

# PREDICCIÓN A CORTO PLAZO DE LA DEMANDA DE ENERGÍA EN CENTROS DE TRANSFORMACIÓN DE BAJA TENSIÓN USANDO SISTEMAS DE INFERENCIA DIFUSA OPTIMIZADOS GENÉTICAMENTE

A. Yanguas-Peña, M. Mendoza-Villena, A. Falces-De Andrés, P. Lara-Santillán, E. García-Garrido, E. Zorzano-Alba

Departamento de Ingeniería Eléctrica  
E.T.S.I.I., Universidad de La Rioja

C/ Luis de Ulloa, 20; 26002 Logroño, La Rioja (España)

Tel.: +34 941 299477, Fax: +34 941 299478, e-mail: montserrat.mendoza@unirioja.es

## Resumen.

Entre las características principales de un sistema de energía eléctrica están las de abastecer a todos los puntos de carga con una buena calidad de servicio y la de operar con los mínimos costes económicos. Estas características pueden obtenerse con una planificación exhaustiva del sistema, no sólo para conocer y optimizar su estado actual, sino también las medidas que puedan adoptarse para alcanzar condiciones futuras.

Una de las herramientas necesarias para esta planificación es la previsión del consumo de energía a corto plazo, que permite conocer las necesidades de generación del sistema y facilita la planificación de la operación del mismo. Por otra parte, estimaciones parciales en nudos de media tensión, tales como subestaciones y CTs, ayudan a obtener un panorama más exacto sobre la demanda en toda la red.

Este artículo presenta los resultados obtenidos con modelos de predicción de la demanda para un centro de transformación real situado en un núcleo urbano. Los valores de predicción corresponden a la energía eléctrica demandada para las 24 horas y el pico de demanda del día siguiente. Los modelos desarrollados están basados en sistemas de inferencia difusa, optimizados mediante un algoritmo genético, y superan los resultados obtenidos con un conjunto de modelos clásicos de predicción.

## Palabras clave

Predicción a corto plazo, demanda en CT, algoritmos genéticos, sistemas de inferencia difusa.

## 1. Introducción

La previsión de la demanda de cualquier producto o servicio intenta revelar las necesidades futuras de una población. Esta previsión debe ser lo más ajustada a la realidad, ya que unos valores inferiores a los reales causarán deficiencias en la prestación del servicio en el futuro, y un pronóstico de necesidades superior al real motiva la inversión prematura en instalaciones que no tendrán un aprovechamiento inmediato.

La predicción de la demanda de energía eléctrica se utiliza fundamentalmente para planificar la generación, la compra y utilización de combustibles, la agenda de mantenimiento [1] y realizar análisis de seguridad. Los errores de predicción pueden implicar errores de planificación significativos, con su coste económico asociado.

Además, la previsión de la demanda eléctrica ayuda a estimar los flujos de carga y a tomar decisiones que puedan evitar las sobrecargas. Implementar la toma de decisiones a tiempo hace que se mejore la robustez de la red, y que se reduzcan los incidentes de fallos de equipos y caídas del sistema [2].

Por otra parte, la expansión de las técnicas de gestión en los sistemas de distribución ponen en evidencia la necesidad de buenas estimaciones de consumo en los nudos de las redes de media tensión, así como la capacidad de prever a 24 horas vista, las curvas de consumo de baja tensión que se producen en los centros de transformación, ya que ambas son de gran importancia en la planificación y funcionamiento de los sistemas de distribución [3]. Otra consideración a tener en cuenta es que los nuevos avances en tecnologías de microgeneración, han llegado a definir el concepto de microgrid, es decir, una red de consumidores y productores de baja tensión capaz de exportar energía eléctrica a las redes de distribución eléctrica [4]. Las microgrids también pueden operar en situaciones de emergencia aisladas de la red de distribución. Pero, en ambos casos (conectada o aislada), es necesario tener previsiones fiables de la demanda y de la generación de energía.

