecuación que represente los valores de demanda en función de una combinación de una serie de variables. La naturaleza de estas variables determinará el tipo de modelo de regresión que se está utilizando.

En primer lugar, podemos describir los modelos auto-regresivos, AR, en los que las variables se restringen a valores previos de la propia serie de demanda. En los modelos de medias móviles, MA, se considera que el siguiente valor de la serie se obtiene como combinación de la media de la serie hasta ese momento más una combinación de errores previos aleatorios. Este tipo de modelos puede combinarse para formar un modelo ARMA que incluya ambas componentes. Por último, además podemos incluir una componente

de integración que representa la no estacionariedad del modelo. Este tipo de modelos, ARIMA, representan la forma más general de los modelos de predicción.

Los modelos de predicción de regresión ARIMA también pueden incluir variables exógenas en la regresión, modelo ARIMAX y, si se desea incluir una componente periódica (*seasonal* en inglés), pasaríamos a denominarlo modelo SARIMAX.

- **Redes neuronales:** La capacidad de las redes neuronales de modelar comportamientos no lineales ha supuesto que se conviertan en la técnica más popular para los modelos de predicción de demanda más recientes [4-9]. Existen diferentes estructuras de redes neuronales empleadas en la predicción de demanda. La más extendida es el perceptrón multicapa (MLP). Este tipo de redes presentan una capa de neuronas de entrada en la que hay tantas neuronas como variables de entrada. Cada neurona de la capa de entrada está conectada con las neuronas de la capa media. El tamaño de la capa media determina la complejidad de los comportamientos que la red sea capaz de modelar, aunque debe elegirse cuidadosamente para no incurrir en errores de diseño como el *overfitting*, que consiste en diseñar una red capaz de modelar muy bien los comportamientos pasados pero que pierde la capacidad de generalizar a comportamientos futuros. La capa de salida presenta tantas neuronas como variables de salida tenga el modelo. Las neuronas consisten en funciones matemáticas que producen una salida en función de sus entradas y una serie de pesos asociados cuyo ajuste se realiza por algoritmos de entrenamiento que pretenden reducir una función de error. Tanto la diferente estructura de la red (mapas autoorganizados -SOM-) como las diferentes funciones internas de las neuronas (funciones de base radial -RBF-) son posibilidades para dar diferentes comportamientos a la red y que han sido planteados en la literatura.
- **Lógica difusa:** La lógica difusa es una técnica útil para modelar el comportamiento de modelos complejos cuyas reglas no son conocidas pero puede establecerse un enunciado general de funcionamiento. Para aplicar la lógica difusa es necesario crear una serie de conjuntos difusos definidos por una función de pertenencia dependiente de parámetros numéricos. Los conjuntos difusos pueden generarse atendiendo a diferentes variables. Una vez que están establecidos los conjuntos es necesario establecer las reglas que definan los comportamientos. Estas reglas se definen de forma *IF THEN* y tienen la ventaja de permitir definir un comportamiento que un experto puede enunciar pero cuya expresión matemática puede ser compleja. Existen numerosos ejemplos de lógica difusa aplicada a la predicción de demanda en los últimos años [10-12].
- **Support Vector Machines (SVM):** Las SVM son sistemas de clasificación supervisados similares a las redes neuronales y, en concreto a los SOM. La idea básica de funcionamiento es que, dado un espacio multidimensional en el que se definen puntos (vectores de datos), una SVM es capaz de identificar los hiperplanos que parten el espacio multidimensional en semiespacios que agrupan los diferentes vectores por categorías. Ejemplos de SVM como motores de predicción son [13-15].
- **Algoritmos evolutivos:** Generalmente este tipo de técnicas se emplea en conjunción con otra como las redes neuronales, de forma que los algoritmos evolutivos supongan una técnica de ajuste fino en el proceso de entrenamiento [16-18]. En otras ocasiones, los

algoritmos evolutivos se utilizan como métodos de optimización en los que es necesaria una heurística de optimización por la complejidad del modelo.

- Descomposición por *wavelets*: Los *wavelets* son funciones matemáticas que permiten la descomposición de series de datos en dos componentes, una de detalle y otra general. La aplicación recursiva de este tipo de transformaciones permite separar las series de datos en componentes de forma que cada una de ellas presente comportamientos periódicos diferentes y que, por tanto, puedan predecirse por separado con mayor precisión [19]. Los *wavelets* permiten la transformación en coeficientes de la serie de datos y su posterior transformación inversa de manera que puede actuarse por separado sobre cada uno de las componentes. De hecho, es posible incluso realizar modelos de predicción sobre los propios coeficientes, de manera que se obtenga la serie predicha al realizar la transformación inversa [20-22].

Esta revisión de técnicas es una muestra somera de las numerosas publicaciones sobre demanda a corto plazo que se han realizado en los últimos años y que han servido de base para la realización de las publicaciones que integran esta tesis. Puede obtenerse una revisión más exhaustiva de cada una de las secciones de estado del arte de cada uno de los artículos adjuntos pero se ha considerado interesante presentar un pequeño resumen para contextualizar los siguientes apartados.

### 1.3.- Objetivos

El trabajo de investigación que aquí se presenta tiene como objetivo general el expandir las fronteras del conocimiento sobre la predicción de demanda. Para satisfacer un objetivo tan ambicioso, se plantea su desglose en dos vertientes:

- Mejorar la precisión de los modelos actualmente disponibles en su aplicación al sistema eléctrico español: Este objetivo consiste en la aplicación práctica de los conocimientos desarrollados para mejorar los resultados de predicción. En concreto, hemos trabajado sobre las bases de datos del sistema eléctrico español peninsular, centrándonos en la mejora de las predicciones realizadas en la mañana del día anterior.
- Sentar las bases de un estándar de diseño que permita la comparación de resultados y la validación de técnicas concretas para resolver problemas concretos: Este objetivo está relacionado con la situación observable actualmente en la que los modelos propuestos no son capaces de acotar el campo de aplicación en el que pueden considerarse efectivos, al menos de forma similar a la que se reporta en el propio artículo. La ausencia de esta información provoca que la replicación de los resultados a otras bases de datos tenga escasa o ninguna probabilidad de éxito.

## 1.4.- Publicaciones

La presente tesis ha sido realizada mediante la modalidad de presentación de tesis doctorales con un conjunto de publicaciones, recogida en la normativa de la Universidad Miguel Hernández de Elche. En dicha normativa se indica que la tesis debe incorporar una introducción general donde se presenten los trabajos y un resumen global de los resultados obtenidos y de las conclusiones finales, así como un anexo con los trabajos publicados en su idioma original. En cumplimiento de dicha normativa, las publicaciones que conforman esta tesis se han incorporado en el Anexo II de la presente memoria. A continuación se proporciona una descripción general de dichos trabajos y en los próximos capítulos se presentarán los resultados obtenidos así como las conclusiones finales. Se incluye también un resumen del siguiente trabajo de investigación, actualmente en proceso de publicación y cuya relevancia justifica su mención en esta tesis.

Las publicaciones detalladas a continuación presentan propuestas para la consecución de los dos objetivos de la tesis:

En primer lugar se plantea una primera propuesta de modelo de predicción basada en la capacidad de los mapas auto-organizados de clasificar y asociar conjuntos de datos. Se trata de una técnica ya empleada para la clasificación de datos pero cuya aplicación al propio proceso de predicción es innovadora.

La segunda publicación se dirige al problema estructural de la investigación de modelos de predicción en tanto que plantea un sistema de clasificación de bases de datos que permita asignarles unos valores cuantitativos de manera que bases de datos con valores similares sean predichas con precisiones similares por cada modelo. De este modo se permite conocer a priori si un método es aplicable a una base de datos en concreto o no.

Esa capacidad, que a primera vista puede no parecer relevante, resuelve lo que se ha valorado como una de las mayores dificultades para avanzar en el campo de la predicción de demanda de forma sostenida. La imposibilidad de comparar resultados de forma objetiva dificulta el trabajo colaborativo entre investigadores.

Por último, se incluye el trabajo más reciente realizado en colaboración con Red Eléctrica de España (REE) y que ha tenido como objetivo actualizar los modelos de predicción actualmente en marcha en el centro de operaciones del sistema eléctrico español. Esta colaboración surge de la necesidad de REE de mejorar dichos sistemas y de la experiencia demostrada en las publicaciones anteriores por el conjunto de autores de las mismas. Este trabajo aún no ha sido publicado pero su inclusión en esta tesis se justifica por la relevancia de los resultados y la validación que supone para el resto de resultados obtenidos



### **1.4.1.- Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study**

El uso de redes neuronales para la predicción de demanda eléctrica se ha estudiado de forma profusa en las últimas décadas. Sin embargo, el uso de los mapas auto-organizados de Kohonen (SOM) no ha sido explorado. Los SOM son un tipo de redes neuronales que se caracterizan por proporcionar una proyección de datos multidimensionales sobre una superficie bidimensional de manera que los puntos del espacio multidimensional similares, ocupan posiciones cercanas en el mapa. Esta características ya se ha utilizado en el proceso de predicción de demanda en la clasificación de tipos de días o de perfiles de demanda, sin embargo, nunca se había utilizado para emitir predicciones.

La aplicación de los SOM a la predicción se realiza a través de dos etapas. En la primera, el mapa se entrena con vectores de datos que contienen tanto los datos conocidos a la hora de realizar la predicción como los datos que se desean predecir. Una vez que el mapa ha sido entrenado, el SOM contendrá vectores similares en celdas contiguas. La segunda fase consiste en la asociación de nuevos datos con posiciones del mapa. Al presentarse un vector de datos incompleto (le falta la información desconocida) el mapa es capaz de encontrar la posición del mapa que mejor se ajusta y nos permite identificar el contenido de las celdas de esa posición. Las celdas del mapa contienen vectores completos por lo que podemos obtener la predicción del contenido de la celda de mejor ajuste.

El proceso de predicción empieza por el pre-procesamiento de los datos. Los datos que se incorporan al modelo propuesto y que constituyen el vector de datos que contiene cada celda del mapa son el perfil de demanda horario de 3 días (día a predecir, día previo y día de la semana anterior), tipo de día y diez variables meteorológicas. Estos datos han de someterse a un proceso de filtrado y de normalización para eliminar datos corruptos que puedan desvirtuar el proceso de entrenamiento y para evitar que una variable cobre mayor importancia únicamente porque se exprese en cifras más elevadas.

El sistema realiza una selección de variables para cada predicción. Esto significa que cada vez que se realiza una predicción se realiza un algoritmo de optimización que selecciona las variables que deben tenerse en cuenta para dicha predicción. Este proceso se basa en la asunción de que las variables que mejor habrían predicho los últimos 30 días son las que mejor predecirán el día siguiente. El algoritmo se basa en un proceso iterativo que se demuestra independiente del conjunto de variables elegido inicialmente.

Además de las variables, es necesario determinar cuál es el periodo previo cuyos datos se utilizarán para realizar el entrenamiento. El artículo propone que los vectores de datos cumplan tres condiciones:

- Emplear sólo los mismos días de la semana: Consiste en seleccionar para el entrenamiento días que coincidan en el día de la semana con el día que queremos predecir.



- Emplear sólo días de un periodo del año similar: Teniendo en cuenta la dependencia con la época del año (o con la temperatura) se plantea excluir a los días distantes en el calendario anual. En este sentido es necesario determinar cuántos años previos deben utilizarse y definir de forma precisa el periodo considerado similar.
- Descartar festivos y días anómalos: No solo se trata de no incluir a los días anómalos y los festivos sino también todos aquellos que tengan uno de estos días en el vector de datos, es decir, en el día anterior o la semana anterior.

Por último, la definición del modelo propuesto no es completa sin la configuración del propio SOM. En este tipo de redes es necesario definir el tamaño del mapa de salida (número de neuronas), la topología, la función de vecindad el algoritmo de entrenamiento, el método de inicialización y la duración del entrenamiento.

El modelo así definido se pone a prueba mediante la predicción de un periodo de 4 años (2006-2009) obteniéndose predicciones para cada día realizadas a las 9 de la mañana del día anterior. Además, se incluye una aplicación práctica al mercado eléctrico español en la que se realizan predicciones a las horas correspondientes para que puedan ser empleadas en el diseño de estrategias de oferta en la participación en el mercado eléctrico diario e intradiario.

#### **1.4.2. - *Short-term predictability of load series: characterization of load data bases***

En los últimos años se han publicado abundantes modelos de predicción basados en diferentes motores de predicción y aplicando diferentes técnicas de selección y tratamiento de datos. Sin embargo, esta dedicación de la comunidad científica no se ha trasladado en una mejora proporcional en los resultados de los modelos. El problema radica en la dificultad de comparar los resultados que promulgan cada uno de los autores ya que, aunque cuenten con un proceso de testeo de los modelos propuestos, dicho proceso es una aplicación a una base de datos de cuyas características generalmente no se conoce prácticamente nada.

Las bases de datos de demanda pueden presentar características de muy diferentes como la influencia de la temperatura o de los festivos o el contenido de ruido blanco. Estas características afectan profundamente a su predictibilidad y hacen que el resultado de su predicción expresado simplemente como una medida de precisión tenga poco valor en sí mismo.

Para resolver este problema, se plantea el diseño de indicadores de predictibilidad que permitan añadir al dato de precisión de la predicción del modelo, las características de predictibilidad de la base de datos contextualizando así el primer dato. En concreto se proponen dos indicadores. El primero de ellos se basa en la composición espectral de la señal de demanda mientras que el segundo valora la influencia de la temperatura.

- Análisis frecuencial: el fundamento teórico del primer indicador se basa en la definición de una señal predecible como una suma finita de señales periódicas

mientras que una impredecible (ruido blanco) consiste en una suma infinita de señales periódicas. Con estas definiciones en mente, podemos considerar que si extraemos unas frecuencias determinadas de una señal de demanda, podremos construir una señal predecible y, podremos considerar que, si la diferencia entre la señal predecible y la original es pequeña, entonces la señal podrá considerarse muy predecible mientras que si no lo es, entonces será poco predecible.

La construcción del indicador requiere por tanto la definición del proceso de extracción de la señal predecible y de la medida de similitud entre la señal predecible y la original. En esencia, se trata de filtrar las frecuencias asociadas con comportamientos conocidos (frecuencias diarias, semanales y estacionales) y comparar las señales a través de un indicador como el promedio del error porcentual en valor absoluto (MAPE).

- **Influencia de la temperatura:** La temperatura influye sobre la demanda de diferentes maneras y es difícil distinguir por completo este efecto sin que esté contaminado por la hora del día o el día de la semana. Para diseñar un indicador similar al anterior, es necesario generar una señal predecible que incluya la temperatura como parámetro. El artículo describe como se obtiene un valor demanda para cualquier día en función del día de la semana, la hora del día y la temperatura.

De nuevo, el funcionamiento del indicador se basa en la obvia predictibilidad de la señal derivada y la similitud entre dicha señal y la original, utilizando como medida de similitud el MAPE.

Aplicando las técnicas anteriores se puede obtener dos valores cuantitativos que valoran la predictibilidad de la señal de demanda en base a dos factores (componentes periódicas de la propia señal y temperatura) muy comunes, sin embargo, la metodología empleada en el diseño del segundo indicador puede reaplicarse para evaluar la influencia de otras variables.

Para comprobar la validez de los indicadores se analizan 15 bases de datos diferentes del noreste de Estados Unidos y se comparan los indicadores definidos junto con otros métodos publicados para identificar si son capaces de predecir el error de predicción de las diferentes bases de datos al aplicar un mismo modelo de predicción a cada una de ellas.

#### ***1.4.3.- New online load forecasting tool for the Spanish national system operator***

El tercero de los trabajos de investigación se encuentra, en el momento de la elaboración de este documento en proceso de revisión. Como resultado de las publicaciones anteriores, el operador del sistema eléctrico español, Red Eléctrica de España (REE) se pone en contacto con los autores para establecer una colaboración que permita mejorar los resultados de predicción del sistema en ese momento en funcionamiento en su centro de operaciones.

En concreto, el principal aspecto de mejora que se identifica es la mejora de las predicciones en los días en los que los errores son más altos, por encima de mejorar el promedio general. Este tipo de días se caracterizan como días fríos o cálidos, festivos nacionales y fechas cercanas y días de cambio de hora. El sistema además debe realizar predicciones de forma horaria para el día en curso y los 9 días siguientes, tanto para la demanda agregada del territorio peninsular, como para 18 regiones en las que el operador tiene dividido dicho territorio.

El proceso de diseño comienza por analizar los datos disponibles y establecer los métodos de filtrado de datos corruptos y de normalización adecuados para introducir los datos en el sistema. A continuación, es necesario seguir un proceso de selección de datos que permita seleccionar cuales son las variables más relevantes que deben ser tenidas en cuenta en los modelos de predicción de cada una de las zonas. Las variables que se han tenido en cuenta son humedad, presión y temperatura de 59 estaciones meteorológicas en toda España. Además se ha tenido en cuenta la influencia dinámica de la temperatura, es decir, que no solo es la temperatura actual la que puede influir en la demanda eléctrica sino también la de los días pasados. Por tanto, para cada zona será necesario determinar cuáles son las estaciones meteorológicas que se consideran y además cuántos días pasados se tienen en cuenta.

La temperatura demostró ser la única variable con una relación significativa con la demanda, por lo que se descartaron el resto. En cualquier caso, debido a la relación no lineal entre demanda y temperatura, es necesario procesar los datos de temperatura para linealizarlos.

Como parte del proyecto se valoró la posibilidad de incluir una descomposición por wavelets de la serie de datos de demanda. Para ello, se partió de los modelos ya planteados en [17] y se realizaron las simulaciones correspondientes. Sin embargo, fue imposible obtener resultados similares a los reportados en dicho artículo ya que el tratamiento de bordes no está descrito y ocupa un puesto fundamental en el proceso de aplicación de la técnica de wavelets. De hecho, una investigación más profunda sobre el tema muestra que únicamente un autor [23] trata el problema de la distorsión de los bordes y muestra la dificultad de la aplicación de wavelets a la predicción de demanda con éxito. En estas condiciones, sólo se puede considerar el uso de wavelets como una técnica para refinar predicciones ya realizadas, sin embargo ni siquiera este tipo de aplicación mejoró los resultados obtenidos.

Como motores de predicción se plantean tres opciones:

- Modelo autorregresivo con realimentación del error: Se trata de un modelo AR con variables exógenas.
- Modelo de red neuronal autorregresiva: Se trata de una red neuronal en la que se realimenta la salida para obtener predicciones multipaso.
- Modelo SOM: Es un modelo de predicción basado en el primero de los artículos pero adaptado a cada una de las zonas.

Cada una de las técnicas obtiene buenos resultados dependiendo de la zona pero el modelo SOM obtiene resultados ligeramente inferiores con un coste computacional elevado, motivo por el cual es descartado ya que en una herramienta online ralentizaría en exceso el funcionamiento general.

Por tanto, el sistema consiste en dos motores de predicción que se aplican a cada una de las 18 zonas y a la demanda agregada. El análisis de resultados se realiza sobre la predicción nacional y se centra en la predicción del día siguiente que se realiza a las 9 de la mañana. Para esta predicción, por tanto, contamos con 4 predictores:

- Modelo AR aplicado a la demanda nacional.
- Modelo NARX aplicado a la demanda nacional.
- Modelo AR aplicado cada zona y agregado después.
- Modelo NARX aplicado a cada zona y agregado después.

Es necesario diseñar un método que permita combinar estas predicciones ponderando la precisión de cada modelo. Para ello, se plantea un problema de optimización lineal que calcule los pesos óptimos de cada modelo para el periodo de los 30 días anteriores y emplee dichos pesos para combinar las predicciones del día actual.

Por último, también es necesario emitir una predicción probabilística que incluya los percentiles 10, 15, 50, 85 y 90. Para ello se ha dispuesto un sistema de cálculo basado en la distribución de los errores pasados.

El sistema ha funcionado durante 10 meses en las instalaciones de REE de forma favorable y compitiendo con los predictores que estaban ya operativos en su sistema. El artículo plantea la comparación intrínseca de los modelos existentes con el propuesto y además plantea los hipotéticos resultados de las combinaciones de los tres modelos existentes y de dos de esos modelos junto con el modelo propuesto.

## Capítulo 2

# Resultados

### Índice

---

<b>2.1</b>	<b>Introducción</b>	<b>14</b>
<b>2.2</b>	<i>Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study</i>	<b>14</b>
<b>2.3</b>	<i>Short-term predictability of load series: characterization of load data bases</i>	<b>21</b>
<b>2.4</b>	<i>New online load forecasting tool for the Spanish national system operator</i>	<b>26</b>
<b>2.5</b>	<b>Resumen</b>	<b>33</b>

## 2.1. - Introducción

Los resultados obtenidos a lo largo de esta investigación se agrupan en dos bloques asociados a cada uno de los objetivos iniciales de la tesis: el diseño de modelos de predicción capaces de mejorar los niveles de precisión actuales y el establecimiento de medidas de predictibilidad estándares para las bases de datos de demanda.

En este capítulo se presentarán los resultados relacionados con cada una de las publicaciones incluidas. En el primer apartado se presentarán los resultados de un nuevo modelo innovador basado en el uso de las redes neuronales SOM como motor de predicción de demanda. En segundo lugar, se incluyen los resultados de utilizar dos indicadores de predictibilidad propuestos a un conjunto de bases de datos para comprobar hasta qué punto es posible conocer la precisión de los modelos al aplicarse a una base de datos concreta antes de realmente realizar la predicción. Por último, presentamos los resultados de una aplicación real diseñada durante la investigación y puesta en funcionamiento en las instalaciones del operador eléctrico de España (REE) para la predicción del sistema tanto nacional peninsular como regional.

