

## Estudio de la mejora de modelos de comportamiento de variables energéticas mediante Committee Machine de redes neuronales

Alain Porto

IK4-Ideko, Arriaga Industrialdea 2, Elgoibar, 20870, Spain, [aporto@ideko.es](mailto:aporto@ideko.es)

Mikel Larrea, Eloy Irigoyen

DISA, EIB-1, UPV/EHU, Bilbao, 48013, {[m.larrea,eloy.irigoyen](mailto:m.larrea@ehu.eus)}@ehu.eus

### Resumen

*El presente trabajo está basado en la modelización de sistemas dinámicos no lineales utilizando diferentes técnicas. Se presentarán los modelos neuronales de dos sistemas complejos, como son el consumo de gas natural y el de electricidad. Dado que el trabajo se ha llevado a cabo con la colaboración de EDP España, desde la compañía se han determinado una serie de directrices a la hora de desarrollar el estudio, de tal modo que cubran diferentes necesidades para cada uno de los sistemas. El objetivo principal de este trabajo es estudiar qué metodología de trabajo se ajusta mejor en el proceso de modelización de los sistemas dinámicos no lineales, mediante la utilización de Redes Neuronales Artificiales, así como la búsqueda de nuevas técnicas que se puedan añadir a las herramientas de predicción que mejoren su rendimiento, como son las Comitte Machine y las operaciones de Boosting. Los resultados presentados mostrarán las mejoras logradas en la estimación de las variables energéticas por medio de estas técnicas.*

**Palabras Clave:** Redes Neuronales, Committee Machine, Boosting, Series Temporales, Sistemas Dinámicos.

### 1 INTRODUCCIÓN

Uno de los principales objetivos de una empresa suministradora de energía es disponer de unas previsiones de consumo a corto plazo fiables, con el fin de optimizar la gestión de dicho consumo mediante los recursos de los cuales dispone. Un correcto pronóstico mejora la gestión del plan de operaciones de las empresas suministradoras, tarea que se realiza no sólo en función de los recursos disponibles sino también de la demanda prevista a abastecer y del cumplimiento de los compromisos contractuales con empresas suministradoras, distribuidoras y comercializadoras.

La problemática de la predicción de energía ha sido abordada con diferentes tecnologías. Las metodologías clásicas distan de aportar una solución bien ajustada, viéndose que los modelos lineales no son capaces de representar series temporales reales que posean comportamientos no lineales, para los cuales, en muchos casos no existen suficientes leyes físicas o económicas que permitan especificar completamente un modelo estadístico para su representación (Haykin, 1994).

Las redes neuronales artificiales son técnicas no paramétricas muy utilizadas en diversos ámbitos de la ciencia e ingeniería porque permiten resolver problemas complejos, que muchas veces no son fáciles de resolver utilizando técnicas tradicionales como la regresión lineal o polinómica. Las redes neuronales permiten obtener un modelo no explícito que relaciona un conjunto de variables de salida con un conjunto de variables de entrada. Así, estos modelos permiten predecir cuál es el valor de salida, dados unos valores de entrada al modelo (Viñuela, 2004).

En el año 2017 en España, entre otros operadores se encontraba EDP Naturgas Energía, un grupo energético integral que tiene como objetivo el suministro de gas y electricidad a empresas y particulares a precios competitivos. Para ello, distribuye gas en el mercado regulado, y comercializa tanto gas, como electricidad. EDP Naturgas Energía cuenta con 425 kilómetros de gasoductos de transporte, localizados principalmente en el País Vasco, siendo el segundo transportista del mercado español en kilómetros de red. EDP Naturgas Energía prestaba servicio al cierre de 2011 a más de 963.873 puntos de suministro en el mercado regulado y a 787.800 clientes de gas en el mercado liberalizado, así como a más de 106.000 de electricidad. Lo cual la sitúa como el segundo distribuidor de gas natural del mercado español.

El presente trabajo tiene como objetivo principal la modelización de sistemas dinámicos no lineales mediante Redes Neuronales (RN), estudiando nuevas técnicas que complementen las herramientas

tradicionales de predicción, mejorando su rendimiento final. Se modelizarán dos sistemas complejos, como son el consumo de gas natural y el de electricidad. Dado que este trabajo se ha llevado a cabo con la colaboración de EDP España, el trabajo se enmarca bajo necesidades específicas para cada uno de los sistemas, por lo que han estudiado la aplicación de estas técnicas por separado.