En cuanto al nivel de exactitud aceptable de una previsión, es obvio que depende de las características de operación de la instalación. Los efectos de predicciones de consumo erróneas también dependen del tipo de día (día laboral o fin de semana), la hora del día y el tipo de consumidores [5]. El impacto económico de un pequeño error de previsión puede significar la necesidad de poner en marcha una unidad extra de generación de energía en

una instalación local. Sin embargo, esto no tendría gran significación si simplemente se requiere un pequeño incremento en una unidad de generación ya operativa.

En un estudio realizado sobre el impacto económico de la predicción de potencia eléctrica en las empresas [6], se apunta que conseguir unos valores de error de estimación en torno al 5% es bastante satisfactorio, ya que los beneficios obtenidos de reducir los valores de error en este margen serán pequeños, mientras que sucede lo contrario en los valores de error superiores al 5%, donde el coste económico se dispara, tal y como se muestra en el siguiente gráfico.




Fig 1. Relación error predicción – Impacto económico.

## 2. Modelos de predicción

El objetivo perseguido con el trabajo de investigación descrito en el presente artículo, es el desarrollo de un modelo óptimo para la predicción del valor máximo y el consumo medio para todas las horas del día siguiente para un centro de transformación real situado en el centro de la ciudad de Logroño. Este centro de transformación suministra energía eléctrica en baja tensión a unos 400 clientes, representando un consumo urbano medio de la ciudad (combinado de abonados domésticos, locales comerciales y de hostelería).

Así, se ha desarrollado una metodología para la optimización de modelos de inferencia difusa como modelos de predicción tanto del pico de la potencia demandada para el día siguiente como de la potencia media horaria para las 24 horas del día siguiente. El proceso de optimización selecciona las entradas utilizadas por el modelo de entre un conjunto de variables disponibles y selecciona también los parámetros que configuran el sistema de inferencia difusa que ofrece los mejores resultados como modelo de predicción; por tanto, se centra no tanto en el proceso de clusterización [7] como en las variables que han de regir el mismo.

### A. Algoritmos genéticos

Los algoritmos genéticos pueden encuadrarse dentro la clase de métodos estocásticos de búsqueda [8]. Mientras la mayoría de estos métodos operan sobre una única solución [7], estos algoritmos operan en una población de soluciones. La idea básica, inspirada en los procesos evolutivos biológicos, es que el contenido genético de

una población contiene potencialmente la solución, o una solución mejor, a un problema dado de adaptación.

Su aplicación está enfocada sobre todo a espacios de búsqueda grandes, complejos y poco entendidos. La idea básica de un algoritmo genético es la siguiente: Generar inicialmente un conjunto con algunas de las posibles soluciones o *individuos*, denominado *población*. Una vez constituida la población inicial esta irá evolucionando de acuerdo a la evaluación que se haga de cada individuo, obteniéndose nuevos individuos (nuevas generaciones) asociados a soluciones mejores.

La información asociada a un individuo se compone de partes indivisibles denominadas  *cromosomas*. Cada cromosoma tiene varios genes, que corresponden a sendos parámetros del problema. Para poder trabajar con estos genes en un programa informático es necesario codificarlos en una cadena numérica o alfanumérica.

Durante la evaluación se decodifica el gen y se convierte en una serie de parámetros del problema cuya solución se pretende optimizar. Luego se halla la solución del problema a partir de esos parámetros y se le da una puntuación en función de lo cerca que esté de la mejor solución. A esta puntuación se le llama *fitness*.

Después de haber codificado las variables y haber definido el método de selección, el algoritmo genético procede de la siguiente manera:

1. Se generan aleatoriamente una serie de individuos (cromosomas).
2. Se evalúa la puntuación de cada uno de ellos.
3. Se permite a cada uno de los individuos reproducirse de acuerdo con su puntuación.
4. Se empareja a los individuos haciendo que intercambien material genético (operación de cruce o cross-over) y que alguno de los caracteres de un gen se vea alterado debido a una mutación espontánea (operación mutación). El resultado es la creación de una nueva generación de individuos.