## 2.2. - *Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study*

Los resultados de la aplicación del modelo basado en SOM descrito en el capítulo anterior que se presentan no se limitan al resultado de un modelo final ya definido, sino que pretenden guiar al lector durante el proceso de diseño para entender cómo y en base a qué parámetros se tomaron las decisiones de diseño que definen el modelo tal y como se ha publicado.

Los resultados finales se corresponden a un periodo de pruebas comprendido entre 2006 y 2009. Para obtener el modelo, se han realizado validaciones de los parámetros de diseño utilizando como periodo de validación el año 2005. Por último el conjunto de datos original utilizado para realizar el entrenamiento de los modelos corresponde al periodo que discurre entre 2000 y 2004.

a) Resultados de la selección de variables de entrada:

Tal y cómo se describe en el resumen del capítulo 1, los resultados de esta etapa deben confirmar las dos suposiciones planteadas:

- En primer lugar debemos demostrar que la selección de variables como entradas del modelo afecta en gran medida a los resultados de precisión y que no es aceptable un modelo en el que simplemente se vuelque la mayor cantidad de información posible. Además, es interesante comprobar si dicho conjunto de variables es constante a lo largo del día e incluso a lo largo del año.

- En segundo lugar, es necesario aportar pruebas de que efectivamente el conjunto de variables que produce la mejor predicción de los últimos 30 días son, al menos, buenos candidatos para producir la mejor predicción posible. Además es interesante comprobar que el algoritmo de optimización planteado es convergente independientemente del conjunto de variables iniciales que se considere.

La figura 1 contiene la información de qué grupos de variables se han considerado óptimos para cada uno de los 6 periodos de 4 horas considerados:

	INPUT VARIABLES										METEOROLOGICAL	
	ELECTRICAL LOAD											
	WEEK BEFORE					DAY BEFORE						
6 am - 9 am												NONE
10 am - 1 pm												NONE
2 pm - 5 pm												AVG. TEMP
6 pm - 9 pm												AVG. TEMP
10 pm - 1 am												NONE
2 am - 5 am												NONE

Fig.1 Agrupaciones de variables para predecir cada uno de los periodos del día.

Los aspectos interesantes a considerar de la figura 1 son que efectivamente se definen diferentes grupos de variables para cada uno de los periodos del día. Además, esta agrupación presenta cierta coherencia en sí misma ya que periodos adyacentes entre sí presentan variables similares incluidas en su conjunto óptimo. En cualquier caso, para validar la primera de las hipótesis es necesario incluir también la figura 2, en la que se detalla el resultado de predicción de cada periodo para cada uno de los grupos que se han considerado óptimos para alguno de los periodos. En la figura se observan dos fenómenos: en primer lugar podemos observar cómo efectivamente la selección de variables puede significar una variación del error de predicción significativa; además, podemos concluir que la utilización de un conjunto diferente para cada periodo proporciona un aumento de la precisión considerable.

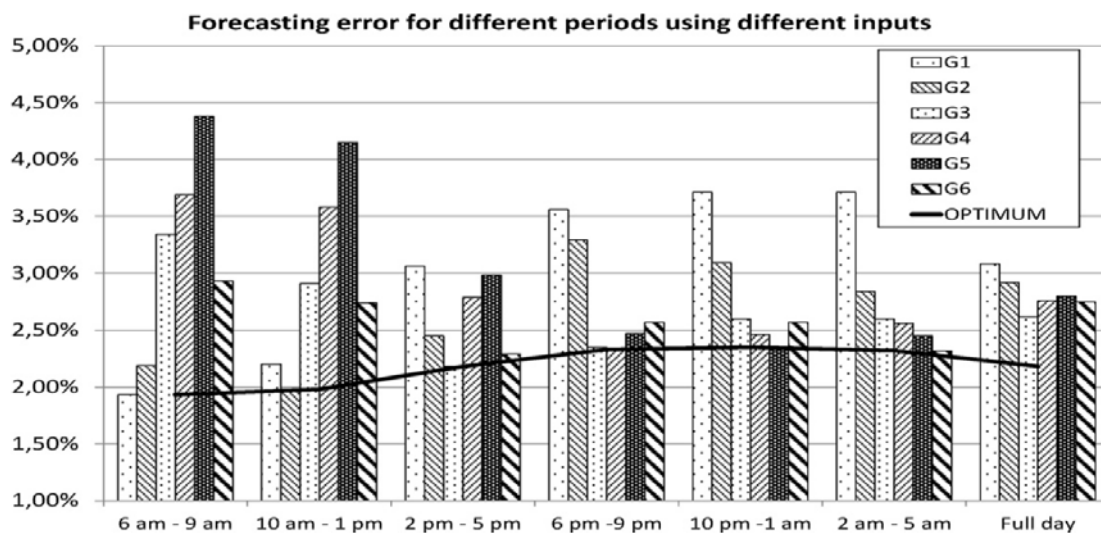


Fig. 2 Resultado de predicción de las agrupaciones óptimas de variables para cada uno de los periodos.



El resultado de la investigación también presenta que aunque sí existe una variación del conjunto de variables óptimas a lo largo del día, esto no es así a lo largo del año.

Para validar la segunda de las hipótesis necesitamos mostrar que existe correlación entre el error que consigue un conjunto de variables durante los últimos 30 días y el que consigue para el día siguiente. Dicha correlación se muestra en la figura 3. Finalmente, comprobamos que el algoritmo de optimización es convergente poniéndolo a prueba a partir de 4 conjuntos aleatorios de variables y obteniendo el mismo resultado final en un máximo de 11 iteraciones como se observa en la figura 4:




Fig. 3 Error de predicción de los últimos 30 días en función del error del día de predicción.




Fig. 4 Error de predicción en cada una de las iteraciones del proceso de optimización de variables para 4 puntos de inicio diferentes.



## b) Selección del periodo de entrenamiento:

Para determinar el patrón de días de cada año que deben seleccionarse para cada año se utilizó un método de prueba y error para comprobar el efecto de ampliar el número de días “próximos” y de incrementar el número de años pasados considerados. La figura 5 muestra los diferentes experimentos llevados a cabo y que justifican el diseño final de tener en cuenta 2 años y un periodo de 30 días por delante y por detrás del día de predicción.

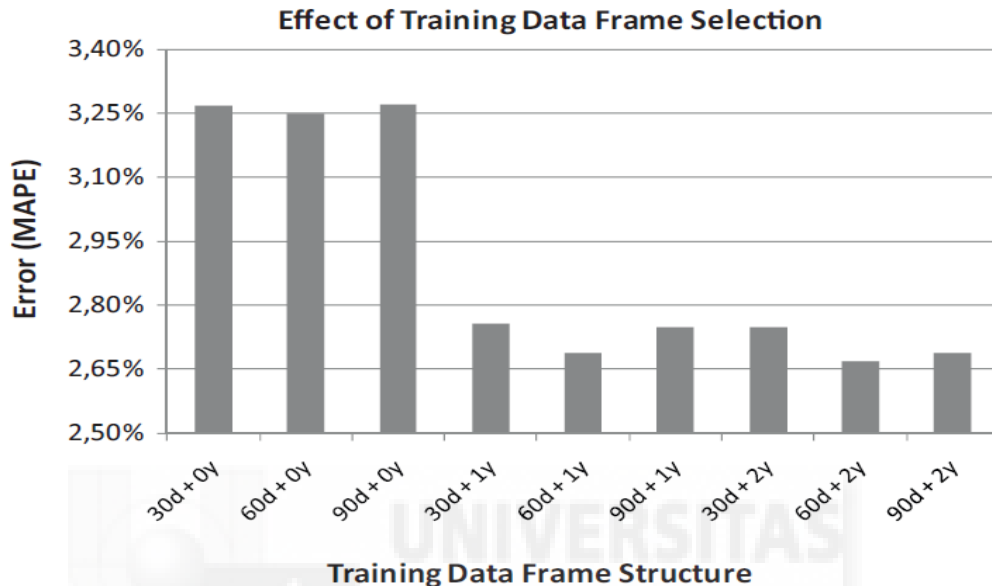


Fig. 5 Resultado de predicción en función del periodo de entrenamiento empleado.

## c) La última característica fundamental en el diseño del modelo basado en SOM es la que afecta a la arquitectura de la propia red y los parámetros de entrenamiento. En general se testearon todos los parámetros relacionados con la topología y las funciones de vecindad de la red SOM: redes cilíndricas o toroidales, con celdas hexagonales o rectangulares, vecindad gaussiana o rectangular... sin embargo, ninguno de estos parámetros supuso un cambio relevante en la precisión o en la funcionalidad del modelo.

La característica que sí demostró estar relacionada con la capacidad del modelo de captar las relaciones no lineales entre las variables de entrada y la demanda y, por tanto, ser capaz de predecir de forma más precisa fue el tamaño del mapa. Desafortunadamente, el aumento del tamaño del mapa tiene una contrapartida relevante en las aplicaciones reales ya que el tiempo de ejecución crece de forma exponencial con el tamaño. Por tanto, es necesario alcanzar una solución de compromiso. La figura 6 muestra el efecto que el tamaño del mapa tiene en los dos resultados considerados (precisión y tiempo de ejecución) y justifica en sí misma la elección de un mapa de 10 x 10 neuronas:




Fig. 6 Resultado de predicción y tiempo de ejecución en función del tamaño de mapa.

d) Resultados globales:

Finalmente podemos describir la precisión del modelo ajustado de acuerdo a los resultados expresados en los apartados anteriores. Es interesante comprobar no sólo los resultados de la predicción en términos generales sino entender cómo se distribuye dicho error en función del tipo de día (figura 7) o en los diferentes años en los que se testeó el modelo (figura 8):

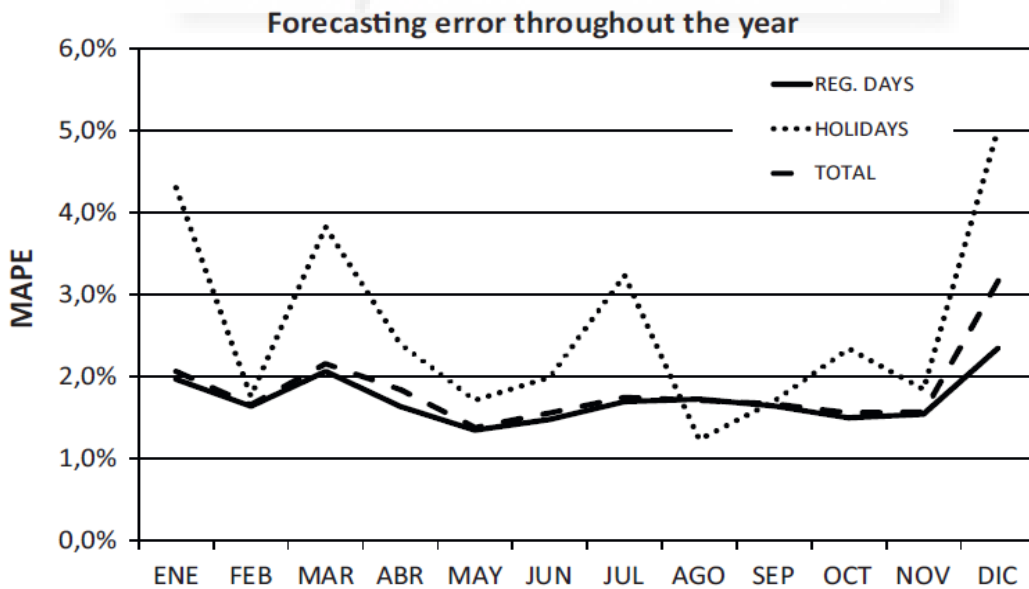


Fig. 7 Resultado de predicción a lo largo del año.




Fig. 8 Resultado de predicción final agrupado por años.

Los resultados de la figura 7 son los esperables asumiendo que los resultados de los festivos y días especiales serán mucho peores que los de los días normales. De la figura 8, sin embargo, se observa un comportamiento interesante que merece la pena explorarse con mayor detenimiento.

Se puede observar como el resultado de los años 2006 y 2007 es bastante similar entre sí y más preciso que el de los años 2008 y 2009. Esto podría interpretarse como una pérdida de validez del modelo a medida que nos alejamos del momento inicial pero hemos de recordar que el modelo diseñado se actualiza continuamente por lo que no debería observarse dicho comportamiento. Un análisis más en profundidad muestra una característica específica que aparece a partir del año 2008.

Al realizar un análisis frecuencial de la señal de demanda se identifica, como no podía ser de otra forma, una serie de periodos (diario, semanal,...) con una potencia asignada mucho mayor que la del resto de frecuencias. Se trata de una cuantificación del carácter periódico de la señal de demanda.

En ese sentido, podemos intuir que cuanto mayor sea la potencia localizada en frecuencias cuyo carácter periódico está recogido en la mayoría de modelos de predicción, más precisos serán dichos modelos al predecir tales señales, ya que el resto de señales, que podríamos considerar ruido, son menos relevantes que la señal predecible.

La figura 9 muestra un análisis frecuencial de la señal de demanda por años desde 2004, cuantificando el porcentaje de la potencia total de la señal que se asigna a los periodos de un día, medio día, una semana y media semana:

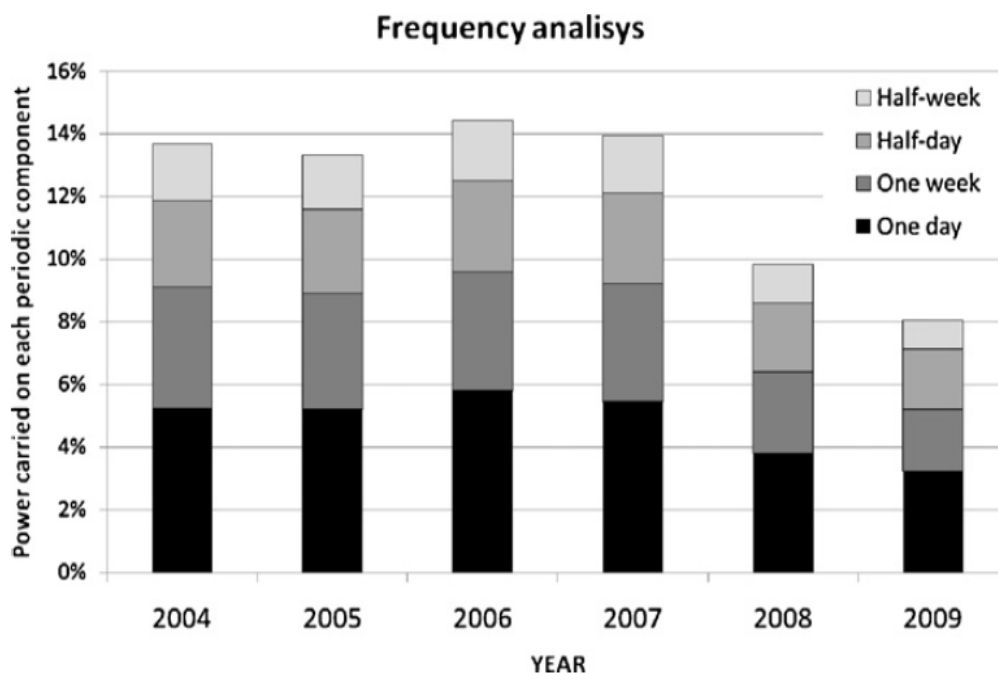


Fig. 9 Potencia de la señal en las frecuencias diaria y semanal

En la figura 9 se puede observar cómo los años 2008 y 2009 reducen la potencia asignada a las frecuencias predecibles de forma considerable, proporcionando así una explicación a la menor precisión con la que el modelo predice estos años.

Este hallazgo es de extraordinaria relevancia ya que proporciona una base cuantitativa para la elaboración de indicadores de predictibilidad que permitan contextualizar los resultados de predicción de diferentes modelos al aplicarse a diferentes bases de datos. Este concepto es la base de la segunda publicación aportada en esta tesis.

e) Aplicación al mercado eléctrico:

Como resultado complementario, se muestra el comportamiento del modelo cuando se somete a las restricciones del mercado eléctrico español realizando las predicciones de manera que coincidan con el momento de realizar las ofertas al mercado diario e intradiario. Estos resultados se muestran en la tabla 1.

TABLA 1:  
Resultados de la aplicación del modelo SOM al mercado eléctrico español

SESIÓN	DIARIO	INTRADIARIO					
		1	2	3	4	5	6
MAPE (%)	2.32	2.20	2.08	2.05	2.05	1.98	1.84

Los resultados son coherentes con otros resultados reportados en la bibliografía del artículo aunque, como ya se resaltado, resulta complicado comprender la calidad de un resultado de predicción sin conocer los pormenores de la base de datos.

### 2.3. - *Short-term predictability of load series: characterization of load data bases*

Al igual que en el apartado anterior, esta sección de resultados no sólo pretende aportar los resultados finales sino que se entiende como una guía para entender el proceso de diseño y las decisiones que se han tomado en su desarrollo.

Los resultados servirán como justificación de nuevo de las hipótesis planteadas en el resumen del artículo:

- Las señales de demanda se pueden descomponer en una señal predecible compuesta por un número limitado de frecuencias y una señal impredecible compuesta por un número infinito de frecuencias (ruido blanco).
- La diferencia entre las señales predecibles y las originales puede emplearse como indicador de la dificultad de predecir dicha serie de datos, es decir, como estimador de predictibilidad.

Para comprobar la primera hipótesis se plantea la elaboración de un filtro que separe la señal extrayendo algunas frecuencias cuya relevancia se debe a factores conocidos. El filtro consiste en una función gaussiana centrada en cada una de las frecuencias que se quieren extraer y cuyo ancho de banda está definido por un parámetro  $s$  que debe ser ajustado empíricamente y que se muestra en la figura 10. El efecto de un valor para  $s$  excesivamente grande es que el filtro arrastra muchas frecuencias además de las consideradas relevantes, poniendo en duda la definición de predecible para la señal filtrada. Si el parámetro  $s$  es demasiado pequeño no se estará extrayendo toda la información predecible de la señal original y, por tanto, no tendrá la condición de impredecible.

Por tanto, para obtener un valor óptimo de  $s$  deberíamos identificar el valor a partir del cual, aunque aumente la diferencia con la señal original (se disminuye el número de señales que pasan el filtro) esto no se traduce en una mejora de la precisión al realizar la predicción (no aumenta la predictibilidad). Es decir, determinamos que si al excluir más señales la predictibilidad no mejora es porque las señales que quedan son predecibles. Esto queda ilustrado en la figura 11, en la que se muestra los resultados de predicción de señales filtradas en función de la diferencia de dichas señales con la señal completa. En principio, al aumentar la diferencia (nos movemos por el eje X) el error de predicción va disminuyendo (estamos filtrando ruido). Sin embargo, observamos como en todas las señales se llega a un punto a partir del cual, aunque se incremente la diferencia, el error de predicción no disminuye.

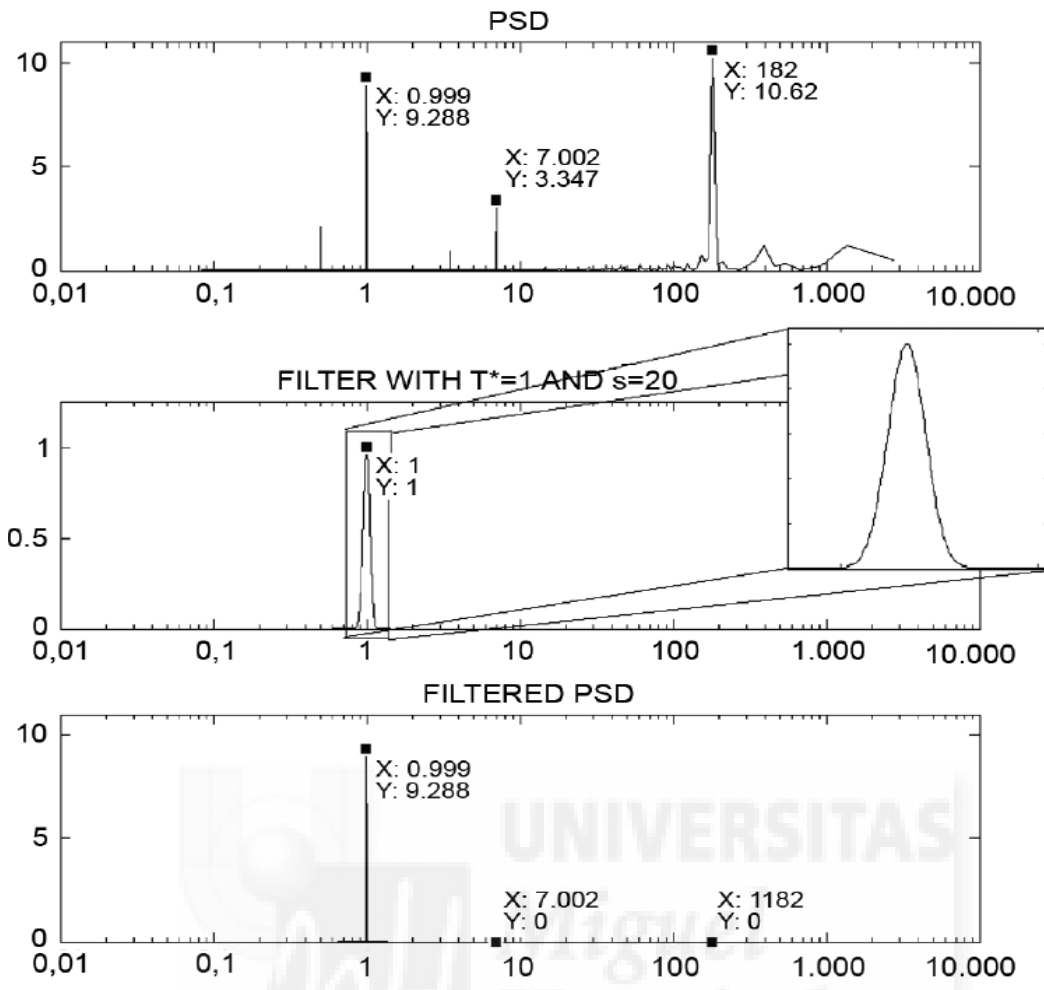


Fig. 10 Configuración del filtro gaussiano empleado para extraer las señales predecibles.