Inicialmente, con objeto de optimizar la gestión del consumo doméstico de gas a corto plazo, se ha estudiado cómo establecer correlaciones entre el consumo de gas de clientes domésticos y comerciales, así como la estacionalidad de ese consumo y de otras variables significativas como pueden ser las condiciones meteorológicas. El ámbito geográfico sobre el que se ha realizado el estudio es el municipio de Lasarte-Oria, situado en el País Vasco. Para validar el modelo neuronal EDP España impuso como condición que dicho modelo no cometiese nunca un error en la predicción superior al 10% del consumo real. Esto se ha logrado, tal y como queda plasmado en el capítulo de resultados.

En el caso del consumo eléctrico, se definió como objetivo el obtener un modelo neuronal capaz de predecir la demanda eléctrica total de la península ibérica con un horizonte de predicción de 24h, con predicciones horarias. La empresa necesita obtener una estimación del consumo, para así poder subastar, como se hace trimestralmente, de manera más eficiente el precio de la energía. Hasta ahora los modelos públicos, como el de Red Eléctrica España, tienen un horizonte de predicción inferior a 24h. Al igual que en el modelo gasístico, se pretende obtener un modelo neuronal que estime los consumos con un error inferior al 10%.

En este artículo se presentará tras la introducción, el desarrollo de la solución presentada para modelizar complejos sistemas dinámicos, comenzando con la presentación de los problemas de consumo energético a estudiar, siguiendo con una exposición de las estructuras neuronales a utilizar y finalizando con la presentación de la metodología de trabajo seguida basada en las *Committee Machine* y una técnica adaptada de *boosting*. En el siguiente apartado se presentarán los resultados más relevantes. Finalmente, se apuntarán una serie de conclusiones y posibles trabajos futuros.

## 2 DESARROLLO DE LA SOLUCIÓN

La problemática de la predicción de series temporales, como son las variables energéticas, ha sido abordada con diferentes tecnologías, tal y como presentan los trabajos de (Szoplik, 2015),

(S.Dablemont, 2003) y (D. Coyle, 2005), donde se trabaja con Perceptrones Multicapa tradicionales, Mapas Autoorganizados y modelos no lineales locales, respectivamente. Las metodologías clásicas no han aportado una solución acorde a las demandas de los respectivos entes reguladores. Esto ha llevado a las empresas involucradas en este servicio a buscar otros métodos con el fin de realizar una predicción del consumo energético con mayor exactitud

Las RN son técnicas no paramétricas muy utilizadas en diversos ámbitos de la ciencia e ingeniería porque permiten resolver problemas complejos, que muchas veces no son fáciles de resolver utilizando técnicas tradicionales como la regresión lineal o polinómica. Las redes neuronales permiten obtener un modelo no explícito que relaciona un conjunto de variables de salida con un conjunto de variables de entrada. Así, estos modelos permiten predecir cuál es el valor de salida, dados unos valores de entrada del modelo. Así mismo, para extraer un buen modelo es necesario disponer de un conjunto de observaciones de las variables. A continuación se realizará una descripción de las posibles variables que tienen influencia en consumo energético como pueden ser las condiciones meteorológicas, estacionalidad, situación socioeconómica, etc. Posteriormente se presentará la estructura de RN elegida tras un pormenorizado estudio de alternativas.

### 2.1 VARIABLES OBJETO DE ESTUDIO

Es especialmente importante encontrar variables que sean capaces de ser correlacionadas con facilidad con la variable energética (gas o electricidad) que se desea predecir. De hecho, es objeto de estudio el encontrar un conjunto de variables que conformen el vector de entrada, las cuales sean fácilmente disponibles o que incluso que sean accesibles sus estimaciones futuras procedentes de plataformas como la Agencia Estatal de Meteorología (AEMET). Esto supondría reducir la complejidad del modelo neuronal al valernos de plataformas ya asentadas y robustecer, si cabe, su nivel de predicción.