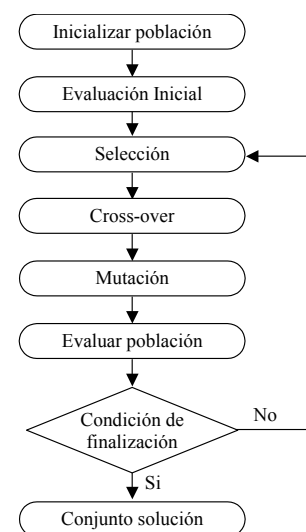


Fig 2. Diagrama funcionamiento algoritmo genético.

Un algoritmo genético también tiene parámetros que se tienen que fijar para cada ejecución:

- *Tamaño de la población:* debe de ser suficiente para garantizar la diversidad de las soluciones y tiene que crecer más o menos con el número de caracteres del cromosoma.
- *Condición de terminación:* lo más habitual es que sea la convergencia del algoritmo genético o un número prefijado de generaciones. Esta última será la condición de nuestro estudio.

El diagrama general de funcionamiento de un algoritmo genético es el representado en la Figura 2.

### B. Sistemas de inferencia difusa

Las técnicas de inferencia difusa proporcionan un método para el proceso de modelado fuzzy. Además, una vez construido un sistema de inferencia difusa, pueden utilizarse técnicas neurodifusas [9], [10], similares a las utilizadas en el entrenamiento de redes neuronales artificiales, para adaptar los parámetros de las funciones de pertenencia y de las reglas del sistema que permitan la mejor adecuación entre la salida del sistema y salida deseada. Es decir, usando un conjunto de datos de entrada y salida podemos construir un sistema de inferencia difusa cuyas funciones de pertenencia y coeficientes de las reglas se ajustan usando un algoritmo de retro-propagación de error, solo o en combinación con la técnica de mínimos cuadrados, dotando al sistema de la capacidad de aprender.

La estructura de funcionamiento de este modelo es primeramente, clasificar las entradas mediante funciones de pertenencia y sus parámetros asociados, estudiar el modelo, y finalmente generar unas funciones de pertenencia de salida, a partir de los cuales obtenemos los resultados de salida. Los parámetros asociados con las funciones de pertenencia y los coeficientes de las reglas cambian a lo largo del proceso de aprendizaje. El cálculo de estos, es proporcionado por un vector gradiente, que realiza una medida de como el sistema de inferencia difusa está modelizando los datos de entrada-salida, para un conjunto de parámetros dado. Por tanto, cuanto más se parezcan las funciones de pertenencia iniciales a las óptimas, mejor convergerá el entrenamiento hacia el punto óptimo en el espacio de parámetros. Una vez que se obtiene el vector gradiente, pueden aplicar varias rutina de optimización para ajustar los parámetros que reduzcan las medidas de error (normalmente mínimos cuadrados). Además, se utiliza conjuntamente el método retro-propagación (backpropagation) para la estimación de los valores de las funciones de pertenencia.

El agrupamiento (clusterizado) substractivo [11], es una técnica que estima los centros de los grupos en un conjunto de datos, para ello, asume que cada punto-dato es un centro de grupo en potencia, y le asigna un potencial basándose en la densidad de puntos que le rodean. El algoritmo, selecciona el punto-dato con mayor potencial como primer centro de grupo, y después, borra el potencial de los puntos-dato cercanos a dicho primer

centro de grupo. A continuación, el algoritmo selecciona el punto-dato con el mayor potencial remanente como siguiente centro de grupo y vuelve a destruir los potenciales de los datos en su zona de influencia. Y así sucesivamente. El ciclo iterativo termina cuando el potencial de todos los puntos cae por debajo de un umbral. El algoritmo substractivo necesita cuatro parámetros: el valor del radio que define la influencia (o vecindad), el valor del radio que define la zona de reducción de potencial cuando se ha escogido un centro, un factor de representa el umbral de aceptación como centro (son aceptados aquellos posibles centros con potencial superior al del primer centro multiplicado por este factor), y otro factor que representa el umbral de rechazo como centro.