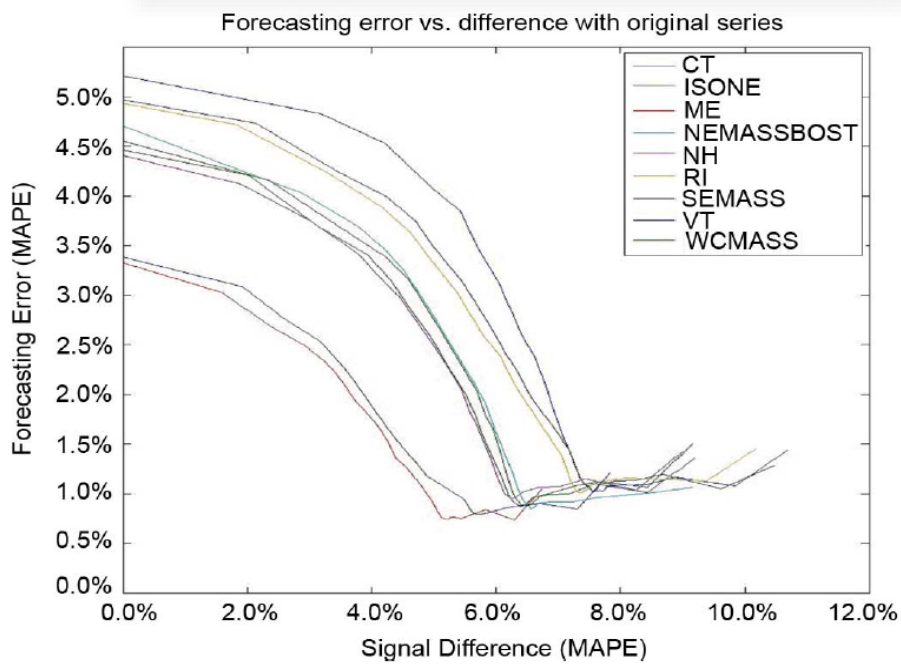


Fig. 11 Error de predicción de cada señal filtrada en función de la diferencia con la señal original.

El valor óptimo teórico de  $s$  se corresponde con el punto descrito en el párrafo anterior. El problema a la hora de determinarlo es que no podemos hacer uso de valores de predicción si queremos determinar la predictibilidad a priori. Por tanto, necesitamos un método alternativo que nos permite estimar dicho valor óptimo. Para ello podemos hacer uso de otro fenómeno interesante que visualizamos en la figura 12 al expresar la diferencia entre señales filtradas en función del parámetro  $s$ . En dicha figura podemos comprobar cómo la diferencia aumenta rápidamente al principio hasta un cierto valor de  $s$  a partir del cual la curva presenta una pendiente mucho menos pronunciada. Al analizar la relación entre el valor umbral de  $s$  descrito en este párrafo y el valor óptimo teórico de  $s$  observamos que son equivalentes con una  $R^2$  de 0.9970. Por tanto, podemos utilizar el valor de  $s$ , que llamaremos  $s^*$ , como sustituto del valor óptimo.

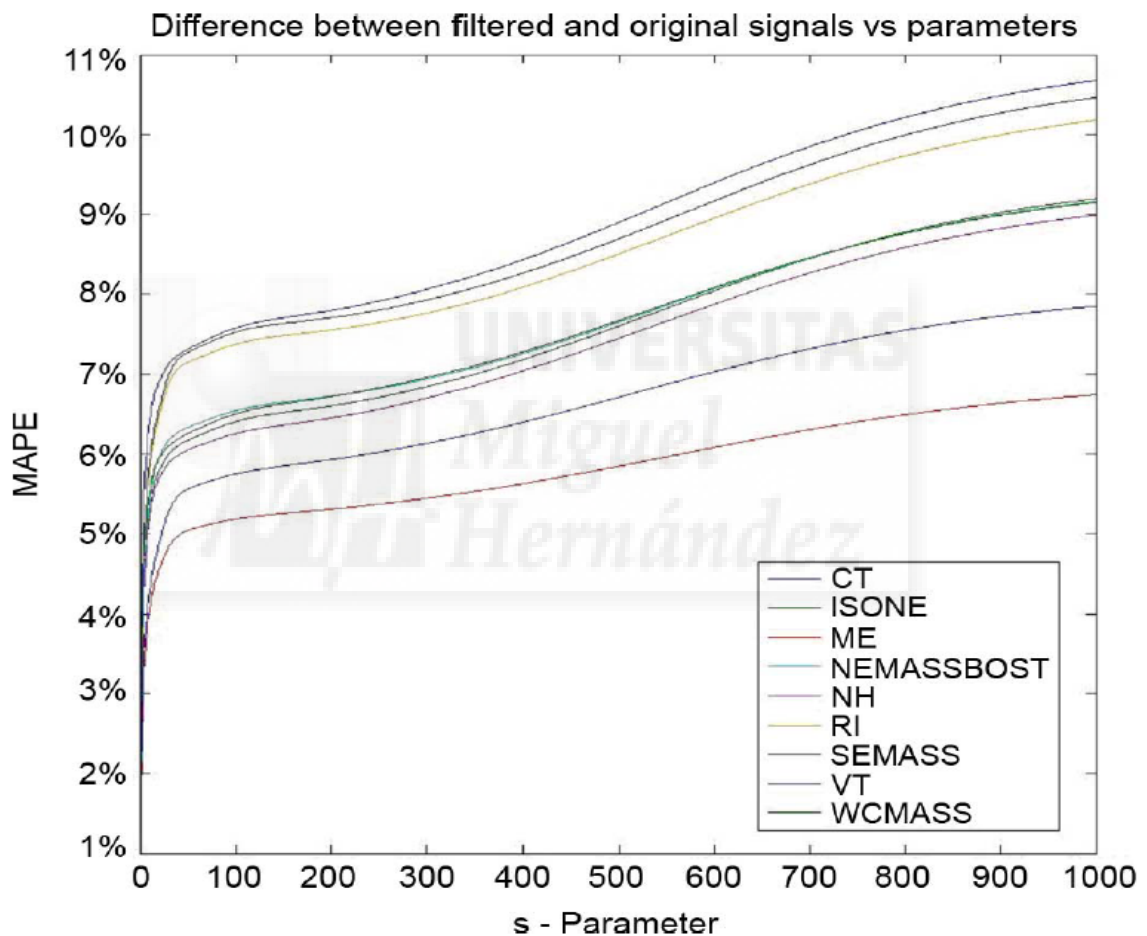


Fig. 12 Diferencia de la señal filtrada con la señal original en función del valor de  $s$ .

Este valor, junto con los centros de las gaussianas definidos en la tabla 2, define por completo el filtro que separa la señal impredecible de la predecible, demostrando así la primera hipótesis:

TABLA 2  
Periodos de las componentes más relevantes de la señal de demanda

	PATRÓN DIARIO			PATRÓN SEMANAL						PATRON ESTACIONAL		
<b>T</b> (días)	1/3	1/2	1	7/6	7/5	7/4	7/3	7/2	7	365/3	365/2	365

No es necesario esta demostración para el caso en que se descompone la señal en función de una variable exógena y variables temporales ya que, por definición, si la señal derivada es función únicamente de parámetros conocidos es totalmente predecible.

Sin embargo, sí es necesario comprobar que, una vez que tenemos ambas señales y hemos calculado la diferencia con la señal original en términos de MAPE, entonces dichos valores son estimadores válidos del error de predicción que se obtendrán con el modelo. Además, para validar los indicadores propuestos, se han valorado otros indicadores descritos en la bibliografía del artículo.

Para valorar la calidad de cada uno de los indicadores se incluyen en la tabla 3 los resultados de predicción de todas las bases de datos y los valores de todos los indicadores analizados:

TABLA 3  
Error de predicción y valores de los diferentes indicadores de predictibilidad empleados

DATABASE	Error (%)	D(*) (%)	$\eta_k$	$\eta_D$	$\eta_1$	$\eta_2$
<b>CT</b>	5.2	7.5	0.221	0.118	0.910	0.700
<b>ISONE</b>	4.5	6.3	0.300	0.164	0.927	0.729
<b>ME</b>	3.3	5.2	0.285	0.155	0.937	0.750
<b>NEMASSBOS</b>	4.7	6.5	0.171	0.907	0.883	0.657
<b>NH</b>	4.4	6.1	0.268	0.145	0.925	0.727
<b>RI</b>	4.9	7.3	0.228	0.122	0.911	0.702
<b>SEMASS</b>	5.0	7.5	0.293	0.160	0.927	0.730
<b>VT</b>	3.4	5.7	0.232	0.124	0.935	0.745
<b>WCMAS</b>	4.6	6.5	0.339	0.188	0.919	0.715



Los resultados muestran que los indicadores  $\eta_1$  y  $\eta_2$  presentan correlación despreciable con el error de predicción. En la tabla 4 se incluyen los resultados de correlación del resto de indicadores y se puede comprobar que el indicador propuesto  $D(s^*)$  es el que presenta mejores resultados:

TABLA 4  
Parámetros de correlación entre la el error de predicción y los principales indicadores de predictibilidad

Parametros de correlación	$D(s^*)$	$\eta_k$	$\eta_D$
<b>R<sup>2</sup></b>	0.8665	0.357	0.401
<b>SSE</b>	4.78E-5	2.30E-4	2.14E-4
<b>StdError</b>	0.0026	0.006	0.006
<b>95 Conf. interval</b>	0.57%	1.21%	1.18%

Los resultados de predicción empleados hasta ahora son producto de una predicción en la que no se han tenido en cuenta las variables meteorológicas. Para comprobar la validez del segundo indicador incluimos en la tabla 5 los resultados de los indicadores propuestos:

TABLA 5  
Error de predicción con temperatura y valores de los indicadores propuestos de predictibilidad y su interacción

DATA BASE	Error (con tempertura, %)	$D(s^*)$	$E_t$	$D(s^*)x E_t$
<b>CT</b>	3.9	7.5	4.2	0.3
<b>ISONE</b>	3.2	6.3	3.1	0.2
<b>ME</b>	3.2	5.2	3.5	0.2
<b>NEMASSBOS</b>	3.5	6.5	3.3	0.2
<b>NH</b>	3.4	6.1	3.7	0.2
<b>RI</b>	3.8	7.3	3.6	0.3
<b>SEMASS</b>	3.8	7.5	3.9	0.3
<b>VT</b>	2.8	5.7	3.3	0.2
<b>WCMASS</b>	3.5	6.5	3.6	0.2

A partir de los datos anteriores puede elaborarse la tabla 6, que muestra los índices de correlación entre el error de predicción y el uso de uno sólo de los indicadores o de los dos conjuntamente:

TABLA 6  
Parámetros de correlación entre el error de predicción con temperatura y los indicadores propuestos de predictibilidad

<b>Parámetros de ajuste</b>	<b><math>D(s^*)</math></b>	<b><math>D(s^*) + E_t</math></b>
<b><math>R^2</math></b>	0.7679	0.8935
<b>SSE</b>	2.33E-5	1.07E-4
<b>stdError</b>	0.0017	0.0011

A partir de los datos anteriores, podemos comprobar cómo el índice de correlación entre el error de predicción empleando la temperatura y un indicador resultado de una combinación lineal de los indicadores propuestos es elevado, 0.8935, y es superior al de utilizar únicamente el indicador frecuencial.

Además, el resultado muestra, como era de esperar, que el indicador frecuencial está más correlacionado con el error de la predicción que no utiliza la temperatura que con el error de la predicción que sí la utiliza.

#### 2.4. - *New online load forecasting tool for the Spanish national system operator*

En este trabajo se comunica el diseño de una aplicación real de un sistema de predicción para el operador del sistema eléctrico español (REE). La validez del diseño detallado en el artículo se demuestra en sí misma por el intenso banco de pruebas al que ha estado sometido durante un periodo de pruebas ligeramente inferior a un año en el que ha estado resultando proporcionando resultados de predicción en las mismas condiciones que los predictores actualmente funcionando en las oficinas centrales de REE.

Por tanto, en este apartado se detallarán los resultados finales de dicho banco de pruebas por considerarlos mucho más definitorios de la calidad del modelo que el propio proceso teórico de diseño.

a) Resultado de los modelos propios:

El sistema propuesto cuenta con dos modelos de predicción para cada una de las zonas, lo que significa que para la predicción nacional se cuenta con cuatro predicciones (2 propias y 2 agregadas).

Los datos de las zonas presentan un elevado número de anomalías que, en gran parte, han sido filtradas por el sistema para el periodo de entrenamiento y para realizar la predicción. Sin embargo, la base de datos definitiva siempre mantiene los datos salvo que se modifiquen a mano por un operador, por lo que al calcular el error de predicción compara el valor predicho con el real, aunque éste presente anomalías. Las anomalías son más frecuentes en las bases de datos de menor volumen por lo que los resultados expresados en la tabla 7 y la figura 13 son coherentes:

TABLA 7

Error de predicción de los modelos individuales y combinados. Peso de cada uno de los modelos en la combinación optimizada de referencia.

REGIÓN	AR	NN	TOTAL	DEMANDA (MW)	%AR	%NN	OPT
'CATALU'	3,46%	3,79%	2,72%	5338	64%	36%	3,2%
'MADRID'	3,59%	5,44%	3,17%	3362	93%	7%	3,6%
'VALENC'	4,03%	4,61%	3,10%	3016	63%	37%	3,6%
'ANDOCC'	4,88%	4,88%	3,70%	2534	52%	48%	4,3%
'ANDORI'	7,37%	8,95%	6,21%	1901	100%	0%	7,4%
'C_LEON'	10,40%	5,43%	5,00%	1839	14%	86%	5,2%
'PVASCO'	6,01%	5,97%	5,19%	1799	48%	52%	5,4%
'GALI_N'	13,42%	6,93%	5,70%	1452	0%	100%	6,9%
'ARAGO'	5,91%	5,71%	4,01%	1223	41%	59%	5,5%
'MANORI'	6,32%	5,15%	4,81%	1205	22%	78%	5,0%
'MURCIA'	18,71%	12,78%	7,90%	971	0%	100%	12,8%
'MANOCC'	6,21%	5,99%	4,53%	723	46%	54%	5,2%
'GALI_S'	6,09%	6,80%	5,75%	717	68%	32%	5,9%
'MANORI'	29,48%	17,83%	13,01%	639	0%	100%	17,8%
'EXTREM'	11,20%	7,85%	7,13%	603	16%	84%	7,7%
'CANTAB'	33,76%	11,17%	9,64%	480	0%	100%	11,2%
'NAVARR'	19,28%	12,70%	7,88%	452	0%	100%	12,7%
'RIOJA'	15,34%	13,45%	11,70%	203	31%	69%	13,0%

La tabla 7 muestra los resultados de predecir cada zona mediante los dos modelos diferentes y la combinación lineal de ambos que el sistema elabora como predicción final. Se puede comprobar que la predicción final es mejor que cualquiera de las dos predicciones en todos los casos. Además, se ha incluido una predicción de referencia resultado de realizar una optimización lineal a todo el intervalo a posteriori. De este modo, podemos comparar la combinación que el sistema realiza de las dos predicciones con la que el mejor combinador podría hacer para todo el periodo una vez conocidos los resultados. De nuevo podemos comprobar cómo el resultado también es mejor, por lo que el sistema dinámico de combinación queda perfectamente validado.

Como resultados a destacar puede observarse que en algunas bases de datos la combinación óptima asigna un valor de 0 a alguna de las dos predicciones. Salvo en el caso de Andalucía oriental, en el que ambas predicciones son siempre muy similares, en el resto de casos se pondera únicamente la predicción elaborada por el modelo basado en redes neuronales. Esto sucede en bases de datos con muchas anomalías, y sucede porque el sistema neuronal se adapta mucho mejor a estas anomalías que el auto-regresivo. A continuación, comprobaremos el efecto que esto puede tener en las predicciones globales.




Fig. 13 Error de predicción de los modelos individuales y combinados y volumen de demanda horaria.

La predicción más relevante para las operaciones de REE es la predicción agregada nacional. Los resultados de esta predicción se exponen en la tabla 8, mostrando las predicciones de cada uno de los predictores, así como la combinación de los mismos realizada por el sistema y la combinación optimizada siguiendo los parámetros anteriormente descritos:

TABLA 8

Error de predicción de los modelos individuales nacionales y su combinación. Peso de cada uno de los modelos en la combinación optimizada de referencia.

	AR	NN	AR (agreg.)	NN (agreg.)	TOTAL	OPTIMIZADO
<b>MAPE (%)</b>	3,33%	2,50%	1,97%	2,69%	1,56%	1,65%
<b>Pesos (OPT)</b>	13%	22%	58%	7%		N/A

De nuevo podemos comprobar cómo la predicción combinada realizada por el sistema supera las cuatro predicciones individuales y también la optimización de referencia. Sin embargo, un aspecto destacable es que la mejor predicción es la predicción agregada hecha por el método auto-regresivo,

superando la agregada basada en redes neuronales pese a que ésta obtenía mejores resultados en casi todas las zonas. La explicación de este fenómeno es que, mientras que cada una de las anomalías provoca un gran error en la predicción AR de cada zona, la agregación de todas las zonas elimina las anomalías y los errores cometidos por el modelo AR por dichas anomalías se compensan.

b) Contextualización de los resultados: modelos de REE:

Como ya hemos demostrado en la sección anterior, los resultados de predicción no tienen gran valor sin que se establezca un marco comparativo relevante. En este caso, contamos con los datos facilitados por REE de las predicciones realizadas por tres predictores actualmente en funcionamiento en sus instalaciones. La tabla 9 muestra el resultado de estos predictores junto con el predictor propuesto. Además, se incluyen tres referencias calculadas como combinaciones optimizadas a todo el periodo:

- Referencia A: Optimización de los 3 modelos de REE.
- Referencia B: Optimización de los 4 modelos.
- Referencia C: Optimización de los dos mejores modelos de REE y el modelo propuesto.

De este modo, podemos cuantificar, al menos de forma relativa, la mejora que la inclusión de nuestro sistema podría aportar a las predicciones finales del operador.

TABLA 9

Error de predicción de los modelos actuales, modelo propuesto y combinaciones de referencia. Peso de cada uno de los modelos en la combinación optimizada.

	RMSE	MAPE	Weights (A)	Weights (B)	Weights (C)
<b>Forec. 1</b>	1,68%	1,43%	0,27	0,17	0,21
<b>Forec. 2</b>	2,06%	1,77%	0,2	0,1	N/A
<b>Forec. 3</b>	1,59%	1,35%	0,53	0,45	0,47
<b>Proposed</b>	1,83%	1,56%	N/A	0,28	0,32
<b>Opt'd. ref (A)</b>	1,46%	1,24%	N/A		
<b>Opt'd. ref (B)</b>	1,39%	1,18%			
<b>Opt'd. ref (C)</b>	1,40%	1,19%			

En primer lugar, se observa en los datos de la tabla 8 que el modelo propuesto es el tercer mejor modelo, por detrás de los predictores 1 y 3 de REE. Este resultado es en sí positivo, ya que ya supondría una mejora en los resultados. Sin embargo, merece la pena explorar en mayor profundidad los resultados.

Pese a que la medida de precisión de un modelo es claramente la mejor manera de estimar su calidad, cuando consideramos modelos que se combinan es necesario tener en cuenta la correlación que puede existir entre ellos. De este modo, dos modelos con una correlación elevada podrían combinarse para obtener un error que se situase entre los errores conseguidos por cada uno, sin mejorar entonces las predicciones del mejor de ellos. Sin embargo, un tercer modelo con baja correlación con los primeros puede obtenerse al combinarse un error más bajo que cualquiera de los dos individualmente.