En lo que a gas se refiere, la mayor parte de los trabajos existentes en la bibliografía apuntan a que la variable más importante a tener en cuenta es la temperatura, dada su fuerte relación con el consumo de gas (Kizilaslan & Karlik, 2008), (Fagiani, 2015). En nuestro caso de estudio se puede observar este hecho a través de la figura 1, donde se presenta el consumo y la temperatura a lo largo de dos años. Parece fácil considerar que a mayor temperatura menor consumo y viceversa. Otras variables que también son consideradas de importancia en los trabajos anteriormente referidos son:




Figura 1: Lasarte-Oria. Consumo en Kwh y Temperatura en °C

- Variable de laboralidad o efecto calendario: Recoge las diferencias de días laborables y festivos en los meses objeto de estudio.
- Actividad económica: Refleja la actividad económica del país y cuáles son las necesidades de consumo energético relacionadas.
- Porcentaje de segunda vivienda: Representa el % de la población que posee una segunda vivienda.
- Inercia térmica (temperatura): Los requerimientos de energía de un país se hayan fuertemente vinculados a factores climatológicos. La demanda de energía no responde a las condiciones climáticas de un día fijo, sino que depende del escenario preexistente; ya que no se da el mismo consumo en un día de verano en el cual se registra una temperatura de 20°C, que en un día de invierno.
- Variable de actividad económica (pib, renta...): El PIB es la variable macroeconómica por excelencia, dado que recoge el valor de la producción final generada por una economía en un período de tiempo determinado, y por lo tanto sintetiza el nivel de actividad de todos los sectores productivos.
- Sensación térmica: El índice de sensación térmica por frío no es estrictamente una temperatura, sino una variable adimensional que ayuda a estimar el efecto adicional de enfriamiento que aporta el viento sobre el ser humano.
- Dirección de viento: Se considera de interés el estudio de la dirección del viento como nueva variable meteorológica.
- Velocidad de viento: La velocidad del viento es una variable influyente en la sensación térmica que pueda sentir una persona.
- Humedad: Al igual que la velocidad del viento esta variable tiene una relación directa con la sensación térmica por lo que se consideró interesante de estudio para este trabajo.

En una primera fase de estudio del presente trabajo se considera la Temperatura como la variable más significativa e influyente sobre el consumo, tal y como apuntan los trabajos existentes previos mencionados anteriormente. Es por ello que este primer paso en el estudio se apoye en las valoraciones extraídas del análisis de la temperatura.

### 2.1.1 Análisis de Variables meteorológicas

Como se ha comentado anteriormente, para este estudio se ha dispuesto de los datos que proporciona AEMET. Como primer paso se ha considerado necesario analizar y evaluar el error que el modelo AEMET comete en sus estimaciones, ya que al utilizar sus estimaciones como variables en el vector de entrada a la RN, se trabajará con un error intrínseco a dicho modelo. Independientemente de la bondad de la estimación de un modelo meteorológico consolidado como el mencionado, ha parecido oportuno conocer qué error comete ya que marcará un umbral mínimo por debajo del cual no será posible bajar.

La temperatura que suele ser relevante en las pautas de consumo es la temperatura del aire, que se mide en grados Celsius (°C). Normalmente se utiliza la temperatura media diaria, calculada como media aritmética de las temperaturas máxima y mínima diaria. En el estudio que se está presentando, el cual parte de datos históricos descargados periódicamente desde AEMET, se ha considerado como índice del “día actual” la nomenclatura **H**, siendo **H+n** los días consecuentes. El estudio se realiza con temperaturas registradas durante 725 días, en el periodo del 21/01/2013 hasta el 15/01/2015, semejante al mostrado en la figura 1. Los errores estudiados arrojan el resultado mostrado en la tabla 1.

Tabla 1: Medias y varianzas de los errores AEMET.

Día de predicción	Media(°C)	Varianza
H+1	0.157	2.169
H+2	0.905	5.932
H+3	0.982	9.072
H+4	1.224	12.817
H+5	1.229	14.372
H+6	1.333	15.734

Ello nos indica el grado de error que comete el propio modelo AEMET a la hora de estimar las temperaturas futuras. Esto quedará reflejado en las estimaciones de consumo energético que realice nuestro modelo neuronal, incorporando una componente de error determinada para cada día estimado y que afectará en mayor medida conforme la estimación sea a más días vista.