### C. Datos de entrada para los Modelos de Predicción

Una de las más importantes tareas en la construcción de un modelo, es la selección de las variables de entrada relevantes. Desafortunadamente, no hay un método sistemático a seguir. Sin embargo, una solución práctica aceptable consiste en el proceso de iteración de prueba y error, donde se añaden algunas nuevas variables o se substraen otras irrelevantes para obtener un modelo mejor. En este contexto, la teoría de regresión lineal puede aportar información relevante. Así, se han propuesto métodos automáticos de poda, que hacen posible que, empezando de un modelo que contiene todas las variables de entrada posible, se descarten aquellas irrelevantes mediante un análisis de sensibilidad.

Un planteamiento distinto es el que se ha seguido en este trabajo. Es el proceso de optimización, controlado por algoritmo genético, el que selecciona las variables de entrada a los sistemas de inferencia difusa de entre todas las variables de entrada disponibles. Las entradas disponibles son las siguientes:

- E1.- Día de la semana (lunes, martes...).
- E2.- Potencia máxima consumida día anterior.
- E3.- Potencia máxima consumida dos días antes.
- E4.- Temperatura media para el día siguiente.
- E5.- Temperatura media día anterior.
- E6.- Temperatura máxima para el día siguiente.
- E7.- Temperatura mínima para el día siguiente.
- E8.- Humedad relativa (%) para el día siguiente.
- E9.- Radiación solar (W/m<sup>2</sup>) para el día siguiente.
- E10.- Velocidad del Viento (m/s) para el día siguiente.

La salida son los datos de consumo reales del centro de transformación.

### D. Consideraciones previas

En nuestro estudio comprobaremos que los resultados de predicción obtenidos no son tan buenos como los que se podrían obtener si el objeto de estudio fuera una red eléctrica de mayores dimensiones, donde los errores asociados a CTs individuales pueden compensarse mutuamente y reducir el error total. Ya que el centro de transformación objeto de nuestro estudio dispone de unos 400 usuarios, localizados en unos pocos bloques de

viviendas en el centro urbano, sus patrones de consumo experimentan grandes variaciones a lo largo de las horas del día, y entre unos días u otros.

En las Figuras 3 y 4 podemos comparar las variaciones porcentuales de la demanda media a lo largo de los días de una semana entre ambos ámbitos de estudio.



Fig 3. Desvío porcentual en función de la hora. Red eléctrica extensa.

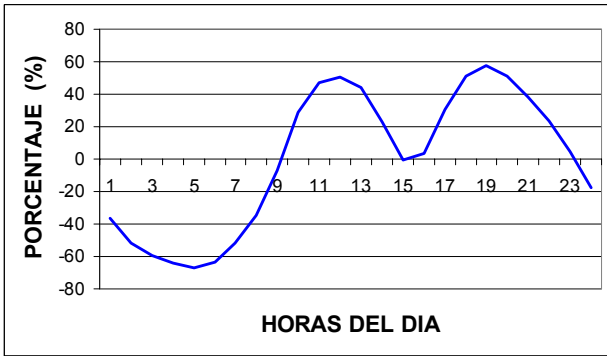


Fig 4. Desvío porcentual en función de la hora. CT de Logroño.

Comparando ambas figuras, se pueden observar las considerables diferencias entre los valores de variación en una red eléctrica de tamaño medio (Fig. 3), con diferentes tipos de clientes (empresas de producción, de servicios, alumbrado público, particulares, etc.) donde las diferencias de consumo entre horas respecto al consumo medio, tienen valores máximos de un 15%, mientras que en un centro de transformación con un número limitado de clientes, las variaciones horarias respecto al consumo medio llegan a superar el 60%.

Aunque estas diferencias de consumo horario influyen de manera negativa en el estudio del modelo, obteniendo peores resultados que en sistemas eléctricos de mayor tamaño, el modelo de la red como suma de CTs permite mejorar sustancialmente.

#### E. Criterios de evaluación de los Modelos de Predicción

La adecuación de los modelos no se evalúa con los datos utilizados en su ajuste o entrenamiento, sino con otro conjunto de valores (valores de test) de las variables explicativas (Fig 4X). Esta prueba permite la comparación de los resultados (valores de predicción) entre diferentes modelos y de esta forma seleccionar el modelo que arroje

los menores errores de predicción. La figura 5 representa como se utilizan los datos.




Fig 5. Utilización de los datos en la generación de modelos.