Éste último es el fenómeno que se produce en nuestro caso. El modelo propuesto presenta una correlación respecto de los modelos de REE mucho menor que la que tienen entre ellos, por lo que al incluirlo entre los candidatos para una combinación, en realidad obtiene el segundo peso más importante. Por tanto, podríamos considerar el modelo propuesto como el segundo más importante en el nuevo mix de predictores disponibles.

c) Resultados por tipo de día:

La colaboración con REE se origina por la necesidad de REE de mejorar sus resultados de predicción especialmente en los días en los que los resultados son peores. Estos días se identifican con los días de temperaturas extremas, los festivos, los días adyacentes a festivos y los periodos vacacionales. Los modelos están centrados en la mejora de estos resultados e intentan captar toda la información posible que modele los comportamientos anómalos de este tipo de días. A continuación se presentan en la tabla 10 los datos de predicción agrupados por tipos de días para comprobar cuál es el resultado del sistema propuesto en los días complicados:

**TABLA 10**  
Error de predicción de los modelos actuales, modelo propuesto y combinaciones de referencia en los días de difícil predicción

		Cold	Hot	Nat'l holidays	Long weekends	First & last week of year	Passover weeks	Total difficult days	Rest	# days w/ RMSE > 4%
<b># of days</b>		10	10	7	3	14	15	59	256	N/A
<b>Forecaster 1</b>	RMSE	2,13%	2,22%	3,59%	2,55%	3,29%	1,62%	2,30%	1,57%	8
	MAPE	1,75%	1,87%	2,99%	2,19%	2,76%	1,33%	1,91%	1,34%	
<b>Forecaster 2</b>	RMSE	2,13%	1,68%	4,48%	6,11%	4,70%	2,68%	3,08%	1,88%	24
	MAPE	1,81%	1,42%	3,75%	5,67%	4,27%	2,20%	2,67%	1,61%	
<b>Forecaster 3</b>	RMSE	1,86%	2,14%	3,53%	1,92%	2,79%	1,65%	2,18%	1,48%	8
	MAPE	1,57%	1,79%	2,96%	1,56%	2,40%	1,35%	1,83%	1,26%	
<b>Proposed</b>	RMSE	1,71%	2,03%	2,62%	1,68%	2,61%	2,01%	2,16%	1,75%	7
	MAPE	1,43%	1,69%	2,27%	1,40%	2,22%	1,57%	1,78%	1,49%	
<b>Optimized reference (A)</b>	RMSE	1,80%	1,67%	3,29%	2,57%	2,78%	1,40%	2,01%	1,36%	5
	MAPE	1,51%	1,36%	2,73%	2,14%	2,38%	1,16%	1,69%	1,16%	
<b>Optimized reference (C)</b>	RMSE	1,57%	1,69%	2,37%	1,54%	2,09%	1,24%	1,70%	1,34%	4
	MAPE	1,28%	1,40%	2,01%	1,35%	1,84%	1,01%	1,43%	1,15%	

Los resultados mostrados en la tabla 9 muestran que el modelo propuesto es el mejor salvo en Semana Santa y días cálidos. Además, presenta los mejores resultados para el global de los 59 días difíciles como modelo individual y es el modelo con menor número de días con un error superior al 4%.

Al revisar las combinaciones de modelos se observa que al sustituir el modelo 2 por el modelo propuesto los resultados mejoran en todas las categorías salvo en la de días cálidos debido a que el modelo 2 obtiene resultados excelentes en esta categoría. El resultado de los 59 días difíciles mejora desde un 1.69% hasta un 1.43% e incluso el resultado de los días normales mejora ligeramente del 1.16% al 1.15%.

d) Resultados según la hora del día y el día de la semana:

Es importante también, a la hora de evaluar los resultados de un modelo de predicción comprobar que el error se distribuya de la manera más equilibrada posible y que los errores no se concentren a unas horas o en unos días

determinados. Es imposible conseguir una distribución totalmente equilibrada ya que unas horas o unos días son inherentemente más difíciles de predecir que otros. Sin embargo, las figuras 14 y 15 muestran cómo la inclusión del modelo propuesto en los sistemas de predicción de REE reduce el error en todas las horas y en todos los días sin empeorar la situación existente de ligeros desequilibrios hora a hora y día a día:

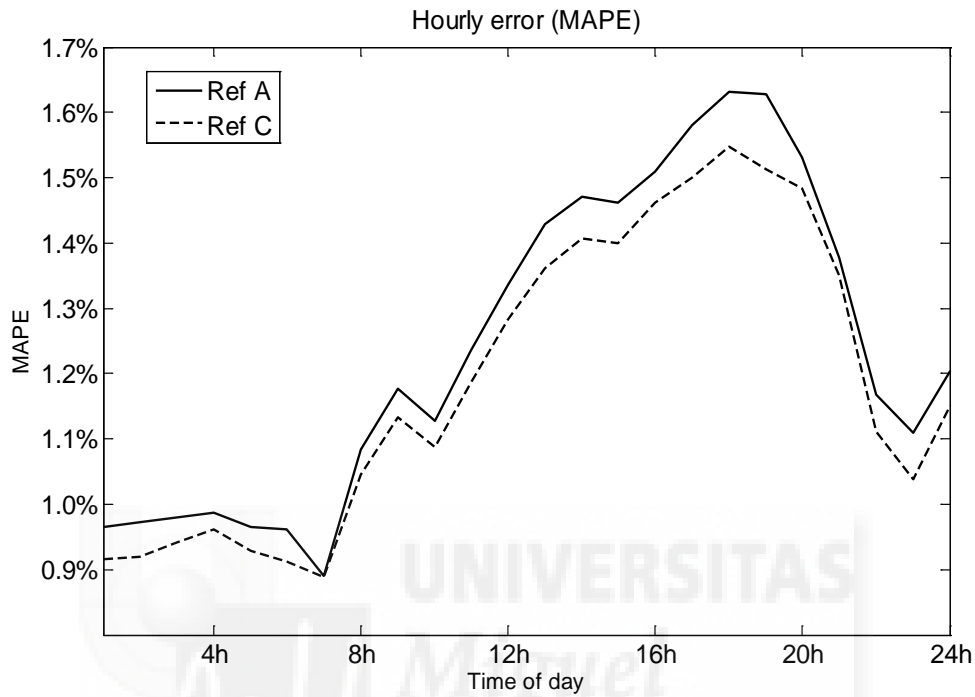


Fig. 14 Error de predicción en función de la hora del día.

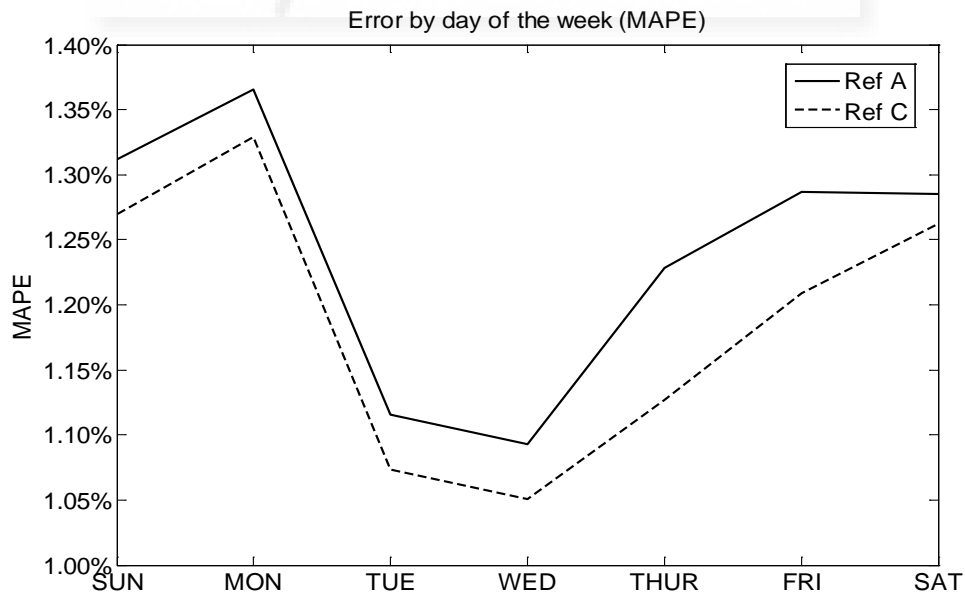


Fig. 15 Error de predicción en función del día de la semana.



## e) Error de predicción en función de la antelación:

La aplicación diseñada para el operador del sistema requiere que las predicciones se actualicen frecuentemente y que alcancen un horizonte de 9 días. Los resultados expresados en este resumen se refieren a las predicciones realizadas a las 9 de la mañana sobre el día siguiente. Obviamente, las predicciones realizadas con más antelación presentan mayor dificultad por la escasez de información disponible. En la figura 16 se ilustra la evolución de la precisión de las predicciones en función de la antelación con la que se han realizado. Se puede observar que la precisión de las predicciones varía desde un 1.32% si la predicción se realiza a las 23 horas del día anterior hasta un 2.56% si la predicción se realiza con una antelación de 9 días.




Fig. 16 Error de predicción en función de la antelación.

## 2.5. – Resumen

En los apartados anteriores se han detallado los resultados alcanzados durante el proceso de investigación. En primer lugar, se han aportado pruebas de que es posible la utilización de las redes neuronales SOM como motor de predicción de demanda. Los resultados obtenidos por el modelo propuesto son comparables a aquellos obtenidos por otras técnicas más populares y más estudiadas como las redes MLP o los modelos regresivos. Sin embargo, el elevado coste computacional dificulta su aplicación a situaciones reales.

La evaluación de los resultados de predicción conduce al segundo de los objetivos tratados en esta tesis. Se han propuesto dos indicadores de predictibilidad que, siendo

evaluados junto con otros indicadores propuestos en la bibliografía, proporcionan una correlación superior con el resultado de predicciones tanto utilizando temperatura como sin utilizarla.

Por último se ha presentado el resultado de una aplicación real de un sistema de predictores para el sistema eléctrico español. Se ha demostrado el funcionamiento para cada una de las zonas y para el agregado nacional comprobando que tanto los modelos en sí mismos como el sistema de combinación propuestos permiten mejorar los resultados de predicción actuales del operador nacional del sistema eléctrico.



## Capítulo 3

# Conclusiones

### Índice

<b>3.1</b>	<b>Conclusiones</b>	<b>36</b>
<b>3.2</b>	<b>Trabajo futuro</b>	<b>38</b>
<b>3.3</b>	<b>Otras publicaciones</b>	<b>39</b>

### 3.1. - Conclusiones

En esta tesis se ha tratado el problema de la predicción de demanda a corto plazo, tanto desde el punto de vista del investigador y la necesidad de establecer parámetros que permitan establecer líneas base de comparación como desde el punto de vista de los participantes del sistema y su necesidad de obtener modelos precisos, puntuales y robustos.

El principal reto a superar en el primer caso es la dificultad de comparar los resultados de predicción de una base de datos con los de otra y aislar el efecto que cada uno de los pasos del proceso de predicción tiene en el resultado final. Se trata de un problema que lastra el proceso de investigación porque dificulta el traspaso de conocimiento y la reaplicación de técnicas válidas a nuevos modelos. Para superar este reto, es posible establecer parámetros que cuantifiquen las características de las bases de datos a las que se aplican los modelos de manera que se contextualicen los resultados y se conozca a priori en qué tipo de bases de datos puede esperarse unos resultados similares a los publicados. Además, este paso es necesario para superar la segunda parte de este reto: una vez que las bases de datos pueden caracterizarse, es posible determinar qué aspectos o técnicas empleadas en cada modelo están especialmente diseñados para qué características específicas.

Las dos propuestas de indicadores de predictibilidad avanzan en esta dirección, permitiendo cuantificar en el primer caso, la predictibilidad de la serie en base a su periodicidad conocida. Es decir, permite identificar si la señal de demanda es predecible por tener un patrón de repetición elevado respecto al nivel de ruido causado por otros fenómenos. Para estos otros fenómenos se ha diseñado un segundo indicador que permite cuantificar la predictibilidad de la serie en base a la influencia que ejerce sobre ella una variable exógena, que en el caso estudiado ha sido la temperatura. Es decir, permite identificar si la señal es predecible por tener una influencia elevada de una variable externa conocida.

Los resultados han demostrado que puede establecerse una correlación elevada ( $R^2 > 0.85$ ) entre los valores de estos indicadores y el error de predicción que un modelo de predicción que incluye la temperatura comete al aplicarse a un conjunto de bases de datos del noreste americano. Esta correlación valida los indicadores, ya que podemos concluir que las bases de datos con valores similares en los indicadores obtendrán valores de predicción similares.

Es necesario desarrollar este tipo de indicadores y aplicarlo a más bases de datos, más modelos y más variables para disponer de las herramientas necesarias que, como visión a largo plazo, permitirán poder clasificar la base de datos en función de su vector de características, pero las bases de diseño ya han sido establecidas en esta tesis.

El modelo de predicción presentado basado en redes SOM cumple un doble propósito en cuanto a lo que los objetivos de la tesis se refiere. Obviamente proporciona el diseño y los resultados que justifican el uso de una nueva técnica y las conclusiones en

este sentido serán presentadas en breve, pero también se ha desarrollado siguiendo un modelo totalmente modular y aislando cada una de las técnicas aplicadas de modo que pueda comprobarse la aportación de cada una al resultado final. Este tipo de estándar modular de modelo de predicción sería una gran aportación para promover el trabajo colaborativo y la reaplicación de los trabajos de investigación publicados.

Los resultados del modelo de predicción basado en SOM son comparables a los de la mayoría de modelos publicados y detallados en la bibliografía. Sin embargo, como hemos venido detallando, los resultados de predicción sobre diferentes bases de datos no son una referencia válida. En cualquier caso, el mismo modelo se puso a prueba junto con el sistema de predicción que se instala en REE y los datos obtenidos por él son también aceptables en términos de precisión.

El uso de las redes SOM como motor de predicción no resulta intuitivo y es posible que suponga una sobrecarga computacional para conseguir resultados que sistemas más sencillos serían capaces de obtener. Sin embargo, la aplicación de los SOM al proceso de predicción en forma de un proceso de clasificación y posterior asociación de datos es innovadora, obtiene resultados aceptables y es posible que, en sistemas menos intensivos computacionalmente tenga un campo de aplicación, por lo que los resultados aportados son relevantes para posteriores desarrollos.

Finalmente, los resultados más relevantes se han obtenido para el desarrollo de una herramienta que funcione en tiempo real y sea capaz de producir predicciones dentro de un entorno comercial como es el operador del sistema eléctrico español.

Existen numerosas dificultades en el desarrollo de este tipo de modelos, como la escasa confiabilidad de los datos, los requisitos de velocidad de ejecución o el desarrollo de predicciones tan frecuentes. Para conseguir una herramienta capaz de proporcionar datos en los formatos correctos y con contenidos que supongan una creación de valor es necesario resolver puntualmente todas estas dificultades.

Los sistemas de tratamiento de datos deben ser robustos tanto a la ausencia de datos como a la presencia de datos absurdos o corruptos. En ocasiones es difícil establecer una frontera que distinga entre el dato absurdo y el factible por lo que en cualquier caso debe poder responderse de forma automática a la incidencia pero debe mantenerse la integridad de la base de datos para que sea un operador humano el que determine los errores de cara a futuros usos de la base de datos. Además, es necesario que los sistemas generen alertas de fallos repetitivos para que se activen los agentes necesarios para su resolución.

Los procesos computacionales deben optimizarse al máximo y debe cuestionarse cualquier decisión de diseño que incremente la carga computacional para mantener el equilibrio entre la precisión y el tiempo de respuesta. Nunca debe sacrificarse lo primero por lo segundo pero se ha de ser riguroso a la hora de establecer y evaluar los criterios que determinan una mejora de precisión.

El uso de la información más reciente es fundamental para poder responder adecuadamente y a tiempo con predicciones que se actualizan cada hora. También es necesario discriminar entre la información reciente que es relevante para el horizonte de uno o dos días pero que en realidad no modifica las predicciones de más largo plazo y que únicamente incrementa el coste computacional.

Los resultados obtenidos demuestran que los dos modelos propuestos son capaces de generar valor al incorporarse como predictores en el sistema. De hecho, el propio sistema de combinación también ha proporcionado resultados de éxito al superar incluso a una combinación fija hecha a posteriori. Uno de los aspectos más interesantes es que en sistemas de predicción que integran diferentes modelos, la precisión de cada uno de ellos deja de ser tan relevante como la ausencia de correlación entre el error de cada uno de ellos de manera que la combinación de dos modelos que incurren en un error de predicción superior al de un tercer modelo puede ser incluso mejor que la de este tercer modelo. Por tanto, pese a que el coste computacional sea más elevado, en este caso quedan demostradas las ventajas del mestizaje de modelos cuyos errores, además, estarán menos correlacionados cuanto menos tengan en común sus diseños.

Por tanto, podemos dar por alcanzados los dos objetivos que nos planteábamos al inicio de esta tesis. Las propuestas de cara a la comunidad científica proporcionan una base para iniciar el camino hacia modelos de predicción comparables, modulares y reaplicables. Además, la puesta en funcionamiento en el que probablemente sea el modelo de predicción más importante del país con resultados positivos se considera el primer gran éxito de los integrantes del equipo de investigación.

### 3.2. – Trabajos futuros

Los excelentes resultados alcanzados por el Sistema propuesto para REE han condicionado los siguientes pasos del equipo de investigación de modo que actualmente iniciamos un proyecto encaminado a mejorar los resultados de predicción de los sistemas insulares y las ciudades autónomas.

Los retos que presentan este tipo de sistemas están relacionados con las características específicas de cada uno de ellos, ya que presentan una especificidad mayor que los de las regiones peninsulares.

Además, al tratarse de sistemas relativamente pequeños, existe la posibilidad de que clientes singulares de gran consumo puedan alterar en gran medida el total de la demanda, dificultando así el proceso de predicción si no existe flujo de información de los clientes hacia el sistema de predicción.

Las variables meteorológicas también tienen un peso específico mayor al tratarse de territorios más reducidos y el tipo de variables relevantes puede mostrar más variabilidad en las islas que en la península.

Por otro lado, también se plantea interesante el continuar el desarrollo de indicadores para clasificación de las bases de datos y la cuantificación de la aportación de las diferentes etapas de un modelo modular de predicción.

### 3.3. – Otras publicaciones

A continuación, se enumeran otras publicaciones en las que ha participado el autor, generalmente como primer autor, relacionadas con los temas tratados en esta tesis:

- Lopez, M.; Valero, S.; Senabre, C.; Gabaldon, A., "Short-term load forecasting: Revising how good we actually are," in *Power and Energy Society General Meeting, 2012 IEEE*, vol., no., pp.1-6, 22-26 July 2012  
doi: 10.1109/PESGM.2012.6345392
- Lopez, M.; Valero, S.; Senabre, C.; Aparicio, J.; Gabaldon, A., "Development of a model for short-term load forecasting with neural networks and its application to the electrical Spanish market," in *Energy Market (EEM), 2011 8th International Conference on the European*, vol., no., pp.321-326, 25-27 May 2011  
doi: 10.1109/EEM.2011.5953031
- Lopez, M.; Valero, S.; Senabre, C.; Aparicio, J., "A SOM neural network approach to load forecasting. Meteorological and time frame influence," in *Power Engineering, Energy and Electrical Drives (POWERENG), 2011 International Conference on*, vol., no., pp.1-5, 11-13 May 2011  
doi: 10.1109/PowerEng.2011.6036553
- Lopez, M.; Valero, S.; Senabre, C.; Aparicio, J.; Gabaldon, A., "Standardization of short-term load forecasting models," in *European Energy Market (EEM), 2012 9th International Conference on the*, vol., no., pp.1-7, 10-12 May 2012  
doi: 10.1109/EEM.2012.6254733
- Valero, S.; Senabre, C.; López, M.; Aparicio, J.; Gabaldón, A.; Ortiz, M., "Comparison of Electric Load Forecasting between Using SOM and MLP Neural Network," in *Journal of Energy & Power Engineering*; Vol. 6 Issue 3, p411 March 2012





Anexo 1

# Artículos



En cumplimiento de la normativa de la Universidad Miguel Hernández de Elche, en las siguientes páginas se recogen el conjunto de trabajos publicados.

- **"Short-Term Predictability of Load Series: Characterization of Load Data Bases"**

López García, M.; Valero, S.; Senabre, C.; Gabaldón Marin, A.  
*IEEE Transactions on Power Systems*  
Volume 28. Issue 3. Pages: 2466-2474, Aug. 2013  
doi: 10.1109/TPWRS.2013.2250317

- **"Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study"**

López García, M.; Valero, S.; Senabre, C.; Aparicio, J., Gabaldón Marin, A.  
Electric Power Systems Research  
Volume 91. Pages 18-27. Oct 2012. ISSN 0378-7796  
doi: 10.1016/j.epsr.2012.04.009

A continuación se especifica la clasificación de las revistas donde se han publicado los artículos, dentro del índice *Journal Citation Reports* de 2015.

***IEEE Transactions on Power Systems***

Impact Factor: 2.814

Category Name: ENGINEERING, ELECTRICAL & ELECTRONIC

Total Journals in Category: 249

Journal Rank in Category: 26

Quartile in Category: Q1

***Electric Power Systems Research***

Impact Factor: 1.749

Category Name: ENGINEERING, ELECTRICAL & ELECTRONIC

Total Journals in Category: 249

Journal Rank in Category: 83

Quartile in Category: Q2

---

En cumplimiento de la normativa se indica la afiliación de los coautores de los artículos presentados en esta tesis.

Departamento de Ingeniería Mecánica y Energía de la Universidad Miguel Hernández de Elche, situada en la Avda. de la Universidad s/n, 03202, Elche, España.

- Miguel López García

[m.lopezg@umh.es](mailto:m.lopezg@umh.es)

- Sergio Valero Verdú

[svalero@umh.es](mailto:svalero@umh.es)

- Carolina Senabre Blanes

[csenabre@umh.es](mailto:csenabre@umh.es)

Departamento de Estadística, Matemáticas e Informática de la Universidad Miguel Hernández de Elche, situada en la Avda. de la Universidad s/n, 03202, Elche, España.

- Juan Aparicio Baeza


[j.aparicio@umh.es](mailto:j.aparicio@umh.es)

Departamento de Ingeniería Eléctrica de la Universidad Politécnica de Cartagena, situada en Campus Muralla del Mar s/n, 30202, Cartagena, España.