## Variables que influyen en el consumo de Gas

En este estudio se ha comprobado que la variable por excelencia que marca una relación clara con el consumo de gas es la temperatura. Con objeto de analizar la posible correlación entre consumo y temperatura se ha considerado utilizar la relación inversa de esta última, arrojándose los resultados mostrados a continuación. La relación existente entre la inversa de la temperatura y el consumo es una relación inversa no-lineal, tal y como se observa en la figura 2, donde se muestra un diagrama de dispersión entre ambas variables.




Figura 2: Lasarte-Oria. Diagrama de dispersión Temperatura-Consumo

En esta primera fase del estudio no se han considerado los resultados de otras variables meteorológicas puesto que estas no muestran una relación tan clara en relación al consumo de gas. En una ampliación del estudio, en aras de seguir robusteciendo el modelo neuronal se puede proceder a incluirlas en el mencionado estudio.

## Variables que influyen en el consumo Eléctrico

Dada la periodicidad del perfil de consumo, tal y como se muestra en la figura 3, se plantea la posibilidad de descomponer esta en frecuencias fundamentales. Para ello se utiliza la transformada de Fourier, que proporciona información acerca de los coeficientes de las funciones propias seno.

El análisis previo mostrado en la figura 4 da como resultado que los armónicos aparecidos obedecen a: El primer armónico coincide con periodo 400 días, que puede asociarse al ciclo anual; El segundo es cada 60 días, puede asociarse al cambio de estación; El tercer armónico es el mensual (30 días), es decir se repite cierto patrón de consumo mensual; El último con un patrón semanal.

Según lo estudiado y basándose además en trabajos previos, es importante incluir la hora, día de la semana y un indicador de día festivo para lograr una estimación adecuada del consumo eléctrico (Kani &

Ershad, 2007), (MohammadZadeh & Masoumi, 2010).




Figura 3: Consumo eléctrico diario y mensual. Acumulación de consumos registrados




Figura 4: Transformada de Fourier de la señal de demanda eléctrica

## 2.2 ARQUITECTURA Y TIPO DE RED NEURONAL

En trabajos anteriores, la estructura feedforward del Perceptron Multicapa (MLP) muestra un desempeño apropiado para predecir variables similares, tales como el estudio de Mohammad Moradi Dalvand et al. (Dalvand, et al., 2008) donde utilizan una RN con 12 entradas diferentes que implican variables económicas para el pronóstico a largo plazo de la demanda de energía iraní. Otro ejemplo es el presentado por Jolanta Szoplik (Szoplik, 2015), donde utiliza MLP para predecir el consumo de gas natural para la ciudad de Szczecin en Polonia, con resultados igualmente satisfactorios.

En base a estos trabajos previos y estudiados los problemas de consumo gasístico y eléctrico del

presente trabajo, la estructura neuronal seleccionada ha sido una MLP en configuración NARX, tal y como se muestra en la figura 5.




Figura 5: Esquema NARX en MATLAB

Este tipo de estructura tendrá en cuenta los valores anteriores de las variables temperatura y consumo, constituyentes del vector de entradas a la RN.

Para la determinación del número de neuronas de la capa oculta y el número de retardos por variable de entrada se han realizado estudios de exactitud (accuracy) y error cometidos (MSE), utilizando herramientas de visualización, además de análisis numérico, como las mostradas en la figura 6.




Figura 6: Herramientas de análisis: Accuracy-MSE

Los experimentos llevados a cabo con las RN han cumplido con los estándares en este ámbito, llevando a cabo tandas de entrenamientos, repitiéndose un total de 10 veces por estructura elegida. Dichas estructuras han barrido un rango [5-25] de neuronas en la capa oculta, así como [1-10] en lo concerniente a los retardos incorporados a las variables de entrada. Dado que esta combinación da como resultado una cantidad ingente de pruebas, en este trabajo se desarrolló explícitamente un mecanismo de entrenamiento basado en Particle Swarm Optimization, con objeto de acelerar el proceso de búsqueda de la RN óptima.