Para la comparación general entre los modelos a la hora de su optimización con el algoritmo genético, se ha usado la raíz del error cuadrático medio, **RMSE**.

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N E_t^2} \quad (1)$$

Por otro lado, para comprobar la adecuación del modelo final obtenido y comprobar los resultados obtenidos con los datos reales, calcularemos el error absoluto porcentual de la media, **MAPE**.

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{E_t}{Y_t} \right| \quad (2)$$

Donde  $E_t$  es el error de predicción del período  $t$  ( $E_t = Y_t - F_t$ ),  $Y$  es el valor real para ese período y  $F_t$  el valor que se había pronosticado.

#### F. Datos utilizados en la creación de los modelos

Los datos disponibles como entradas de los modelos de predicción corresponden a predicciones meteorológicas, para el día siguiente, referidas a dos años (2004 y 2005), para la ciudad de Logroño, y los datos de consumo de energía eléctrica proporcionados por el centro de transformación ubicado en el centro de Logroño y para el mismo periodo de tiempo.

Para el desarrollo de los modelos de predicción, los datos referidos se han dividido en tres grupos, entrenamiento, validación cruzada y test.

- Entrenamiento: el primer 60 % de los datos de los dos años.
- Validación: el siguiente 20% de los datos .
- Test: el 20% restante de los datos.

#### G. Solución adoptada

Inicialmente todos los datos de entrada disponibles son normalizados a valores comprendidos entre 0 y 1, para poder aplicar sobre ellos la técnica de la clusterización subtractiva, que supone que todos los datos que el rango de valores en cada dimensión (entrada en este caso) es el mismo. Para este algoritmo se toman constantes los valores de umbral de aceptación y de rechazo, con valores de 0.5 y 0.15, respectivamente. Únicamente se va a variar el radio de influencia, con valores entre 0 y 2,

haciendo que el radio que define la reducción de potencial sea 1.25 veces mayor que el radio de influencia.

La estructura empleada para el cromosoma, que contiene toda la información necesaria para la creación del sistema de inferencia difusa que se va a utilizar como modelo de predicción, es la recogida en la figura 6. Cada cromosoma (o individuo) es una cadena de 18 dígitos con valores de 0 a 9. Cada uno de los 10 primeros dígitos de la cadena que corresponde al cromosoma (de  $d_1$  a  $d_{10}$ ) representa a una de las variables de entrada disponibles. El significado del valor de estos dígitos es: Si es mayor o igual que 5 la entrada correspondiente se utiliza como entrada del modelo de inferencia difusa; si, por el contrario, el dígito correspondiente es menor que 5, la entrada no se utiliza como tal en el modelo de inferencia difusa. Los siguientes 8 dígitos de la cadena (de  $d_{11}$  a  $d_{18}$ ) que representa el cromosoma corresponden al radio de influencia para el algoritmo substractivo de agrupamiento de los datos de las entradas seleccionadas para el modelo. El valor numérico de este radio se obtiene multiplicando por  $2E-8$  el valor numérico representado por esos 8 dígitos. Así, si el cromosoma contiene la cadena numérica "158223943122371901" el significado de la misma es que las entradas seleccionadas para el modelo de inferencia difusa son las E2, E3 y E7 (al ser mayores o iguales a 5 los dígitos segundo, tercero y séptimo) y el valor del radio de influencia para el algoritmo substractivo es 0.44743802.




Fig. 6. Estructura del cromosoma (individuo).

Para el operador de mutación se ha realizado una ligera modificación cuando el dígito afectado corresponde a los que representan a las entradas disponibles: una mutación en uno de estos dígitos se traduce en incrementar en cinco unidades dicho dígito, si este era originalmente menor que 5, o decrementarlo en cinco unidades si originalmente era mayor o igual a 5.

Una vez construido un nuevo cromosoma para la nueva generación, en primer lugar se determina si por lo menos ha seleccionado a una de las entradas de entre las disponibles. Si no es así (los 10 primeros dígitos serían menores a 5), se crea un nuevo individuo por cruce y/o mutación hasta conseguir un cromosoma válido.