- Antonio Gabaldón Marín

[antonio.gabaldon@upct.es](mailto:antonio.gabaldon@upct.es)





## Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study

M. López<sup>a</sup>, S. Valero<sup>a,\*</sup>, C. Senabre<sup>a</sup>, J. Aparicio<sup>b</sup>, A. Gabaldon<sup>c</sup>

<sup>a</sup> Dpto. Ingeniería de Sistemas Industriales, Universidad Miguel Hernández de Elche (UMH), Área de Ing. Eléctrica, Avd. de la Universidad s/n, 03202, Elche, Spain

<sup>b</sup> Centro de Investigación Operativa, Universidad Miguel Hernández de Elche (UMH), Avd. de la Universidad s/n, 03202, Elche, Spain

<sup>c</sup> Universidad Politécnica de Cartagena (UPCT), Spain

### ARTICLE INFO

#### Article history:

Received 23 May 2011

Received in revised form 6 February 2012

Accepted 14 April 2012

Available online 23 May 2012

#### Keywords:

Short-term load forecasting

Self-organizing maps

Neural network

Electrical market

### ABSTRACT

The use of neural networks in load forecasting has been a popular research topic over the last decade. However, the use of Kohonen's self-organizing maps (SOM) for this purpose remains yet mostly unexplored. This paper presents a forecasting model based on this particular type of neural network. The scope of this study is not only to prove that SOM neural networks can be effectively used in load forecasting but to provide a deep and thorough analysis of the prediction and a real-world application. The data used to assess the validity of the model corresponds to Spain energy consumption from 2001 to 2010. Also meteorological data from this period has been used. The analysis comprises the study of the significance of different meteorological variables, the relevance of these meteorological data when recent load values are used as input and the effect of using different patterns to select the days to train the map. In addition, the evaluation of the frequency components of the data has provided an explanation to why apparently similar data sets allow different forecasting performances of the model. In order to build an application to the Spanish electricity market, the model was adjusted to timely forecast a load profile for each session of the daily and intra-daily markets. These forecasts are intended as an input to a decision support system for any commercializing company bidding on the market.

© 2012 Elsevier B.V. All rights reserved.

### 1. Introduction

Short-term load forecasting is an essential tool for energy systems planning and operation [1,2] and, therefore, it has been a major area of research in the last decade. The importance of load forecasting has historically been related to production and operating costs and to ensure the permanent balance between electricity demand and its production. However, it is in current deregulating markets where forecast accuracy may become especially relevant. Liberalization of the market may reveal forecasting errors as the root of inefficient behavior of commercializing and distributing companies. This model is a complement to other techniques and methodologies such as customer clustering and classification that may assist commercializing agents when developing specific tariff programs [3,4]. In Sections 1.1 and 1.2 we will provide a brief review of different load forecasting techniques and their performance and also an overview of how SOM work and how they can be applied to load forecasting. In Section 2, the core of the forecasting model is described in its five stages: data

pre-processing, input selection, training data selection, forecasting engine and data post-processing. In Section 3 we will expose the results of the model, including not only forecasting accuracy but also the conclusions drawn from optimizing the parameters of the model.

As a special point of interest, Section 4 presents an application of the model to the Spanish electricity market. While most of the models mentioned in Section 1.1 only show an accuracy result of 24-hour forecasts, in this section we adapt the forecast in order for it to be used in a real application. We do this by taking into account the times in which the auctions are held to determine the available information at the time and also the horizon in each auction to provide with a forecast of the appropriate time span. Finally, Section 5 contains a brief summary of the highlights of the model and its application to the Spanish electricity market.

#### 1.1. History of load forecasting

The different techniques used for load forecasting range from the early statistical models [5–7] to complex artificial intelligence such as neural networks or fuzzy logic [8–18]. The latter have been extensively used in the last decade; however, statistical methods have not disappeared completely although they are mostly used combined with AI methods in hybrid models.

\* Corresponding author.

E-mail addresses: [lopezgarcia.m.81@gmail.com](mailto:lopezgarcia.m.81@gmail.com) (M. López), [svalero@umh.es](mailto:svalero@umh.es) (S. Valero).

**Table 1**  
Forecasting results of some methods using both classic statistical methods or artificial intelligence.

Comparative MAPE results for classic & AI methods		
Method	Type	Reported MAPE
ARIMA + Temp. transformation [6]	CL	1.43%
Wavelet fuzzy neural network [8]	AI	1.51%
ARIMA + Multiple regression [5]	CL	1.62%
Wavelet transform + Evolutionary algorithm [9]	AI	2.04%
Neuro fuzzy [8]	AI	2.83%
Adaptive neuro-fuzzy inference system [8]	AI	3.00%
ARIMA [7]	CL	3.73%
Wavelets + Particle swarm optimization [10]	AI	3.96%

The most important classical methods are the regression-based models and the time series models. These time series models use the hypothesis that future loads can be predicted from past values, being therefore modeled as an autoregressive process. The multivariate regression technique considers the load profile as a linear combination of explanatory variables (including weather factors). Coefficients for this linear combination are estimated by least squares fittings or modern regression techniques. The results obtained by these methods are shown in Table 1 and they are expressed using the mean average percentage error (MAPE) which is very common in the literature.

Neural networks are currently the most popular method to develop load forecasting tools. The multilayer perceptron (MLP) is the main structure used in these models although other techniques such as self-organizing maps or recurrent networks are also good candidates for promising results. Fuzzy logic and other types of artificial intelligence have been mentioned in recent literature too, especially as being part of hybrid methods. The results obtained using these methods are also shown in Table 1.

The variability of results is not only affected by the design of the forecasting model, but also by the qualities of the load data. The same method may be more or less accurate when applied to different data sets so the results should only be taken as an estimation of the model's forecasting capacity and not as a guaranteed result.

## 1.2. Working principles of forecasting SOM networks


The SOM acronym stands for self-organizing maps and it was first introduced by T. Kohonen [19]. SOM are a popular neural network based on unsupervised learning, which means that it is not necessary to provide the network with an expected output during the training period. Instead, the network is fed with sets of training data usually with the purpose of clustering or classifying them. In these uses, unsupervised training means that it is not necessary to specify to which cluster each data belongs but that the network will be able to determine how many clusters there are and how each data should be assigned to each cluster.

Forecasting is not an intuitive application of self-organizing maps such as the aforementioned clustering or classifying. However, SOM networks' ability to associate new data with similar previously learnt data can be applied to forecasting applications.

The core application of SOM is to simplify high-dimensional data into bi-dimensional spaces (maps) so that the way data spreads in the map is a representation of the characteristics of the original data. In this manner, similarities among the data that may have been difficult to identify are translated into topological proximity within the map.

A SOM architecture is based on neurons organized on a 2-dimensional grid, with a neighborhood relation which establishes the topology of the map. Usually, neurons are arranged in a hexagonal lattice spread over a sheet but other structures are possible like rectangular lattice spread over a cylinder or a toroid [20]. Each neuron is an  $n$ -dimensional vector where  $n$  is equal to the dimension of the input vector. Fig. 1 shows an example of forecasting the second half of a sinusoidal function. In the top left corner of Fig. 1 visualization of a SOM is provided showing its topology and the content of its cells. In this case, each neuron contains both the relevant information known at the forecasting time (the first half of the function) and the actual data to be forecasted (the second half).

At this point, we can consider the input space as an  $n$ -dimensional space in which each point is defined by the information needed for a forecast and the data to be forecasted and the SOM is a projection of this  $n$ -dimensional space in a



**Fig. 1.** The application of SOM to forecasting can be described in three steps: (1) *Training*. The cells of the map in the top left corner contain a linear combination of the vectors in the database. It is shown that the content of each cell does not resemble the content of its neighbors. After training, the map in the bottom left corner show how the cells are arranged so that each one is similar to its neighbors. Also, the whole input space is covered. (2) *Association*. The image in the top center shows a data vector. At the time of forecasting, only the known data is used as input to find the cell in the trained map that best matches it. (3) *Forecasting*. The information stored in the best matching cell is split into the part that was used to match the input and the part that is used to produce a forecast.

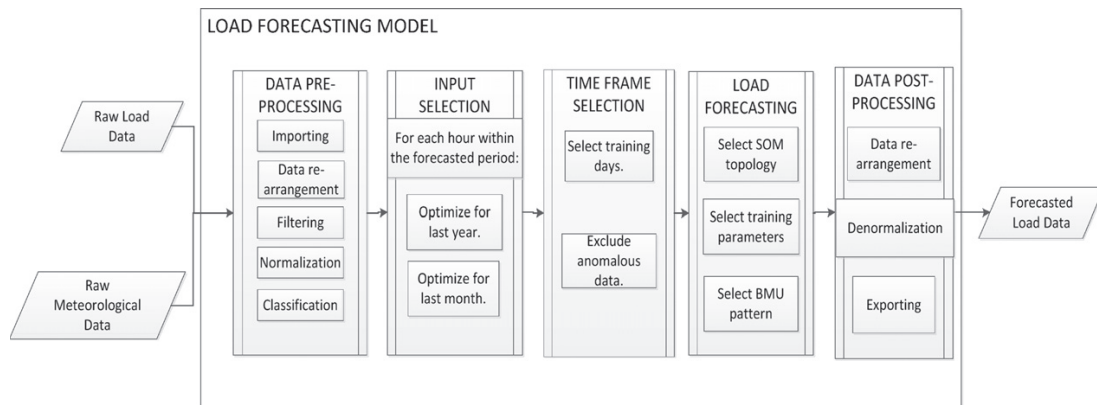


Fig. 2. Structure of the proposed forecasting model.

2-dimensional grid. The training process consists then of a series of calculation through which the SOM spreads throughout the input space, making sure that the entire “cloud” of training points has a projection on the SOM, in other words, every actual point appears on the map and similar points appear near to each other. In Fig. 1 the training process is illustrated.

A properly trained SOM can be used in forecasting assuming that there is a correlation between the data known at the forecasting time and the data to be forecasted. When attempting to realize a new forecast, an incomplete data vector, information to be forecasted is obviously missing, is presented to the map which is able to project the new vector into the map and return the best matching neuron in the grid. This neuron (and its neighbors) contains full data vector that may be used to fill the initial input vector and, therefore, provide with a valid forecast. The association and forecasting processes are shown in Fig. 1.

## 2. Database, tools and methods

For our study, both meteorological and electrical data were used. Electricity raw data used correspond to the hourly load profile for the whole of Spain, from 2001 to 2010 [21]. In addition, a set of 10 climate describing variables [22] has been used in order to determine which meteorological values are best suited to predict electricity consumption. The forecasting model is programmed using Matlab code and runs on an Intel Q8300 CPU. Approximate runtime for a 365 period is 6 min, which means it is capable of producing real-time forecasts. The input and output information is provided through Microsoft Office Excel worksheets with a pre-established format.

### 2.1. Structure of the forecasting model

The main structure of our forecasting model is described in Fig. 2. All the processes used during the forecast are organized in a five-stage generic model. The stages are: data pre-processing, input selection, time frame selection, load forecasting and data post-processing. The model is the result of several optimization processes and, while some of the optimized parameters remain constant regardless of time of day, time of the year or other factors, some other parameters, need to be dynamically optimized in order to obtain best results. This means, for example, that while the same SOM size or training algorithm can be used to forecast any period of time, the input variables need to be optimized for each forecast.

### 2.2. Data preprocessing

The objective of data pre-processing is to provide a valid data set in which all variables are normalized, all corrupted data is either reconstructed or at least identified and all data is classified. The output of this pre-processing block is a data matrix in which each row represents the information available from one day, see Fig. 3.

Input data are imported raw from external Excel sheets. The data are then rearranged so that each row contains the hourly load from 6 a.m. to 5 a.m. on the next day. This consideration is taken due to the fact that the load on the period from midnight to 6 a.m. is actually more influenced by the events on the previous day than by those to happen on its actual calendar date.

Filtering is intended to eliminate corrupted data. This is done by running a low-pass filter that eliminates sudden changes on the load (approximately more than 50% change on a 2-hour period).

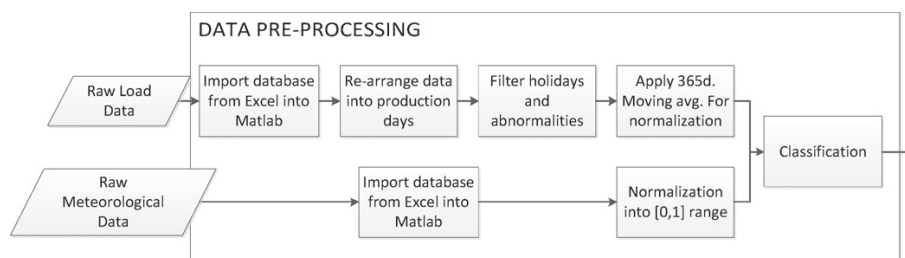


Fig. 3. Flow chart for the pre-processing stage.






Fig. 4. Normalization is needed to eliminate the economic growth trend. The normalization factor used is the 365 days moving average. The figure on the right shows a normalized and stationary series.

This filter identifies days with abnormalities so they are no longer used in the training phase.

Another significant factor concerning electric demand over extended periods of time is economic growth. When we attempt to forecast future load profiles based on data from previous years, we need to compensate this trend. A normalization factor is used in order to overcome this problem. This factor is obtained by averaging the hourly load of the 365 previous days. As it may be seen in Fig. 4, the normalization process eliminates annual trend.

Regarding meteorological data, ten different variables are initially included in the model: maximum, minimum and average day temperatures, wind speed, pressure, rain, visibility, cloudiness and humidity. These values were obtained from meteorological stations in the 52 provinces of Spain and then averaged. Then, they were normalized by dividing each value by the maximum in its category.

Finally, in order to classify the days, another filter is run to label the day of the week and whether each day is a holiday, an abnormal day or a regular day. Further in the process, each type of day will be forecasted using only days of its own type. Classification is also important to ensure that abnormal days or holidays are not used to forecast regular days.

To sum up, the final input to the model will be an 83 component vector including three 24-hour load profiles (forecasted day, previous day and week before day), type of day label and the 10 meteorological values associated with the forecasted day. From these 83 components, the type of day will be considered as a label of the data, while the remaining 82 variables are possible input to the model.

### 2.3. Input selection

Depending on the time of the year and the period of the day to be forecasted, these 82 variables may or may not be part of the optimal information in order to make an accurate forecast. Choosing the right variables to train the SOM for each forecast is probably the most important feature of the model and its dynamical implementation is, along with using SOM itself, at the core of this model's innovation. The input selection affects both meteorological and previous loads input and it is based on the following assumptions:

- The best input to forecast load may depend on the time of day to be forecasted, therefore we must allow our model to use different inputs to forecast different times of the day.

- The best input to forecast load may depend on the time of the year, therefore we must allow our model to use different inputs throughout the year.
- Even though the best input may vary depending on time of day and time of the year, forecast of similar periods must have similar input in order to avoid over-fitting.

The first two assumptions force the need to establish a way to find the best group of variables to train the SOM for each hour of each day. This implies that every time a forecast is made, a SOM model is built for each hour that the forecast lasts. The third assumption implies that a group of variable that has been successful forecasting recent loads is likely to be successful in the near future. Following this idea, a full load profile requires 24 models, one for each hour, for which the input is optimized based on the last 30 days. This is implemented in an algorithm described in the following steps:

- Step 1: Identify the group of variables used in the previous forecast (A-group).
- Step 2: Forecast last 30 days using the A-group.
- Step 3: Identify candidate variables (B-group) to be included in or to be excluded from the A-group. The first and last hours in the A-group from each day are candidates to be excluded. First and last hours not in the A-group are candidates to be included. Meteorological variables are always candidates.
- Step 4: Randomly select a variable (candidate) from the B-group and include/exclude it in/from the A-group. This forms the C-group.
- Step 5: Forecast last 30 days using the (C-group).
- Step 6: If forecast from step 5 is more accurate than last forecast made, then make the C-group the new A-group and eliminate the candidate from the B-group. If forecast from step 5 is less accurate than last forecast made, then eliminate the candidate from the B-group.
- Step 7: If B-group is not empty go to step 4. Finish otherwise.

The result of the application of the algorithm is a new group of variables which is a good solution to optimize the next forecast. In Section 3, the validity and the results of the algorithm and the conclusions to be drawn from them are exposed.

### 2.4. Time frame selection

Every time a forecast is made, it is necessary to determine which previous days should be used to train the SOM. The primary






Fig. 5. Typical differentiation of daily loads by day of the week and by season.

consideration for this purpose would be to choose a set of days with the same behavior as the one we are forecasting. To this end, the following conditions are required:

- Only the same type of weekdays since it is well established that the load profile is highly dependent on the weekday, see Fig. 5.
- Only days from a similar time of the year since there is also a different profile for winter than for summer days, see fig. 5.
- Exclude any holiday or any abnormal day from the training set: this means not only to exclude actual holidays but also to remove days that have holidays or abnormal days in their data vector (day or week before).

First and third conditions are very clear and are easily met by ruling out from the training data set any vector with a label of holiday or abnormal day. The second condition needs to establish a pattern in which only a number of days from each year is included in the training data set. In [18], such condition is met by considering the same date of the forecasting date in the current and past years and including the days within a given distance to this date. Three parameters define this pattern: the number of years to be used, the number of days from past years and the number of days from the current year. Current and past years are treated differently because the days from previous years are centered on the forecasting day and the days from current year are the immediately prior to it. The result of this experiment is exposed in Section 3.

2.5. Map architecture

There are several parameters to define a working SOM. First of all, it is needed to select the topology and the neighborhood function. This defines how the neurons are arranged and

which neurons are considered neighbors to each other. In our case, we choose hexagonal neurons set in a bi-dimensional sheet. A Gaussian function is used to define the vicinity of each cell. Another element regarding the topology is the size of the map, this is, how many neurons and how they should be arranged in rows and columns. In this case, several experiments were carried out with different size maps and, while increasing map size affected exponentially the computational burden, no significant improvement resulted of using maps bigger than  $10 \times 10$  neurons.

The training process is defined by initialization procedure, training algorithm and duration. The neurons were initialized with a linear combination of the actual data, as opposed to a random initialization in order to reduce convergence time. Also, the batch algorithm was used for speeding reasons over the sequential one. Again, two tests using random initialization and sequential training proved that the same result was achieved only with a significant delay. Regarding duration, the number of training epochs is selected on a trial and error basis. An excessive number of epochs may lead to over-fitting while a lack of training may affect accuracy. All the simulations were programmed using Matlab 2010a and the specific Matlab SOM Toolbox. See [20] for further references on the design of SOM networks.

3. Results

On the following subsections, the results of the different tests run in order to optimize the model are presented. Parameters regarding time frame selection and SOM architecture are selected using data from 2000 to 2004 as training set and 2005 as validation set. These parameters remain the same in forecasting the years 2006–2009. Input selection, as it was described uses data up to the previous day to optimize the input variables.

	INPUT VARIABLES										METEOROLOGICAL
	ELECTRICAL LOAD										
	WEEK BEFORE					DAY BEFORE					
6 am - 9 am											NONE
10 am - 1 pm											NONE
2 pm - 5 pm											AVG. TEMP
6 pm -9 pm											AVG. TEMP
10 pm -1 am											NONE
2 am -5 am											NONE

Fig. 6. Variables used in forecasting for each period appear colored. Notice how the variables used smoothly changes as the forecasted period advances.




Fig. 7. MAPE result when forecasting different periods of the day using the 6 group of variables shown in Fig. 8. The line represents the result of the group actually used in that particular period.

3.1. Results of input selection

In Section 2.3, three assumptions were declared as the basis of our input selection process. It is necessary for this work to be valid to assure that the obtained results actually validate these assumptions.

First of all, we need to demonstrate that different periods of day are best forecasted using different input variables. Fig. 6 shows the result of applying the algorithm to forecasting years 2006–2009. The optimum group of variables changes throughout the day without sudden changes, therefore validating our initial assumptions. For clarity reasons, the result is shown in periods of 4 hours while the actual process was realized one hour at a time, therefore we obtain 6 groups of variables each of them being the optimum group for one period of 4 hours.

In addition, in Fig. 7, the forecasting error of each period for the 6 groups of variables is shown. From this chart, it is proven that, while a group of variable may be the most accurate to forecast a period of the day, it may be far from the best when forecasting other periods.

Another interesting conclusion drawn from the application of this algorithm is that while temperature was not observed as relevant when forecasting a 24-hour period, it comes in useful when considering smaller parts of this period (evenings). Therefore, this algorithm allows us to use temperature to increase the accuracy of the model.

Another of our initial assumptions dealt with optimizing the input throughout the year. However, our test showed no significant change in the input pattern for a summer nor for a winter day. Therefore we can conclude that even though our model could detect a seasonal pattern when optimizing input, none is found.

Finally, in order to assess the validity of the algorithm, Fig. 8 shows that there is a significant correlation between the result of a given input for the last 30 days and the result if used for the next forecast. Fig. 9 shows the convergence of the algorithm for a random forecast. The initialization is made with four different seeds and all four converge to the same result within 11 iterations.

3.2. Time frame selection

The experiments to determine the optimum pattern of previous days to be used as training data for each forecast were carried out

using data from 2002 to 2005. To reduce the computational burden, only one group of input variables was used. Therefore, the result in absolute terms is not relevant but the relative accuracy of each of the patterns revealed the importance of selecting training data.

The results shown in Fig. 10 represent accuracy in terms of MAPE of several forecasts made using different patterns of training data. In all of them, only the same days of the week are used since this is well established in the literature. Holidays and abnormal days are also excluded. Nine tests were carried out, each of them using a different amount of previous years or a different number of days from them. Qualitatively speaking, the results prove necessary to use data from at least one previous year and that using 60 days from each previous year seems to be more accurate than 30 or 90. There is no sign that using data from more than two previous years may become counterproductive. Therefore, as a conclusion to be used in our actual testing (2006–2009), the pattern to select training days should be 60 days from all previous days available, centered in the forecasting day in the correspondent year.