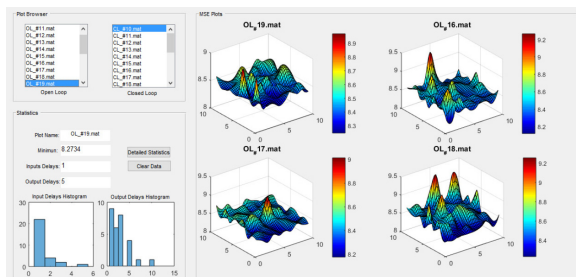


Figura 7: Herramienta software de discriminación por MSE

A pesar de agilizar la fase de entrenamiento con el mecanismo PSO, la fase de análisis es igualmente larga y pesada. Para facilitar el estudio y selección de las mejores RN en la labor de estimar las variables energéticas se desarrollaron sendas herramientas gráficas que permitían visualizar más cómodamente los resultados obtenidos, tal y como se observa en las figuras 7 y 8.




Figura 8: Herramienta software de discriminación por precisión

### 2.3 COMMITTEE MACHINE

Una vez se tiene un conjunto de redes expertas (RN con los mejores resultados entre el conjunto de todas las redes entrenadas), se pueden utilizar distintas metodologías para mejorar aún más la eficiencia de las mismas. La mejora de rendimiento de estas metodologías radica en la estrategia de “Divide and Conquer”. Al contrario de utilizar únicamente la mejor red que devuelva el algoritmo PSO, lo que se hace es utilizar todas aquellas que dan un resultado bueno y similar. La técnica que más se usa comúnmente es la “Committee Machine”, que trata de unir diferentes redes expertas mediante un “Combiner” (Bullinaria, 2004). El *combiner* utiliza únicamente la salida de los modelos neuronales, combinándolos de cierta manera para obtener una salida, tal y como se ilustra en figura 9.




Figura 9: *Committee Machine* de estructuras estáticas

En este trabajo se han estudiado diferentes tipos de *combiner* al habitual. Por lo general se suele utilizar la media en este tipo de máquinas (Min, 2015), (Dong, et al., 2014). Sin embargo, en este caso se ha decidido estudiar como posibles *combiners* la mediana y una adaptación a los casos de regresión de técnicas de *boosting*. Ello es debido a que la media,

no tiene la misma capacidad que los otros dos para filtrar *outliers*. Las pruebas llevadas a cabo en este sentido han arrojado un mejor resultado con el *combiner* basado en *boosting*, tal y como se observa en la figura 10.




Figura 10: Evolución de *combiner*:  
Media-Mediana-Boosting

### 3 RESULTADOS

Para el estudio del presente trabajo se han estudiado los casos de consumo gasístico y eléctrico por separado. El hecho de tener que estudiar y obtener el modelo neuronal de dos sistemas dinámicos, cuyas respuestas temporales tienen comportamientos diferentes, recomienda el hacer los análisis para ambos casos desde un principio. Lo que sí se ha mantenido constante en este trabajo es el planteamiento metodológico expuesto anteriormente. En ambos casos se ha buscado el conjunto de mejores modelos neuronales que reproducen el comportamiento de las series temporales asociadas a los sistemas dinámicos de consumo gasístico y eléctrico y se ha analizado la mejora que presentan bajo la estrategia de *Committee Machine*, especialmente utilizando una técnica de *boosting* adaptado a regresión.

#### 3.1 CONSUMO GASÍSTICO

Como se ha expuesto con anterioridad, una vez obtenidas los mejores modelos neuronales y con el fin de mejorar la precisión de estos, se aplica el algoritmo desarrollado en este trabajo y se compara el error que comete respecto al valor del mejor modelo neuronal individual.

Mientras que en el caso de considerar el mejor modelo neuronal individual para estimar las muestras a H+6 días se obtiene un porcentaje de muestras que están por debajo por el 10% de error (estipulado por EDP) que no supera el 86%, para el caso del *Committee Machine* con el *boosting* adaptado se logran un total del 100% de muestras estimadas que cumplen dicha condición.

La calidad en el ajuste de la predicción del procedimiento de *Committee Machine* frente al planteamiento tradicional queda patente en la

comparativa que se puede establecer entre las figuras 11 y 12.