Con la información contenida en el cromosoma, se crea el sistema de inferencia difusa. El sistema resultante consta de tantas reglas y familias de pertenencia por entrada como grupos obtenidos por aplicación del algoritmo de clusterización substractiva sobre las entradas seleccionadas para el sistema. Si el número de grupos y, por tanto, de reglas es mayor que 5 el sistema de inferencia correspondiente no es evaluado y se le otorga un valor de error RMSE elevado. La función de *fitness* seleccionada es la inversa del error RMSE con los datos del grupo de validación cruzada. Si el número de reglas del sistema de inferencia difusa es menor o igual a 5, el sistema es entrenado como sistema neurofuzzy adaptativo [9] con los datos del grupo de entrenamiento

de las entradas seleccionadas. El proceso de entrenamiento se interrumpe cuando el error RMSE con los datos del grupo de validación cruzada no mejoran tras 50 epochs (iteraciones de entrenamiento); en todo caso, el valor de los parámetros del sistema de inferencia difusa resultante son los que corresponden al mínimo error RMSE con los datos del grupo de validación cruzada. Una vez entrenado el sistema, se toma como valor de *fitness* a la inversa del error RMSE con los datos de este grupo de validación cruzada.

El proceso de optimización fue programado en Matlab, haciendo uso de las funciones de la Fuzzy Toolbox del mismo.

#### H. Resultados obtenidos

Los resultados obtenidos tras el proceso de optimización del modelo de predicción proporciona los siguientes parámetros: las entradas consideradas en ese modelo, el número de reglas de inferencia, y el valor del radio de del algoritmo de clusterización substractiva. Además nos proporciona los valores RMSE de los valores de testeo con los valores reales.

### 3. Modelo de Previsión de Potencia Máxima demandada a 24 horas vista.

#### A. Modelos de Predicción analizados

En primer lugar, a la hora de realizar un correcto estudio de los datos aportados, se debe separar los mismos teniendo en cuenta los diferentes días de la semana, los días festivos del calendario de dichos años, y los puentes vacacionales propios de la zona de suministro. Si comparamos los consumos de potencia de un mes cualquiera, y los dividimos en función del día de la semana a que pertenecen, obtenemos patrones de comportamiento en el consumo de energía con diferencias acusadas dependiendo de si es un día laboral o un día de fin de semana.

El número de generaciones e individuos por generación, para el algoritmo genético, se ha limitado a 50. La tasa de cruce se ha fijado en el 80% y la tasa de mutación en el 2%. También se ha aplicado elitismo: de una generación a otra se conserva el mejor (menor error RMSE) individuo de la generación anterior. Con esto último conseguimos que no empeore el resultado obtenido por el mejor individuo de una generación a otra.

En un estudio inicial no separamos los datos por sus diferentes patrones de consumo o días, sino que tomamos todos los datos en su conjunto y estudiamos el sistema. Como resultado, obtenemos la evolución en la búsqueda del modelo óptimo representada en la figura 7.




Fig. 7. Diagrama relación número de generación – RMS.

En la figura 7 comprobamos que el modelo óptimo se encuentra aproximadamente en la generación 16, y aunque las iteraciones nos lleven hasta la generación 50, éste no varía, puesto que no encuentra un modelo mejor al ya obtenido.

A continuación en nuestro estudio separamos los datos y por tanto, los modelos de previsión en dos grupos de acuerdo con los patrones de consumo de los clientes del centro de transformación. El primero formado por los días laborables y el segundo, por los días de fin de semana. De esta manera conseguimos mayor precisión en la predicción de los consumos.

Los resultados obtenidos y los parámetros en los modelos óptimos para la previsión de demanda eléctrica son los reflejados en la tabla 1. Las variables de entrada (E1, E2,...) se corresponden con las enunciadas en el apartado 1, subapartado C. Como podemos observar los resultados obtenidos al separar los datos en dos grupos de días, en función de sus patrones de consumo, nos han proporcionado unos valores mejores que si los consideramos conjuntamente, ya que conseguimos bajar de un error MAPE del 6,47% a errores de 5,56% y 4,24%.