ACCURACY FOR THE LAST 30 DAYS AND FORECAST DAY USING DIFFERENT INPUTS




Fig. 8. Each point represents a group of variables as input. Groups that obtain a low MAPE in the previous 30 days generally obtain similar results.

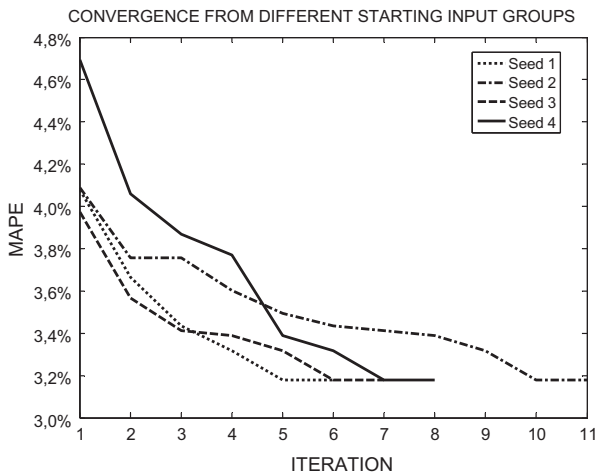


Fig. 9. Four different initialization groups are tested. All four converge to the same final group (same MAPE result) within 11 iterations.

3.3. Map architecture

As it was aforementioned, the design parameters of a SOM regard topology and training. Most of these parameters have general rules but no specific way to find optimal solutions so they are usually designed by trial and error method. Data from 2002 to 2005 was used to determine the optimal design.

In order to determine the topology of the map, cylindrical, toroidal and 2D sheet shapes were tested along with rectangular and hexagonal cells, but there was no difference in forecasting accuracy. Also, Gaussian, rectangular and bubble vicinity functions were used without any influence in the final result. In conclusion, 2-D sheet and hexagonal cells with a Gaussian vicinity function are used merely for simplicity reasons.

Size, however, did prove to have a large impact on forecasting accuracy. Fig. 11 shows the relation between accuracy, execution time and size of the map. A 10 × 10 map seems to be a reasonable compromise between precision and computational cost. The SOM described in [16,17] provide with other possible architectures, although they are designed to clustering data rather than the association and forecasting use described here.

Initialization procedure (linear or random) and training algorithm (sequential or batch) were also tested to determine the




Fig. 10. Result of modifying the time frame used to train the maps. Using data from previous years rather than only those from current year produces a breakthrough in MAPE.

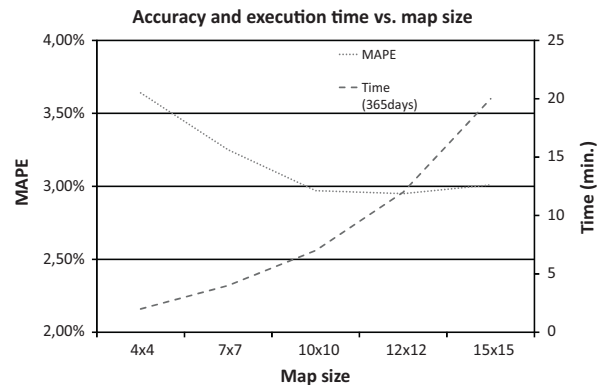


Fig. 11. Accuracy and computational burden as a function of map size. Maps that are bigger than 10 × 10 provide very little accuracy improvement if any at a much higher computational cost.

optimal training parameters. However, once again, both aspects did not have any impact on the final outcome of the forecast so linear initialization and batch training were selected due to speed factors. At last, duration of training is related to how well the SOM adapts to the training data. A SOM which is excessively adapted to the training data would lose its ability to generalize behavior and would perform less accurately when new data is introduced. Nevertheless, if the SOM is not trained for long enough, it will not learn the inner behavior of the training data and, therefore, its application to new data would also perform poorly. Matlab SOM Toolbox offers three qualitative options for this parameter: “short”, “medium” and “long”. Assuming that our training data are not very diverse since they have been selected to that purpose and that our SOM is initialized as a linear combination of the training data, a short training should suffice to meet the requirements, although all three options (short, medium and long) were tested to confirm the hypothesis.

3.4. Overall performance

The performance of a forecasting model is usually given in terms of MAPE. In this section the results of using our model to forecast the years 2006–2009 are presented. In Table 2, two comparisons are shown. The left column presents several results from different models published in the last 3 years. Our 2.18% MAPE appears as an above average result but it is important to consider that each model is tested with a different set of data making it necessary to look MAPE comparison with extreme skepticism. In the right column, the results correspond to the proposed model and to two other models developed: one using a standard MLP instead of SOM and one using an ARIMA model. The results of these models in addition to the aforementioned, make the proposed model a valid competitor to those examined. However, a standardized benchmark system would provide a more definite proof of excellence for forecasting models.


In addition to a single MAPE result, Fig. 12 and Fig. 13 show the result of the model grouped by weekday and month. Throughout the week, it is clear that Mondays are the most difficult day to forecast. The fact that this difficulty is more obvious on holidays is probably due to the fact that they usually occur after a permanent holiday (Sunday). Many stores or industries cannot afford a shut-down of two days in a row, so some holidays are not observed if they occur on a Monday.

Throughout the year, the results show little increments on MAPE during January, March and December. These months coincide with those containing short periods of holidays (Christmas, Easter). These less accurate results come especially from days that

**Table 2**

Forecasting results of reported models using different forms of AI with different sets of testing data. As a reference, the result of applying two other models to the same data set used with the proposed one is provided in the right column.

Comparative MAPE results: other data sets			Same data sets	
Method	Year	Reported MAPE	Method	Result
Wavelet fuzzy neural network [8]	2011	1.51%	MLP	2.59%
Neuro fuzzy [8]	2011	2.83%	ARIMA	3.18%
Adaptive neuro-fuzzy inference system [8]	2011	3.00%	Proposed method	2.18%
Wavelet transform + Evolutionary algorithm [9]	2009	2.04%		
Wavelets + Particle swarm optimization [10]	2009	3.96%		
Proposed method	2011	2.18%		




**Fig. 12.** Monthly evolution of MAPE. The figure shows spikes on the months containing holiday periods.


are actually holidays but also from regular days. In further research, a possible approach to this matter would be to create a new type of day for specific holidays and their eves. Similar results have been obtained when forecasting load from other Southern European countries (Italy, Greece) [14,15].

There is also a significant variation of the MAPE result throughout the forecasted years. While the error on holidays ranging between 2.5% and 3.75% follows no apparent pattern, the error on regular days is approximately 0.5% higher on 2009 than the average from 2006 to 2008 (see Fig. 14). In this period the lowest error obtained was actually 1.6% on 2006. The variation that appears on holidays is not relevant due to the very little amount of holidays. However, studying the difference seen on 2009 may lead to a deeper understanding on how the model works and why some data are easier to predict than other.

In order to comprehend why the same model would have such a different performance on data from the same area, a frequency analysis was done. As it was expected, the heaviest periodical components of the load signal had a period of 1 day, 1 week, 1 year and



**Fig. 13.** Daily evolution of MAPE. The figure shows a spike on Mondays.




**Fig. 14.** Overall performance values for the 2006–2009 period.

their fractions. Assuming that this periodical part of the signal is what provides its predictability, we can determine that those years in which these components were more significant would allow a more accurate forecast. Fig. 15 shows how 2008 and 2009 have a significantly lower percentage of power on the one-day, half-day, one-week and half-week periods. This circumstance may serve as one explanation on how the power carried on these four frequencies can be used to estimate the predictability of the data and why data from 2008 and 2009 are less predictable in terms of MAPE.

#### 4. Case study

##### 4.1. Introduction to the Spanish electricity market

As it was previously stated, the liberalization of the electricity market has uncovered inefficiencies of the systems that were concealed by price regulation. Demand forecast is a basic tool in any market for distributors and commercializing agents in order



**Fig. 15.** Power of the hourly load signal carried by the main four periodical components expressed as a percentage of the total power. The signal shows a significant decay in 2008 and 2009.






Fig. 16. Schedule for each one of the intra-daily session of the Spanish electricity market. Both the time at which the session is held and the time span it covers are shown.

Table 3

Forecasting results of the application of the proposed model to the Spanish electricity market, both daily and intra-daily sessions.

Application of proposed model to Spanish market	
Session	Reported MAPE
Daily	2.32%
Intra-daily 1	2.20%
Intra-daily 2	2.08%
Intra-daily 3	2.05%
Intra-daily 4	2.05%
Intra-daily 5	1.98%
Intra-daily 6	1.84%

to ensure supply at an optimum price, and liberalization makes electricity market no different.

The Spanish market is separated into two: daily and intra-daily. The daily session takes place at 10 a.m. on the day before and it balances offer and demand for the 24 hours of the next day (from 0 a.m. to 11 p.m.). The intra-daily market, however, is organized into 6 different sessions. Each one is scheduled at a different time and it covers from 4 hours after the session to the end of the day (see Fig. 16).

#### 4.2. Forecasting model

In order to build an application to suit this market structure, we need to follow the same structure described in our model flow chart. First of all, the data pre-processing stage should provide with a data matrix for each market session. This data should contain all available information plus the information from the forecasted period. The input selection process would then select the optimal input variables for each session and even for each hour of the session. Finally, time frame selection, load forecast and post-processing would provide a forecast for any of the sessions.

#### 4.3. Results

The model application to the daily market produces a forecast with a 2.32% MAPE. This is in line with the results obtained before, as the forecast for the daily market is carried out early on the previous day.

For the intra-daily market, we obtained a much more accurate forecast. This is mostly due to the forecast being made only 4 hours in advance. The final results are shown in Table 3.

### 5. Conclusions

There are three relevant contributions of this paper to the field of load forecasting. In the first place, SOM networks have proven to

be a successful tool not only for clustering and classification, which had been the most common uses of SOM networks to this day, but also as a valid forecasting engine. The accuracy achieved by the application of SOM networks in this model is comparable to those obtained with more popular techniques such as MLP or support vector regression.

Secondly, the structure of the model presented can be used as an initial approach to standardize the stages and internal procedures of load forecasting. In addition, the development of the input selection process proposed has proven to produce a significant reduction in MAPE.

Finally, the application to the Spanish electricity market proves to be efficient enough to compete with existing techniques. Moreover, the model has shown to be very flexible in terms of input variables, forecasting frequency and forecasted period length. This particular feature makes the model easily applicable to many different usages. Specifically, its application to a smaller load or a more area-specific group of consumers would enhance its performance due to the meteorological factors having a more significant effect.

### Acknowledgments

This research was financed by the Research Project with reference GV/2010/080-Valencian Government, Department of Education, and directed by Prof. Dr. Sergio Valero Verdú.

Also, this work is part of the research proposal by Miguel López García awarded the "I Ayudas a la Investigación" 2011 granted by the Iberdrola Foundation.

### References

- [1] R. Weron, Modeling and Forecasting Electricity Loads and Prices: A Statistical Approach, John Wiley & Sons, Ltd., 2007.
- [2] H.S. Hippert, C.E. Pedreira, R.C. Souza, Neural networks for short-term load forecasting: a review and evaluation, IEEE Transactions on Power Systems 16 (1) (2001) 44–55.
- [3] S. Valero, M. Ortiz, C. Senabre, C. Alvarez, F.J.G. Franco, A. Gabaldon, Methods for customer and demand response policies selection in new electricity markets, IET Generation, Transmission & Distribution 1 (1) (2007) 104–110.
- [4] S.V. Verdu, M.O. Garcia, C. Senabre, A.G. Marin, F.J.G. Franco, Classification, filtering, and identification of electrical customer load patterns through the use of self-organizing maps, IEEE Transactions on Power Systems 2 (4) (2006) 1672–1682.
- [5] A.D. Papalexopoulos, T.C. Hesterberg, A regression-based approach to short-term system load forecasting, IEEE Transactions on Power Systems 5 (November (4)) (1990) 1535–1547.
- [6] T. Haida, S. Muto, Regression-based peak load forecasting using a transformation technique, IEEE Transactions on Power Systems 9 (4) (1994) 1788–1794.
- [7] M.T. Hagan, S.M. Behr, The time series approach to short-term load forecasting, IEEE Transactions on Power Systems PWRS-2 (August (3)) (1987) 785–791.
- [8] M. Hanmandulu, B. Kumar Chauhan, Load forecasting using hybrid models, IEEE Transactions on Power Systems 26 (February (1)) (2011) 20–29.
- [9] N. Amjadi, F. Keynia, Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm, Energy 34 (2009) 46–57.
- [10] Z.A. Bashir, M.E. El-Hawary, Applying wavelets to short-term load forecasting using PSO-based neural networks, IEEE Transactions on Power Systems 24 (February (1)) (2009) 20–27.
- [11] G.-C. Liao, T.-P. Tsao, Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting, IEEE Transactions on Evolutionary Computation 10 (3) (2006) 330–340.
- [12] S. Fan, K. Methaprayoon, W.-J. Lee, Multiregion load forecasting for system with large geographical area, IEEE Transactions on Industry Applications 45 (4) (2009) 1452–1459.
- [13] S. Fan, L. Chem, W.-J. Lee, Short-term load forecasting using comprehensive combination based on multimeteorological information, IEEE Transactions on Industry Applications 45 (4) (2009) 1460–1466.
- [14] S.J. Kirtzis, A.G. Bakirtzis, V. Petridis, Short-term load forecasting using neural networks, Electric Power Systems Research 33 (April (1)) (1995) 1–6.
- [15] M. Sforna, F. Proverbio, A neural network operator oriented short-term and online load forecasting environment, Electric Power Systems Research 33 (May (2)) (1995) 139–149.

- [16] C.-i. Kim, I.-k. Yu, Y.H. Song, Kohonen neural network and wavelet transform based approach to short-term load forecasting, *Electric Power Systems Research* 63 (2002) 169–176.
- [17] V. Yadav, D. Srinivasan, ASOM-based hybrid linear-neural model for short-term load forecasting, *Neurocomputing* 74 (2011) 2874–2885.
- [18] P. Mandal, T. Senjyu, N. Urasaki, T. Funabashi, A neural network based several-hour-ahead electric load forecasting using similar days approach, *Electrical Power & Energy Systems* 28 (2006) 367–373.
- [19] T. Kohonen, *Self-organisation and Associative Memory*, 3rd edn., Springer-Verlag, Berlin, 1989.
- [20] J. Vesanto, J. Himberg, E. Alhoniemi, J. Parhankangas, *SOM Toolbox for Matlab 5*, ISBN 951-22-4951-0, 2000, [www.cis.hut.fi/projects/somtoolbox/](http://www.cis.hut.fi/projects/somtoolbox/).
- [21] REE, Red Eléctrica de España, [www.ree.es](http://www.ree.es).
- [22] Servicio de Información Meteorológica “OGIMET”, [www.ogimet.com](http://www.ogimet.com).



# Short-Term Predictability of Load Series: Characterization of Load Data Bases

Miguel López García, Sergio Valero, *Member, IEEE*, Carolina Senabre, and Antonio Gabaldón Marín, *Member, IEEE*

**Abstract**—This paper proposes the use of two indicators of the predictability of the load series along with an accuracy value such as mean average percentage error as standard measures of load forecasting performance. Over the last 10 years, there has been a significant increase in load forecasting models proposed in engineering journals. Most of these models provide a description of the inner design of the model, the results from applying this model to a specific data base and the conclusions drawn from this application. However, a single accuracy value may not be sufficient to describe the performance of the model when applied to other data bases. The aim of this paper is to provide researchers with a tool that is able to assess the predictability of a load series and, therefore, contextualize the forecasting accuracy reported. Nine different data bases from the U.S. have been used; all of them include hourly load and temperature data.

**Index Terms**—Forecasting, frequency domain analysis, performance evaluation, power demand.

## I. INTRODUCTION

SHORT-TERM load forecasting is an essential part of power generation, operation of power systems and participation in power markets [1]. In addition, the liberalization of energy markets on top of a situation of economic crisis makes efficiency of electric systems and operations a key to success in the business. Being so important, short-term load forecasting has received wide attention from researchers in the last 15 years. The focus of the scientific community on this topic has provided with many different approaches to load forecasting, ranging from the early statistical methods [2]–[4] to the more complex Artificial Intelligence-based models like multilayer perceptron (MLP) [5], [6], fuzzy logic [7], [8], Bayesian neural networks [9] or other topologies like Kohonen maps [10]–[12]. Some proposed works include hybrid models [13]–[15] and also some include feature extraction using decomposition methods such as wavelet transforms [14]–[17].

Manuscript received April 06, 2012; revised November 02, 2012 and January 30, 2013; accepted February 15, 2013. Date of publication March 18, 2013; date of current version July 18, 2013. This work was part of the research proposal by Professor S. Valero and the Ph.D. student M. López García awarded the “I Ayudas a la Investigación” 2011 granted by the Iberdrola Foundation. This work also was supported by the Spanish Government (Ministerio de Economía y Competitividad) and EU-FEDER funds under Research Project ENE2010-20495-C02-02. Paper no. TPWRS-00338-2012.

M. López García, S. Valero, and C. Senabre are with the Universidad Miguel Hernández de Elche, 03202 Elche, Spain (e-mail: svalero@umh.es; csenabre@umh.es; lopezgarcia.m.81@gmail.com).

A. Gabaldón Marín is with the Polytechnic University of Cartagena, Electrical Engineering, Dr. Fleming s/n, Cartagena, Murcia 30202, Spain (e-mail: antonio.gabaldon@upct.es).

Color versions of one or more of the figures in this paper are available online at <http://ieeexplore.ieee.org>.

Digital Object Identifier 10.1109/TPWRS.2013.2250317

The number of available methods for load forecasting has continued to grow each year, which should have led to an overall improvement of forecasting performance. However, the way that results are usually presented (mostly a single accuracy indicator such as mean absolute percentage error: MAPE), and especially, the development of forecasting models focusing on databases of very specific nature [5], [7], [10] (one region, one type of consumer, etc.) makes it very hard to compare results among the variety of proposed methods. This issue also arises when a potential user of the model tries to determine whether the reported performance of the model will also be the result of applying it to his own data base.

The reason for this lack of comparability stems from the diverse nature of load series from different regions or type of consumers. It is well-known that hourly load profiles are highly dependent on the socio-economic activity, the day of the week, the time of the year, whether it is a holiday or not, the temperature and other meteorological variables or the occurrence of different socio-political events such as strikes or sporting events. In addition, even when all known relevant variables are the same, there is variability among the profiles of similar days which implies that there are other unknown factors influencing hourly load. The relevance of all of these known and unknown circumstances varies from one region to another, creating therefore a specific signature of the load series from the region.

This difference among load series is the key to understanding the incomparability of forecasting results. A model designed to perform well when applied to a load series that is highly dependent on the day of the week will not take full advantage of this feature when applied to a load series with a lower dependency on this factor. Therefore, it will perform poorly. It becomes even clearer when the effect of temperature is taken into account: a forecasting model design to take the temperature as a relevant factor will prove effective when the load is highly influenced by the weather (areas in which a significant part of the load comes from air conditioning or heating systems). Nevertheless, it will not be as accurate when it is applied to an area or a type of clients that do not show this behavior.

In order to solve this problem, it is necessary to assess the characteristics of the load series and determine how predictable the series is. This predictability indicator could then be used to contextualize the reported accuracy, enabling potential users of the model to estimate the expected accuracy of the model when applied to their own series. In addition, this indicator would improve the benchmarking possibilities among load forecasting models regardless of the data base they have been tested on.

Predictability of load series has been studied through the use of Lyapunov exponents [18], [19] and also the predictability of other time series through different metrics [20], [21]. In this




Fig. 1. Geographical distribution of the data bases used in the study: ISONE: New England total.




Fig. 2. Main periodical patterns of most load series.

paper we propose two indicators based on the frequency components of the data base and the influence of temperature on the load. The data used is real data obtained from the independent system operator (ISO) in New England (USA), as shown in Fig. 1. In Section II, the main characteristics of load series are analyzed on the frequency domain. The relationships between frequency analysis and predictability which is at the theoretical foundation of the working principles of the indicator are also established. Section III includes an analysis of how temperature influences load. Section IV contains a description of how the predictability indicators are obtained and how the hypothesis presented in Sections II and III are ratified. Section V describes the obtained results and their application in load forecasting research. Finally, conclusions are exposed in Section VI.

## II. FREQUENCY ANALYSIS OF LOAD SERIES

Load series usually represent the evolution of energy consumption during one hour by a group of customers over a period of time. Sometimes shorter units of time are used (5 or 15 min) but hourly loads are the most common. This type of series usually shows periodical behavior of different frequency, generally: daily, weekly and yearly or seasonal (see Fig. 2). The reason for this behavior is quite obvious: the consumers behave in daily, weekly and seasonal consuming patterns.

These patterns are common to all load series, but the relevance of each one varies from one data base to another. In addition, some other patterns with different periods may be of some relevance in certain data bases depending on the nature of the consumer. Fourier transforms and specifically spectral analysis




Fig. 3. Power spectral density of the load series from data base CT.

may be used to determine the significance of a component of a certain frequency within a given signal.