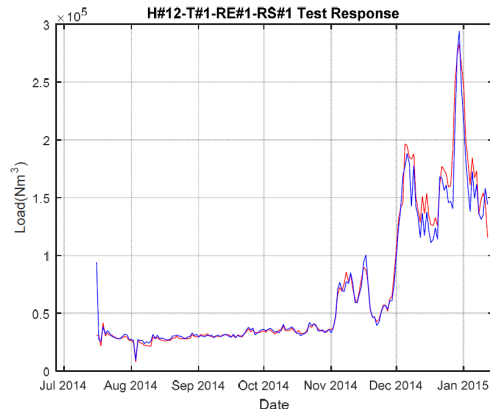


Figura 11: Estimación (rojo) de consumos para el día H+6 con el mejor modelo neuronal individual




Figura 12: Estimación (rojo) de consumos para el día H+6 después de aplicar *boosting* a 100 modelos

De cara a analizar cómo mejora la predicción del modelo híbrido construido con el procedimiento del *Committee Machine* se puede estudiar cómo al añadir nuevos modelos neuronales al conjunto, el error (MSE) va disminuyendo. Aunque no se ha estudiado en este trabajo, cabría plantearse el estudiar qué gasto computacional ocasiona el hecho de utilizar un total de 100 modelos neuronales y las posibilidades de portabilidad a sistemas que se ejecuten on-line.




Figura 13: Evolución de MSE en función de modelos neuronales añadidos

En un intento de clarificar la mejora que arroja crear un *Committee Machine* con un *boosting* adaptado a regresión, se ha creado la tabla 2, donde se recogen los resultados de las mejores redes para cada día y los resultados de los modelos híbridos tras el *boosting*.

Tabla 2: Resumen de resultados de los modelos postprocesados.

Modelo	Estado	Nombre de la red	MAPE	MSE	% error < 15%	% error < 10%	% error < 5%
H+1	Pre-Boosting	'H#5_TH4_RE#2_RS#1'	4%	9,34E+07	95%	88%	78%
	Post-Boosting	H+1 Boosted	1.73%	1,33E+06	98.9%	98.9%	95%
H+2	Pre-Boosting	'H#10_TH2_RE#3_RS#1'	6%	7,77E+07	94%	87%	66%
	Post-Boosting	H+2 Boosted	2.13%	1,8E+06	99.4%	99.4%	95%
H+3	Pre-Boosting	'H#13_TH4_RE#3_RS#2'	7%	9,21E+07	92%	83%	59%
	Post-Boosting	H+3 Boosted	1%	4,08E+05	100%	100%	100%
H+4	Pre-Boosting	'H#5_TH2_RE#2_RS#2'	8%	1,29E+08	85%	73%	54%
	Post-Boosting	H+4 Boosted	1.42%	6,16E+05	100%	99%	97%
H+5	Pre-Boosting	'H#5_TH4_RE#1_RS#2'	7%	9,41E+07	94%	86%	58%
	Post-Boosting	H+5 Boosted	0.87%	3,05E+05	100%	99%	99%
H+6	Pre-Boosting	'H#12_TH1_RE#1_RS#1'	7%	1,07E+08	95%	86%	53%
	Post-Boosting	H+5 Boosted	0.93%	2,88E+05	100%	100%	100%

En la tabla se puede observar que una vez se ha aplicado el algoritmo, el MAPE se ve reducido drásticamente para todos los casos alcanzando mínimos menores del 2%. Cabe destacar el caso de H+5 donde decae desde un 7% a un 0,83%, el valor mínimo alcanzado en todos los experimentos.

Por otro lado, se puede ver cómo el MSE también ha evolucionado de manera favorable, reduciéndose, en la mayor parte de los casos, en un orden de magnitud. El MSE máximo se da en el modelo H+2, alcanzando el 1.8e3. Por el contrario, se encuentra el modelo de H+5 donde se alcanza un mínimo de 3.05e5, reduciendo en dos órdenes de magnitud el MSE.

En cuanto al porcentaje de errores menores que cierto valor, se ha aumentado la tasa en todos ellos. Sobre todos los casos cabe destacar el porcentaje de errores menores del 5% en el que se ha dado una notable mejoría en la totalidad de los modelos.

### 3.2 CONSUMO ELÉCTRICO

De nuevo, para el caso del consumo eléctrico, se ha procedido de igual manera al caso gasístico. Para este caso se han dado estructuras de RN con mayor número de neuronas en la capa oculta y retrasos en las variables de salida, debido principalmente al tipo de comportamiento que tiene el consumo eléctrico.

En este estudio se ha encontrado que los resultados de los modelos neuronales individuales alcanzan estimaciones satisfactorias, aunque de nuevo la solución aportada por el *Committee Machine* supera dichos valores. En la figura 14 se puede observar cómo el modelo individual es muy cercano al consumo real.