Este mismo sistema de separación de datos en función de sus patrones de consumo se ha realizado, todavía con mayor razón, en los modelos de previsión horaria, ya que las variaciones de consumo a lo largo del día y entre diferentes tipos de día, ocasionan mayores errores de predicción.

#### 4. Modelo de Predicción de Potencia Media Horaria demandada a 24 horas vista.

El proceso de búsqueda del sistema óptimo de predicción, está basado en el mismo procedimiento que en el apartado anterior. Es decir, inicialmente se recopilan las variables de entrada; en nuestro caso hemos considerado todas las variables disponibles y que puedan afectar de alguna manera a la solución.

Los datos con los que debemos trabajar en este apartado, presentan una dificultad mayor que los analizados en el apartado anterior, ya que si bien antes la potencia

máxima consumida, variaba con los días, en esta ocasión se producen cambios importantes, no sólo dependiendo de los diferentes días, sino también durante las 24 horas del día. Es decir, no sólo debemos trabajar con muchos más datos (24 veces más), sino que los consumos horarios, aunque siguen patrones bastante determinados, presentan más irregularidades que la potencia máxima consumida, la cual se da normalmente en las mismas horas del día.

Tabla 1. Previsión Potencia Máxima Demandada.

Días	MAPE (%)	Entradas	Reglas	Variables de entrada
Todos	6.4701	6	3	E1, E2, E3, E4, E8, E10
Laborables	5.5611	5	3	E3, E4, E8, E9, E10
Fin de semana	4.2408	4	3	E3, E5, E8, E10

Una vez analizadas las curvas de demanda de energía de nuestro centro de transformación, observamos como los martes, miércoles y jueves, siguen el mismo patrón de consumo, variando notablemente en los días de fin de semana, y durante las primeras horas del lunes. Como consecuencia de estas variaciones, se optó por desarrollar diferentes modelos de predicción en función de la agrupación de los días de la semana, de la siguiente manera: grupo 1: lunes; grupo 2: martes-miércoles-jueves; grupo 3: viernes; grupo 4: sábado; y grupo 5: domingos. De esta forma conseguimos unos mejores resultados de predicción.

Al igual que se hizo con el modelo de predicción del pico de la potencia consumida, se realizó una prueba inicial con desarrollando un modelo para todos los días en conjunto y analizamos los valores obtenidos en función de las horas del día analizados en él. Los resultados se muestran en la figura 8. Como se aprecia en la Figura, los mayores errores se dan en las horas de madrugada coincidentes lógicamente con las mayores bajadas de consumo respecto a la media diaria.




Fig. 8. Error MAPE clasificado por horas del total de días.

Posteriormente se desarrolló, con la metodología descrita, un modelo de predicción distinto para los cinco grupos en los que han dividido los datos en función del tipo de día. En la Tabla 2 se muestra los resultados obtenidos para el grupo de test señalando sus valores de error MAPE, el número de variables de entradas que el modelo

óptimo considera en su análisis, y el número de reglas del sistema difuso obtenido.

En estos sistemas, las variables de entrada consideradas varían ligeramente de las entradas del apartado anterior, y son:

- E1- Hora del día correspondiente al horizonte de predicción.
- E2- Potencia demandada el último día a la misma hora.
- E3- Potencia demandada a la misma hora dos días antes.
- E4- Temperatura media prevista para el día siguiente.
- E5- Temperatura media el último día.
- E6- Temperatura máxima prevista para el día siguiente.
- E7- Temperatura mínima prevista para el día siguiente.
- E8- Humedad relativa (%) prevista para el día siguiente.
- E9- Radiación (W/m<sup>2</sup>) prevista para el día siguiente.
- E10- Velocidad viento (m/s) prevista para el día siguiente.

Tabla 2. Previsión Potencia Horaria Demanda.