### A. Calculation of Power Spectral Density (PSD)

The power spectral density of a signal is the way that the power carried by the signal spreads over the frequency spectrum. In order to calculate this spectral density, the load series  $L_h$  is displaced (1) to obtain a new series  $x_n$  with zero mean. The discrete fourier transform (DFT) is applied in (2) to obtain the series of coefficients  $x_k$ . The series  $P_T$  plotted in Fig. 3 were calculated using (3) and correspond with the power spectral density of the zero-mean series versus frequency.

To help visualization, the x-axis represents period instead of frequency and only the first half of the data is used since the result of (3) is a symmetrical series

$$\{x_n\} = L_h - \overline{\{L_h\}}; h = 0, 1, \dots, N - 1 \quad (1)$$

$$\{x_k\} = \frac{1}{N} \sum_{n=0}^{N-1} (x_n e^{-i2\pi kn/N}); k = 0, \dots, N - 1 \quad (2)$$

$$\{P_T\} = x_k \cdot x_k^*; k = 0, 1, \dots, N - 1 \quad (3)$$

where  $N$  is the number of sample of the original series.

The distribution shown in Fig. 3 confirms the hypothesis that the main contribution to the load series comes from the daily ( $T = 1$ ), weekly ( $T = 7$ ) and seasonal ( $T \approx 182$ ) patterns. However, the whole information derived from these patterns is present also in periods that are fractions of each main period. Table I shows the power carried by the most important frequencies in some of the data bases used in this paper.

### B. Load Predictability and Frequency Analysis

One of the hypotheses presented in this paper is that it is possible to estimate the predictability of a load series by analyzing its PSD. The use of other external variables to improve forecasting accuracy will be discussed in Section III and above.

To gain some perspective on the importance that frequency analysis has on load forecasting; let's consider the load series as the sum of an unpredictable series and a predictable one. Then, it is obvious that the more similar the original series is to its predictable part, the more predictable the original series is.



TABLE I  
POWER CARRIED BY THE MAIN COMPONENTS OF LOAD SERIES

DATA BASE	POWER PERCENTAGE CARRIED BY EACH COMPONENT								
	T=1/2	T=1	T=7/6	T=7/2	T=7	T=365/3	T=365/2	T=365	REST
CT	8,1%	47,1%	1,4%	1,4%	4,7%	1,1%	13,0%	0,4%	22,6%
ISONE	9,1%	50,3%	1,5%	1,4%	5,1%	1,1%	11,7%	0,4%	19,4%
ME	15,1%	56,2%	1,3%	1,0%	3,1%	0,7%	6,9%	0,6%	15,2%
NEMASSBOST	6,9%	47,7%	1,8%	1,7%	6,0%	1,2%	11,5%	0,5%	22,7%
NH	10,8%	54,0%	1,4%	1,3%	5,3%	0,8%	9,4%	0,1%	16,9%
RI	7,4%	47,2%	1,5%	1,3%	4,7%	1,6%	12,5%	1,4%	22,4%
SEMASS	9,0%	48,5%	1,2%	0,9%	3,1%	1,7%	13,0%	1,3%	21,2%
VT	12,6%	51,5%	1,4%	1,5%	5,2%	0,7%	8,9%	1,5%	16,8%
WCMASS	8,8%	48,1%	1,5%	1,9%	7,5%	1,0%	10,5%	0,1%	20,7%
AVERAGE	9,8%	50,1%	1,4%	1,4%	5,0%	1,1%	10,8%	0,7%	19,8%

Any predictable signal can be defined as a combination of a finite amount of periodical signals of known frequency and amplitude as opposed to an unpredictable one (white noise) which is a combination of infinite signals of different frequency and equal amplitude [22]. By these definitions, frequency analysis gives us the tool to extract a predictable series by filtering a group of components of known frequency. This predictable series will be relevant compared to the original one if the power it carries is significant; however, it will be less predictable if the number of frequencies included is too high.

In conclusion, if the load series has such an uneven PSD that few frequencies carry enough power to be relevant compared to the power of the original signal, then the signal will be predictable. Section IV includes the methodology used to obtain a numeric predictability estimator based on the PSD of the original series.

### III. TEMPERATURE INFLUENCE ON LOAD

The influence of the weather on electricity consumption has been widely discussed [23], [24]. In this section, we will focus on the effect of temperature although any other variable can be analyzed in the same way.

#### A. Factors That Determine Temperature's Influence on Load

Temperature can generally be accepted as a major factor driving load; however, it is important to understand precisely how temperature affects electrical load. Variations in temperature usually cause variations in power consumption but the magnitude of this influence may be altered by factors like the day of the week or the time of the day. For instance, the load of a Sunday may be affected by a heat wave differently than that of a Thursday would be. Also, a temperature drop at 4 a.m. may not cause the same behavior than one occurring at noon. Fig. 4 shows how load is affected differently by temperature depending on the time of day and the day of the week.

#### B. Load Predictability From Temperature Data

Predictability is highly related to correlation. Two highly correlated series may be accurate predictors for each other. Therefore, if temperature is highly correlated to load, its use in load forecasting would improve the accuracy of the forecast.

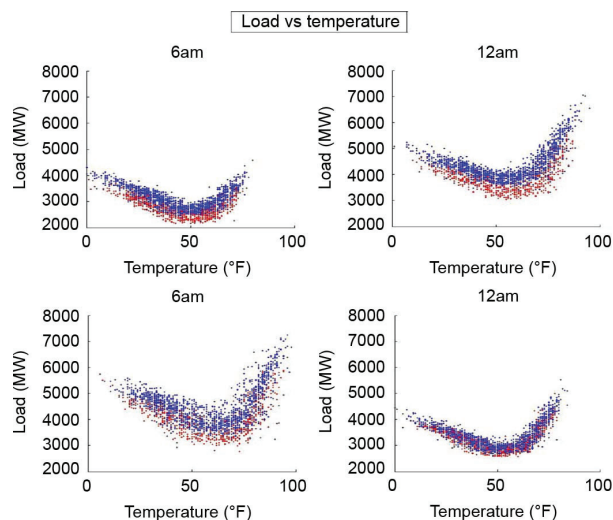


Fig. 4. Load dependency on temperature, time of day and day of the week. Red dots represent Sundays and Saturdays while blue dots represent any other weekday.

However, the nonlinear behavior shown in Fig. 4, makes raw temperature data on its own insufficient to be used in load forecasting. Therefore, it is necessary to contextualize the temperature data and create an additional time-series that can be used as an input for the forecasting model.

This problem has been tackled following different approaches [8], [25]. The scope of this paper is not to determine which approach is best but to provide with a methodology capable of using the aforementioned time-series to estimate the predictability of the load series.

Therefore, the function  $f(T, d, h)$  defined throughout Section IV-E is used. This method is simple and easy to apply to time-series of any other nature (electricity prices, humidity, etc.) that may be considered as load driving factors. This function can be determined from recent historical data and its addition to the data base would provide with an alternate load series whose correlation with the original one may be used as a load predictor.

In conclusion, in order to use temperature in load forecasting it is advised to pre-process the data to eliminate nonlinearities and contextualize the data. The approach taken in this paper is to obtain a surrogate load data series built from both temperature and load historical data which includes the contextualized effect of temperature in load. The similarity (mean absolute percentage difference) between this surrogate series and the original one determines how predictability improves by including temperature data. Section IV shows the methodology used to obtain the series and the predictability estimator based on temperature.

### IV. METHODOLOGY

By the theoretical foundations established in Section II, the first step to achieve the goal of estimating load series predictability is to design a filter that is capable of extracting a signal that is both predictable and significant from the original

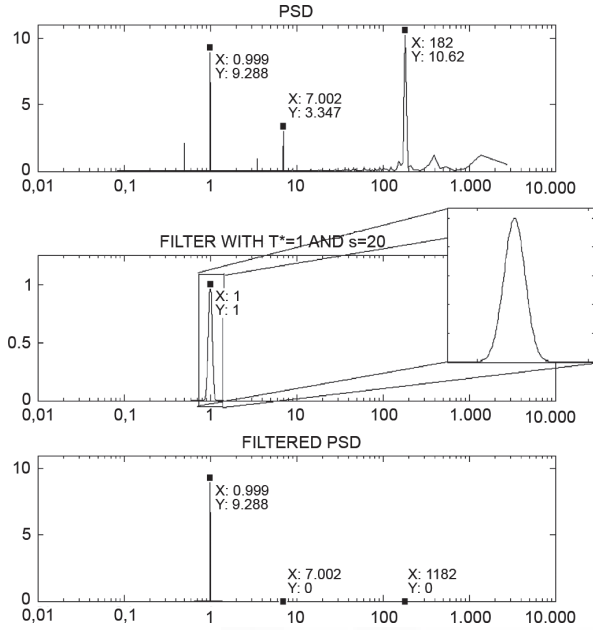


Fig. 5. Effect that each filter has on the original PSD is that it cancels out frequencies that are not within a certain threshold of the specified period  $T^*$ .

one. Then, by calculating the difference between this predictable signal and the original one it will be established that the more different they are to each other, the less accurate its forecast is likely to be.

#### A. Design of the Load Filter

In Table I, the power carried by the most significant frequencies in each load series is shown. Several possible functions (square, triangular, Gaussian) were tested to build a filter to extract the “spikes” shown in Fig. 3, which are the ones associated with the known periodical behavior. The filters based on all three functions provided similar results but the proposed filter  $F_k$  based on the Gaussian function and described in (4) was chosen due to the differentiability of the Gaussian function. The product of the previously defined  $P_T(3)$  and the filter  $F_k(4)$  isolates the signal components of a given period:

$$\{F_k(T^*, s)\} = a \cdot e^{-(T_k - b)^2 / 2c^2}; k = 0, 1, \dots, N - 1 \quad (4)$$

where  $a = 1$ ,  $b = T^*$ ,  $c = T^*/s$ .

$T^*$  is the selected period to be filtered and  $s$  is a parameter to adjust the correct width of the filter. Fig. 5 shows an example of the filter, and its calculation is detailed in Sections IV-C and IV-D.

The selection of the frequencies to be filtered is made based on the PSD. The periods associated with each daily, weekly and seasonal pattern are those of 1, 7 and 365 days and their divisions by natural numbers; however the optimal combination of frequencies depends on each load series. Nevertheless and for the sake of generalization, the selected periods for all series are the same and are shown on Table II.

TABLE II  
SELECTED PERIODS AS CENTER FOR EACH FILTER

	DAILY PATTERN		WEEKLY PATTERN				SEASONAL PATTERN					
$T^*$ (days)	1/3	1/2	1	7/6	7/5	7/4	7/3	7/2	7	365/3	365/2	365

The actual filter applied is a combination of the filters designed for each frequency. The combination of the filters is described in (5):

$$\{FT_k(s)\} = \max \{F_k(T, s)\}; T \in \{T^*\}. \quad (5)$$

#### B. Deviation From the Original Signal

Once the filter has been designed, the next step is to establish a way to determine how different the filtered signal is from its original one. One intuitive way would be to relate the similarity of the signals to the percentage of power carried by the filtered one. However, this method would not be as precise as the same indicator used to measure forecasting accuracy: the MAPE.

In order to reconstruct the signal filtered by  $FT_k$ , the inverse DFT needs to be applied (6) and the mean value of the original series  $L_h(7)$  should be added:

$$\{x_n\} = \frac{1}{N} \sum_{k=0}^{N-1} (x_k e^{+i2\pi kn/N}); n = 0, \dots, N - 1 \quad (6)$$

$$L'_h = x_n + \overline{L_h} \quad (7)$$

where  $L'_k$  is the reconstruction of the original signal

The MAPE between the filtered signal  $L'_k$  and the original  $L_k$  is then calculated using (8):

$$D(s) = \frac{1}{N-1} \sum_{h=0}^{N-1} \left| \frac{L_h - L'_h}{L_h} \right|. \quad (8)$$

As expected, Fig. 6 shows how the difference between signals becomes greater as the width of the filter decreases (more frequencies are attenuated).

Another interesting point is that the difference increases very fast at the beginning but once a certain threshold  $s^*$  is reached, the rate of growth of the difference is close to zero and, therefore, the difference remains reasonably constant. The way this should be interpreted is that  $s^*$  represents the width parameter which optimizes the difference/attenuation ratio. The importance of this parameter and its proper calculation will be further explained in Section IV-D.

#### C. Forecast of Filtered Signals

In Section IV-B, the filtered load series from the data bases were obtained. According to the theory enunciated at the beginning of the section, these series should be more predictable than the original ones. In this sub-section, a series of forecasts will be carried out in order to validate this hypothesis. Also, it is necessary to define a value for  $s$  for which the predictability/difference ratio is optimized. This value completes the definition of the optimal filter to be applied to a load series in order to extract a significant and predictable signal.

TABLE III  
FORECASTING ERROR OF THE ORIGINAL AND FILTERED SIGNALS

DATA BASE	S-parameter														
	s=0	s=1	s=3	s=10	s=30	s=60	s=70	s=80	s=90	s=100	s=150	s=200	s=500	s=700	s=1000
CT	5,2%	4,8%	4,1%	2,6%	1,5%	1,2%	1,1%	1,1%	1,0%	1,0%	1,0%	1,1%	1,2%	1,1%	1,4%
ISONE	4,5%	4,2%	3,4%	2,2%	1,3%	1,0%	0,9%	0,9%	0,9%	0,9%	0,9%	1,0%	1,1%	1,0%	1,4%
ME	3,3%	3,0%	2,5%	1,7%	1,0%	0,8%	0,8%	0,8%	0,7%	0,7%	0,8%	0,8%	0,8%	0,7%	1,0%
NEMASSBOST	4,7%	4,4%	3,7%	2,4%	1,4%	1,0%	1,0%	0,9%	0,9%	0,9%	0,9%	0,9%	1,0%	1,0%	1,1%
NH	4,4%	4,1%	3,4%	2,3%	1,4%	1,1%	1,0%	1,0%	1,0%	0,9%	1,0%	1,0%	1,1%	1,0%	1,4%
RI	4,9%	4,7%	3,9%	2,6%	1,5%	1,2%	1,1%	1,0%	1,0%	1,0%	1,0%	1,1%	1,1%	1,0%	1,5%
SEMASS	5,0%	4,7%	4,0%	2,7%	1,6%	1,2%	1,1%	1,1%	1,1%	1,1%	1,0%	1,1%	1,2%	1,0%	1,3%
VT	3,4%	3,1%	2,5%	1,6%	1,0%	0,8%	0,8%	0,8%	0,8%	0,8%	0,8%	0,8%	0,9%	0,8%	1,2%
WCMASS	4,6%	4,2%	3,4%	2,2%	1,4%	1,0%	0,9%	0,9%	0,9%	0,9%	0,9%	1,0%	1,1%	1,1%	1,5%
AVERAGE	4,4%	4,1%	3,4%	2,3%	1,4%	1,0%	1,0%	0,9%	0,9%	0,9%	0,9%	1,0%	1,1%	1,0%	1,3%

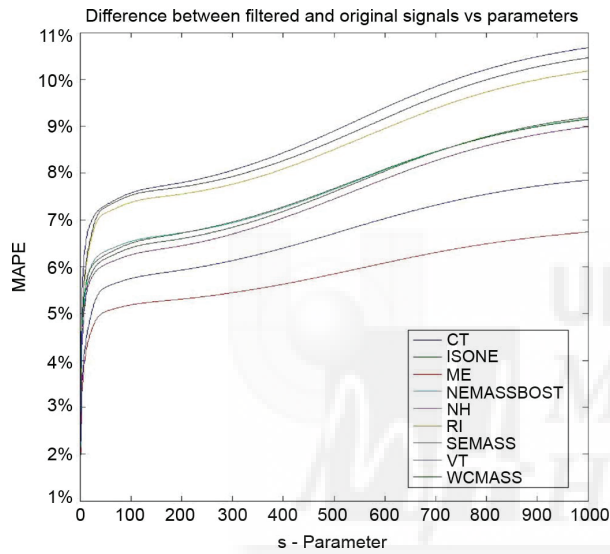


Fig. 6. Difference between an original signal and a filtered one increases up to a certain threshold as the Gaussian function gets thinner.

The model described in [12] will be used as the forecaster. This model forecasts day-ahead 24-hour load profiles. It takes into account the day of the week, holidays, seasonal effect and temperature, if available.

The execution time of this model for a 365 days period is about 3 min on a 2.5-GHz CPU with 4 Gb of RAM. Therefore, considering that there is a total of 9 data bases [26], it is required in order to manage the computational burden to limit the number of  $s$  values tested to 33 (approximately 15 hours of computing time). These 33 values are more densely positioned around the expected “knee” point ( $s \approx 60$ ), so that the point can be accurately identified. Table III shows the results of the forecasts of each original signal and the filtered ones from each data base.

A visualization of Table III (Fig. 7) helps to understand that the forecast error actually decreases as the signal becomes more different (filtered). Actually, for each signal there seems to be a predictability limit at about 1%, although each series reaches this threshold at a different attenuation of the original signal.

The accuracy of these forecasts varies in a wide range, even though the parameters used for the forecasting model were always the same. This also proves that the accuracy of a fore-




Fig. 7. Error of each series decreases down to a certain threshold as the signal is more filtered.

casting model has a high variability when applied to different load series.

#### D. Calculation of the S-Parameter

The curves shown in Fig. 7 show that there is a turning point at which the cost of reducing the error by increasing the difference is the lowest.

This point corresponds with the optimal value of  $s$ . This point can be obtained from the forecasts already made; however, this value is needed before a forecast is available. An approximation for it is the  $s^*$  value described in Section IV-B. To obtain  $s^*$ , the series  $D(s)$  described in (8) must be calculated with  $s$  taking all integer values from 0 to 200. Then, (9) is used to determine the optimal value of  $s$ :  $s^*$ :

$$s^* = s \left| D(s^*) - D(s^* - 1) \right| \\ = \min \{D(s) - D(s - 1)\} \quad \forall s > 0. \quad (9)$$

Given that forecasts are not necessary, the calculation of  $D(s)$  for 200 values is not time consuming.

Table IV shows the values of  $D(s^*)$  and  $D(s)$  with  $s =$  optimal applied to all data bases. The coefficients of the linear correlation are shown, proving them equivalent.

TABLE IV  
EQUIVALENCY BETWEEN  $s^*$  AND THE OPTIMAL VALUE OF S

DATA BASE	Difference with original series (MAPE)		
	$s=s^*$	$s=optimal$	
CT	7,5%	7,6%	
ISONE	6,3%	6,4%	
ME	5,2%	5,1%	
NEMASSBOST	6,5%	6,6%	
NH	6,1%	6,3%	
RI	7,3%	7,3%	
SEMASS	7,5%	7,6%	
VT	5,7%	5,6%	
WCMASS	6,5%	6,4%	
	m	b	$R^2$
Linear regression	1,012	-0,002	0,9970

TABLE V  
CORRELATION BETWEEN SURROGATE AND ACTUAL LOAD SERIES

	NN5	NN7	NN10	NN15	M-REG	MEAN
$R^2$	0,9154	0,9331	0,939	0,938	0,6312	0,9639

### E. Design of the Temperature Function

As it was established in Section III-B, it is necessary to obtain a function that relates load to temperature, day of the week and time of day (10):

$$\tilde{L}^{d,h} = f(T^{d,h}, w(d), h) \quad (10)$$

where

- $\tilde{L}^{d,h}$  alternate load at time  $h$  of day  $d$ ;
- $T^{d,h}$  temperature at time  $h$  of day  $d$ ;
- $w(d)$  weekday of day  $d$ .

The choice of the function  $f$  should be determined by its ability to provide a series highly correlated to the actual load. If this function is applied to the whole data base, the result would be an alternate load series depending solely on temperature, day of the week and time of day. The techniques tested to implement this function were:

- multivariate regression, using one regression for each day of the week, with the temperature and a sinusoidal series derived from the time of the day as input variables.
- MLP neural network configured with 5, 7, 10 and 15 hidden neurons.
- mean function where the output is the average load of values of the same hour, day of the week and temperature plus or minus 1 degree.

The results of these functions in terms of the correlation between the surrogate and the actual load is presented in Table V and show how the mean function provides a simple yet highly correlated series.

TABLE VI  
FORECASTING ERROR AND PREDICTABILITY ESTIMATORS FOR DIFFERENT DATA BASES

DATA BASE	Forecasting error	$D(s^*)$	$\eta_k$	$\eta_b$	$\eta_1$	$\eta_2$
CT	5,2%	7,5%	0,221	0,118	0,910	0,700
ISONE	4,5%	6,3%	0,300	0,164	0,927	0,729
ME	3,3%	5,2%	0,285	0,155	0,937	0,750
NEMASSBC	4,7%	6,5%	0,171	0,907	0,883	0,657
NH	4,4%	6,1%	0,268	0,145	0,925	0,727
RI	4,9%	7,3%	0,228	0,122	0,911	0,702
SEMASS	5,0%	7,5%	0,293	0,160	0,927	0,730
VT	3,4%	5,7%	0,232	0,124	0,935	0,745
WCMASS	4,6%	6,5%	0,339	0,188	0,919	0,715

### F. Deviation From the Original Series

The same index is proposed in order to determine how similar the alternate load series and the actual load are. Calculation of MAPE can be found in (11):

$$E_T = \frac{1}{N-1} \sum_{h=0}^{N-1} \left| \frac{L_h - \tilde{L}_h}{L_h} \right|. \quad (11)$$

In addition, Table VI shows the obtained values for the MAPE between actual and alternate loads for all data bases.

### G. Estimating Predictability Using PSD and Temperature Data

The initial goal of this paper was to provide a method that would allow a researcher to estimate how a forecasting model would perform with data bases with different characteristics and, more importantly, include in his work an indicator of the predictability of the data based used for his accuracy report. The reader could use this indicator to estimate whether the model will apply accurately to his data base or not.