Días	MAPE (%)	Entradas	Reglas	Variables de entradas
Lunes	6.9356	3	3	E1,E2,E7
Martes – Miércoles- Jueves	8.0845	7	3	E1, E2, E3, E4, E7, E8, E9
Viernes	6.3656	7	5	E1, E2, E3, E6, E8, E9, E10
Sábado	6.5384	8	5	E1, E2, E3, E5, E6, E7, E8, E10
Domingo	5.7191	6	5	E1, E2, E3, E4, E7, E9

## 5. Conclusiones

En este artículo se ha mostrado los diferentes modelos de predicción de demanda eléctrica para un centro de transformación real y concreto. Se han desarrollado diferentes modelos de predicción para la potencia máxima demanda y para la potencia media horaria para las 24 horas del día siguiente. Todos los modelos se han obtenido mediante un proceso de optimización controlado por un algoritmo genético.

Analizado los resultados obtenidos comprobamos que los valores de error MAPE obtenidos están entre un 5% y un 8%, por lo que podemos concluir que son unos errores de previsión muy aceptables dadas las grandes variaciones de consumo debido a tratarse sólo de un centro de transformación.

La principal ventaja que proporciona la metodología descrita de optimización de un sistema de inferencia difusa para su uso como modelo de predicción de la potencia demanda en un centro de transformación se centra en la selección automática de los parámetros del

sistema. El método seguido permite la selección de las variables de entrada de entre un conjunto de variables disponibles y selecciona los parámetros que determinan, junto con los datos de entrada, las características del sistema de inferencia difusa (número de reglas y número de funciones de pertenencia). El resultado, tras el proceso de optimización, es el modelo de predicción que mejores resultados ofrece en la predicción de la potencia demandada.

## Agradecimientos

Los autores agradecen el apoyo prestado por el Gobierno de La Rioja al financiar este trabajo bajo el proyecto de investigación FOMENTA 2008/9. Asimismo, agradecen a Iberdrola la ayuda prestada para la realización de las medidas que han servido de base a este estudio.

## Referencias

- [1] J.A. Jardini, H.P. Schmidt, C.M.V. Tahan, C.C.B. de Oliveira, S.U. Ahn, "Distribution Transformer Loss of Life Evaluation: A Novel Approach Based on Daily Load Profiles", IEEE Transactions on Power Delivery, VOL. 15, NO. 1, pp 361-366 January 2000.
- [2] S.C. Pandian *et al.*, "Fuzzy approach for short term load forecasting", Electric Power Systems Research, Vol. 76, pp 541-548, 2006.
- [3] T. Konjic, V. Miranda, I. Kapetanovic, "Fuzzy Inference Systems Applied to LV Substation Load Estimation", IEEE Trans. on Power Systems, Vol. 20, No. 2, pp. 742-749, May 2005.
- [4] P.M. Costa, M.A. Matos, "Assessing the contribution of microgrids to the reliability of distribution networks", Electric Power Systems Research, Vol. 79, pp. 382-389, January 2009.
- [5] J.A. Jardini, C.M.V. Tahan, M.R. Gouvea, S. U. Ahn, F.M. Figueiredo, "Daily Load Profiles for Residential, Commercial and Industrial Low Voltage Consumers", IEEE Transactions on Power Delivery, VOL. 15, NO. 1, pp 375-380 January 2000.
- [6] D.K. Ranaweera *et al.*, "Economic impact analysis of load forecasting", IEEE Trans. on Power Systems, Vol. 12, No 3, pp. 1388-1392, August 1997.
- [7] W. Li, J. Zhou, X. Xiong, J. Lu, "A Statistic-Fuzzy Technique for Clustering Load Curves", IEEE Transactions on Power Systems, VOL. 22, NO. 2, pp 890-891, May 2007.
- [8] D.E. Goldberg, "Genetic algorithms in search, optimization and machine learning", Addison-Wesley, Reading, Massachusetts, 1989.
- [9] J.S.R. Jang, C.T. Sun and E. Mizutani, "Neuro-Fuzzy and Soft Computing", Prentice Hall, Englewood Cliffs, NJ, 1997.
- [10] T. Senjyu, P. Mandal, K. Uezato, T. Funabashi, "Next Day Load Curve Forecasting Using Hybrid Correction Method", IEEE Transactions on Power Systems, VOL. 20, NO. 1, pp 102-109, February 2005.
- [11] S. Chiu, "Fuzzy model identification based on cluster estimation", Journal of Intelligent and Fuzzy Systems, Vol. 2, pp. 267-278, 1994.