At this point, it has been established that the filter described in (4) and (5) is able to extract a signal that is both more predictable than the original and has a certain degree of similarity to it. Also, if the filtering parameter  $s$  equals  $s^*$ , the predictability of the resulting signal is optimal, which means that further filtering of the signal does not result in decreasing forecasting error. Therefore, it is possible to consider the difference of the filtered signal with  $s = s^*$ ,  $D(s^*)$ , as an estimator of the predictability of the signal.

To prove the validity of  $D(s^*)$  as a predictability estimator, a linear regression analysis for  $D(s^*)$  and the forecast error of the original series was made using all 9 data bases. The result of this regression is detailed in Section V.

In addition, the possibility of having external variables available to improve the forecast is considered. The value of  $E_t$  obtained in (10) and (11) provides with an estimation of how different is the actual series from one that can be forecasted without error only by using the temperature, the time of day and the day of the week. The validity of  $E_t$  as a predictor of the accuracy improvement derived from including temperature data in a forecast is also presented in Section V.



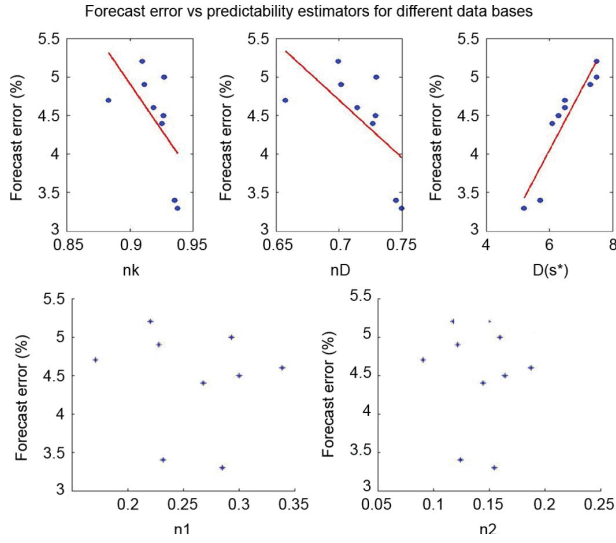


Fig. 8. Different data bases data dispersion and curve fitting of forecasting error versus each of the predictability estimators.

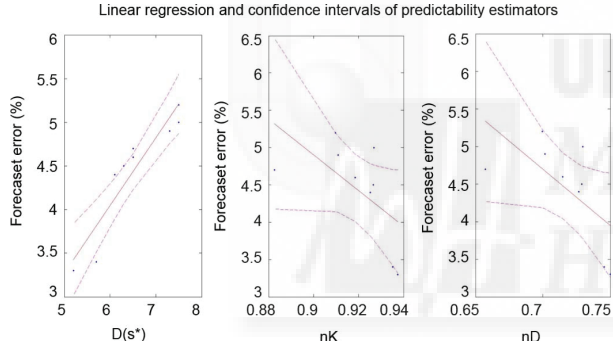


Fig. 9. Curve fitting and confidence intervals for  $D(s^*)$ ,  $\eta_k$  and  $\eta_d$ .

## V. RESULTS

The objective of this section is to demonstrate that  $D(s^*)$  can act as an estimator of series predictability and that  $E_t$  can estimate the increase of predictability when temperature is also included. In order to do so, nine different real data bases and one forecasting model are used. Data bases comprise hourly loads for different regions in the New England area from 2005 to 2010 [26]. As described in [12], the forecast uses data from 2005 to 2009 to self-adjust its parameters and uses an ongoing learning algorithm to forecast the year 2010. The forecast accuracy for these databases is relatively low, but it is worth noticing that the forecasting model have not been adapted in any way to the data used and all type of days (holidays, weekends and workdays) are included in the result. To contextualize the results obtained by the proposed indicators, the predictability estimators defined in (12) have been implemented:

$$\begin{aligned} \eta_1 &= 1 - \frac{SSE_{act}}{SSE_{surr}} & \eta_k &= 1 - \frac{SSE_{act}}{SSE_{shf}} \\ \eta_0 &= 1 - \sqrt{\frac{SSE_{act}}{SSE_{shf}}} & \eta_2 &= 1 - \sqrt{\frac{SSE_{act}}{SSE_{surr}}} \end{aligned} \quad (12)$$

TABLE VII  
STATISTICAL DATA FOR THE FITTING OF FORECASTING  
ERROR AND PREDICTABILITY ESTIMATORS

Curve fitting parameters	$D(s^*)$	$\eta_k$	$\eta_D$
$R^2$	0,8665	0,357	0,401
SSE	4,78E-5	2,30E-4	2,14E-4
stdError	0,0026	0,006	0,006
95% Conf.Interval	0,57%	1,21%	1,18%

where  $SSE$  stands for the sum square error of a dummy forecast of the actual time series, or either a shuffled or a surrogate series based on the former. The obtencion of these forecast and surrogate and shuffled series is detailed in [20] and [21].

### A. Accuracy of Predictability Measures

The results shown in Table V correspond to the values of the estimator  $D(s^*)$ , the control estimators  $\eta$  and the actual forecast error of the model described in [12]. A visual representation of this result (Fig. 8) proves that  $\eta_1$  and  $\eta_2$  do not show any correlation in any form but also that  $D(s^*)$ ,  $\eta_k$  and  $\eta_d$  can be linearly correlated to the forecasting error. This relation is further studied and expressed in terms of the correlation coefficients, sum of square error, standard error and the average 95% confidence prediction interval width.

The data shown in Table VII prove that  $D(s^*)$  is the most accurate predictor of the forecast performance. Also, in Fig. 9, it is represented the graphical meaning of the confidence intervals expressed in Table VII.

The estimator  $E_t$  is included for the case that temperature is also taken into account. At this point only  $D(s^*)$  is further used. Table VIII shows the data used in the multi-variable linear regression between forecasting error (using temperature),  $D(s^*)$  and  $E_t$ . As a comparison, the data from the regression using only  $D(s^*)$  is also included. From the statistical correlation data shown in Table IX it can be concluded that both indicators,  $D(s^*)$  and  $E_t$  can act as predictors of the predictability of a data base and may, therefore, be used to characterize it in order to contextualize a forecasting result.

### B. Applicable Results

The result described in Section V-A opens some possibilities to improve accuracy reporting in load forecasting. The use of indicators characterizing load data bases in terms of predictability can help to contextualize the forecasting reported in a proposed forecasting model. This would improve the possibilities for actual benchmarking and also provide with a tool to identify which type of models are most accurate when considering a specific data base.

This paper proposes that forecasting models report, along with an accuracy result such as MAPE, the value of  $D(s^*)$  and  $E_t$ . These values are obtained by the application of the filter defined in (4) and (5), whose parameters  $s^*$  and  $T^*$  are specified in (9) and Table II, respectively, and the use of the transform function described in (10) and the error calculation found in (11).

If more than one data base is available, the proposal is extended to also include the accuracy result and indicator values for all data bases. In addition, it is advised to provide also an

TABLE VIII  
FORECASTING ERROR USING TEMPERATURE AND PREDICTABILITY ESTIMATORS  
FOR DIFFERENT DATA BASES

DATA BASE	Forecasting error with temperature	D(s*)	E <sub>t</sub>	D(s*) × E <sub>t</sub>
CT	3,9%	7,5%	4,2%	0,3%
ISONE	3,2%	6,3%	3,1%	0,2%
ME	3,2%	5,2%	3,5%	0,2%
NEMASSBOST	3,5%	6,5%	3,3%	0,2%
NH	3,4%	6,1%	3,7%	0,2%
RI	3,8%	7,3%	3,6%	0,3%
SEMASS	3,8%	7,5%	3,9%	0,3%
VT	2,8%	5,7%	3,3%	0,2%
WCMASS	3,5%	6,5%	3,6%	0,2%

TABLE IX  
STATISTICAL DATA FOR THE FITTING OF FORECASTING ERROR USING  
TEMPERATURE AND PREDICTABILITY ESTIMATORS

Curve fitting parameters	D(s*)	D(s*) + E <sub>t</sub>
R <sup>2</sup>	0,7679	0,8935
SSE	2,33E-5	1,07E-4
stdError	0,17%	0,11%

analysis of the correlation of these sets of values which may not be necessarily linear.

## VI. CONCLUSIONS

This paper proposes a new approach to load forecasting error reporting. By including the proposed indicators about the load series in the performance analysis of a forecasting model, it is possible to better understand the expected forecasting accuracy when such model is applied to other data bases.

The indicators described in this paper are a simple and independent from the forecasting model. Therefore, they provide an interesting tool to enhance performance reporting of load forecasting models by contextualizing the difficulty of the forecasting task.

The method to calculate such estimators is detailed throughout the document and can be easily adapted to include other variables. Finally, the test carried out with real data proved that the indicators  $D(s^*)$  and  $E_t$  have a strong correlation with forecast error obtained by a general forecasting model, both using temperature and not. As a result, the indicators can be used to characterize the data series and *a priori* assess its predictability.

## ACKNOWLEDGMENT

The authors would like to thank A. Hernández and A. Martínez-Gómez for their work in the improvement of this document.

## REFERENCES

- [1] H. S. Hippert, C. E. Pedreira, and R. C. Souza, "Neural networks for short-term load forecasting: a review and evaluation," *IEEE Trans. Power Syst.*, vol. 16, no. 1, pp. 44–55, Feb. 2001.
- [2] A. D. Papalexopoulos and T. C. Hesterberg, "A regression-based approach to short-term system load forecasting," *IEEE Trans. Power Syst.*, vol. 5, no. 4, pp. 1535–1547, Nov. 1990.
- [3] T. Haida and S. Muto, "Regression-based peak load forecasting using a transformation technique," *IEEE Trans. Power Syst.*, vol. 9, no. 4, pp. 1788–1794, Nov. 1994.
- [4] M. T. Hagan and S. M. Behr, "The time series approach to short-term load forecasting," *IEEE Trans. Power Syst.*, vol. PWRS-2, no. 3, pp. 785–79, Aug. 1987.
- [5] P. Mandal, T. Senjyu, N. Urasaki, and T. Funabashi, "A neural network based several-hour-ahead electric load forecasting using similar days approach," *Elect. Power Energy Syst.*, vol. 28, pp. 367–373, 2006.
- [6] T. Yalcinoz and U. Eminoglu, "Short term and medium term power distribution load forecasting by neural networks," *Energy Convers. Manage.*, vol. 46, pp. 1393–1405, 2005.
- [7] G. C. Liao and T. P. Tsao, "Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting," *IEEE Trans. Evol. Comput.*, vol. 10, no. 3, pp. 330–340, 2006.
- [8] Y.M. Wi, S.K. Joo, and K.B. Song, "Holiday load forecasting using fuzzy polynomial regression with weather feature selection and adjustment," *IEEE Trans. Power Syst.*, vol. 27, no. 2, pp. 596–603, May 2012.
- [9] D.X. Niu, H.F. Shi, and D. D. Wu, "Short-term load forecasting using Bayesian neural networks learned by hybrid Monte Carlo algorithm," *Appl. Soft Comput.*, vol. 12, no. 6, pp. 1822–1827, Jun. 2012.
- [10] C.I. Kim, I.K. Yu, and Y. H. Song, "Kohonen neural network and wavelet transform based approach to short-term load forecasting," *Elect. Power Syst. Res.*, vol. 63, pp. 169–176, 2002.
- [11] V. Yadav and D. Srinivasan, "A SOM-based hybrid linear-neural model for short-term load forecasting," *Neurocomputing*, vol. 74, pp. 2874–2885, 2011.
- [12] M. López, S. Valero, C. Senabre, C. Aparicio, and A. Gabaldón, "Development of a model for short-term load forecasting with neural networks and its application to the electrical Spanish market," in *Proc. 2011 8th Int. Conf. European Energy Market (EEM)*, 2011, pp. 321–326.
- [13] M. Hanmandlu and B. K. Chauhan, "Load forecasting using hybrid models," *IEEE Trans. Power Syst.*, vol. 26, no. 1, pp. 20–29, Feb. 2011.
- [14] C. M. Lee and C. N. Ko, "Short-term load forecasting using lifting scheme and ARIMA models," *Expert Syst. Appl.*, no. 38, pp. 5902–5911, 2011.
- [15] N. Amjady and F. Keynia, "Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm," *Energy*, vol. 34, pp. 46–57, 2009.
- [16] A. J. R. Reis and A. P. A. da Silva, "Feature extraction via multiresolution analysis for short-term load forecasting," *IEEE Trans. Power Syst.*, vol. 20, no. 1, pp. 189–198, Feb. 2005.
- [17] Z. A. Bashir and M. E. El-Hawary, "Applying wavelets to short-term load forecasting using PSO-based neural networks," *IEEE Trans. Power Syst.*, vol. 24, no. 1, pp. 20–27, Feb. 2009.
- [18] Z. Soozanchi-K, M. Yaghoobi, M.-R. Akbarzadeh-T, and M. Habibipour, "Modeling and forecasting short-term electricity load based on multi adaptive neural-fuzzy inference system by using temperature," in *Proc. 2010 2nd Int. Conf. Signal Processing Syst. (ICSPS)*, Jul. 5–7, 2010, vol. 3, pp. V3–18.
- [19] O. M. M. Mohamed, M. Jaidane-Saidane, J. Ezzine, J. Souissi, and N. Hizaoui, "Variability of predictability of the daily peak load using Lyapunov exponent approach: case of Tunisian power system," in *Proc. Power Tech. 2007 IEEE Lausanne*, Jul. 2007, pp. 1078–1083.
- [20] S. R. Abbas and M. Arif, "New time series predictability metrics for nearest neighbor based forecasting," in *Proc. IEEE Multitopic Conf., 2006 (INMIC '06)*, Dec. 23–24, 2006, pp. 100–105.
- [21] M. Kaboudan, "A measure of time-series predictability using genetic programming applied to stock returns," *J. Forecast.*, vol. 18, pp. 345–357, 1999.
- [22] H. Kuo, *White Noise Distribution Theory*, illustrated ed. Boca Raton, FL, USA: CRC, 1996, pp. 1–2.
- [23] S. Fan, M. Kittipong, and W.-J. Lee, "Multiregion load forecasting for system with large geographical area," *IEEE Trans. Ind. Appl.*, vol. 45, no. 4, pp. 1452–1459, 2009.
- [24] S. Fan, L. Chem, and W.-J. Lee, "Short-term load forecasting using comprehensive combination based on multimeteorological information," *IEEE Trans. Ind. Appl.*, vol. 45, no. 4, pp. 1460–1466, 2009.
- [25] Y. Chen, P. B. Luh, C. Guan, Y. Zhao, L. D. Michel, M. A. Coolbeth, P. B. Friedland, and S. J. Rourke, "Short-term load forecasting: Similar day-based wavelet neural networks," *IEEE Trans. Power Syst.*, vol. 25, no. 1, pp. 322–330, Feb. 2010.

[26] ISO NE, Hourly Load Data. [Online]. Available: [http://www.iso-ne.com/markets/hstdata/znl\\_info/hourly/index.html](http://www.iso-ne.com/markets/hstdata/znl_info/hourly/index.html).



**Miguel López García** received the M.Eng. degree in industrial technologies from the Miguel Hernández University of Elche, Spain, in 2010. Currently, he is pursuing the Ph.D. degree from the UMH of Elche.

Before starting his career in research, he worked as a manufacturing engineer from 2005 to 2009.



**Carolina Senabre** received the engineering degree in 1998 from the Universidad Politécnica de Valencia and the Ph.D. degree in 2012 from the University of Elche.

In 2001 she became an Associated Professor in Mechanical Engineering at the Universidad Miguel Hernández.



**Sergio Valero** (M'09) was born in Elche, Spain, in 1974. He received the industrial engineering degree in 1998, from the Universidad Politécnica de Valencia and the Ph.D. degree from the Universidad Miguel Hernandez, Elche, Spain, in 2007.

Currently, he is an Associated Professor at the Universidad Miguel Hernández de Elche, Spain. His research activities include distribution system analysis and neural network applications in power systems.



**Antonio Gabaldón Marín** (M'96) was born in Cieza, Spain, in 1964. He received the industrial engineering and Ph.D. degrees from the Universidad Politécnica de Valencia, in 1988 and 1991, respectively.

Currently, he is a Full Professor at the Universidad Politécnica de Cartagena, Cartagena, Spain. His research activities include distribution system analysis, electricity markets and demand-side management and response.







# Bibliografía

- [1] A.D. Papalexopoulos, T.C. Hesterberg, "A regression-based approach to short-term system load forecasting," *IEEE Transactions on Power Systems* 5 (November (4)) (1990) 1535–1547.
- [2] T. Haida, S. Muto, "Regression-based peak load forecasting using a transformation technique," *IEEE Transactions on Power Systems* 9 (4) (1994) 1788–1794.
- [3] M.T. Hagan, S.M. Behr, "The time series approach to short-term load forecasting," *IEEE Transactions on Power Systems PWRS-2* (August (3)) (1987) 785–791.
- [4] S.J. Kiartzis, A.G. Bakirtzis, V. Petridis, "Short-term load forecasting using neural networks," *Electric Power Systems Research* 33 (April (1)) (1995) 1–6.
- [5] M. Sforna, F. Proverbio, "A neural network operator oriented short-term and online load forecasting environment," *Electric Power Systems Research* 33 (May(2)) (1995) 139–149.
- [6] P. Mandal, T. Senjyu, N. Urasaki, T. Funabashi, "A neural network based severalhour-ahead electric load forecasting using similar days approach," *Electrical Power & Energy Systems* 28 (2006) 367–373.
- [7] T. Yalcinoz and U. Eminoglu, "Short term and medium term power distribution load forecasting by neural networks," *Energy Convers. Manage.*, vol. 46, pp. 1393–1405, 2005.
- [8] Y. Chen, P. B. Luh, C. Guan, Y. Zhao, L. D. Michel, M. A. Coolbeth, P. B. Friedland, and S. J. Rourke, "Short-term load forecasting: Similar day-based wavelet neural networks," *IEEE Trans. Power Syst.*, vol. 25, no. 1, pp. 322–330, Feb. 2010.
- [9] K. Kalaitzakis, G.S. Stavrakakis, E.M. Anagnostakis, "Short-term load forecasting based on artificial neural networks parallel implementation," in *Electric Power Systems Research*, Volume 63, Issue 3, Pages 185-196, ISSN 0378-7796, October 2002

- [10] Y.M. Wi, S.K. Joo, and K.B. Song, "Holiday load forecasting using fuzzy polynomial regression with weather feature selection and adjustment," *IEEE Trans. Power Syst.*, vol. 27, no. 2, pp. 596–603, May 2012.
- [11] Z. Soozanchi-K, M. Yaghibi, M.-R. Akbarzadeh-T, and M. Habibipour, "Modeling and forecasting short-term electricity load based on multi adaptive neural-fuzzy inference system by using temperature," in *Proc. 2010 2nd Int Conf. Signal Processing Syst. (ICSPS)*, Jul. 5–7, 2010, vol. 3, pp. V3–18.
- [12] Yun, Z., Quan, Z., Caixin, S., Shaolan, L., Yuming, L., Yang, S., "RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment, " in *Power Systems, IEEE Transactions on*, 23 (3), pp. 853-858, 2008
- [13] Yang Wang; Qing Xia; Chongqing Kang, "Secondary Forecasting Based on Deviation Analysis for Short-Term Load Forecasting," in *Power Systems, IEEE Transactions on* , vol.26, no.2, pp.500-507, May 2011
- [14] Espinoza, M.; Suykens, J.A.K.; Belmans, R.; De Moor, B., "Electric Load Forecasting," in *Control Systems, IEEE* , vol.27, no.5, pp.43-57, Oct. 2007
- [15] Elattar, E.E.; Goulermas, J.; Wu, Q.H., "Electric Load Forecasting Based on Locally Weighted Support Vector Regression," in *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on* , vol.40, no.4, pp.438-447, July 2010
- [16] N. Amjady, F. Keynia, "Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm," *Energy* 34 (2009) 46–57.
- [17] G.-C. Liao, T.-P. Tsao, "Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting," *IEEE Transactions on Evolutionary Computation* 10 (3) (2006) 330–340.
- [18] Hinojosa, V.H.; Hoese, A., "Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms," in *Power Systems, IEEE Transactions on* , vol.25, no.1, pp.565-574, Feb. 2010
- [19] Z.A. Bashir, M.E. El-Hawary, "Applying wavelets to short-term load forecasting using PSO-based neural networks," *IEEE Transactions on Power Systems* 24 (February (1)) (2009) 20–27.
- [20] C.-i. Kim, I.-k. Yu, Y.H. Song, "Kohonen neural network and wavelet transform based approach to short-term load forecasting," *Electric Power Systems Research* 63 (2002) 169–176.
- [21] C. M. Lee and C. N. Ko, "Short-term load forecasting using lifting scheme and ARIMA models," *Expert Syst. Appl.*, no. 38, pp. 5902–5911, 2011.

- [22] A. J. R. Reis and A. P. A. da Silva, "Feature extraction via multiresolution analysis for short-term load forecasting," *IEEE Trans. Power Syst.*, vol. 20, no. 1, pp. 189–198, Feb. 2005.
- [23] Rana, Mashud, and Irena Koprinska. "Wavelet Neural Networks for Electricity Load Forecasting—Dealing with Border Distortion and Shift Invariance." Proceedings of the 23rd International Conference on Artificial Neural Networks and Machine Learning—ICANN 2013-Volume 8131. Springer-Verlag New York, Inc., 2013.