Figura 14: Respuesta de validación de un modelo neuronal individual con 16 neuronas en la capa oculta y 12-11 retrasos en las variables de entrada




Figura 15: Histograma de error porcentual del modelo neuronal individual

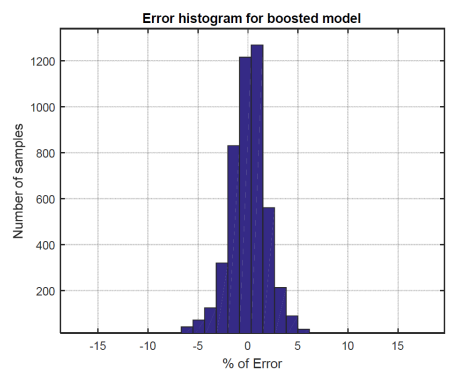


Figura 16: Histograma de error porcentual del modelo híbrido (*boosting*)

Dado que la mejoría del modelo no es tan evidente como en el caso gasístico y con el fin de clarificar la aportación del modelo híbrido, se ha optado por graficar el histograma de errores porcentuales del modelo después del *boosting*. De esta forma se puede apreciar la mejora que ha habido, el error porcentual

máximo que se comete es de alrededor del 7%, representado en la figura 16, distinto al 15% que se obtenía antes, representado en la figura 15.

Por último, se muestra la tabla 3 con los datos concretos de mejora. En este caso se puede observar que la mejora más significativa se ha obtenido en el MSE. También se ha incrementado en un 1% la variable porcentaje.

Tabla 3: Resumen de mejoras

Estado	Nombre de la red	MAPE	MSE	% error < 15%	% error < 10%	% error < 5%
Pre-boosting	'HW16_TW1_REV12_RS#11'	3%	2,92E+06	100%	99%	88%
Post-Boosting	Modelo	2.6%	2,25E+06	100%	100%	88.5%

## 4 CONCLUSIONES

El estudio presentado en este trabajo ha iniciado una línea de investigación donde se plantea una metodología de trabajo para lograr reproducir el comportamiento de sistemas dinámicos complejos a partir de modelos neuronales incorporados a un procedimiento de *Committee Machine*.

Los resultados han demostrado que la solución propuesta tras la aplicación de un *boosting* adaptado mejora la estimación de muestras futuras en dos casos de consumo energético: gasístico y eléctrico.

Por todo ello, queda abiertas un conjunto de líneas de trabajo donde se puedan estudiar nuevos hitos como los relativos a la carga computacional o a las estructuras de nuevas RN, o incluso otro tipo de modelos.

### Agradecimientos

Los autores quieren agradecer al MINECO por el proyecto concedido TIN2017-85827-P, a la empresa EDP Naturgas por su colaboración en todo este trabajo y especialmente al Grupo de Investigación de Control Inteligente de la UPV/EHU.

### English summary

#### Study of the improvement of behavior models of energetic variables by Committee Machine of neural networks

#### Abstract


*The present work is based on the modeling of nonlinear dynamic systems using different techniques. The neural models of two complex*

*systems will be presented, such as the consumption of natural gas and electricity. As the work has been carried out with the collaboration of EDP Spain, the company has determined a series of guidelines when developing the study, in such a way that they cover different needs for each of the systems. The main objective of this work is to study which work methodology best fits in the modeling process of energy systems, which have the character of nonlinear dynamic systems, through the use of Artificial Neural Networks, as well as the search for new techniques that can be added to predictive tools that improve their performance, such as Committee Machine and Boosting. The results presented will show the improvements achieved in the estimation of the energetic variables by means of these techniques.*

**Keywords:** Neural Networks, Committee Machine, Boosting, Time Series, Dynamic Systems.

### Referencias

- [1] Coyle, D., et al (2005) "A time-series prediction approach for feature extraction in a brain-computer interface". *IEEE Transactions on Neural Systems and Rehabilitation Engineering*.
- [2] Dablemont, S., et al (2003) "Time series forecasting with SOM and local non-linear models - Application to the DAX30 index prediction. Proceedings of the 4th Workshop on Self-Organizing Maps.
- [3] Fagiani, M., et al (2015). "A review of datasets and load forecasting techniques for smart natural gas and water grids: Analysis and experiments". *Neurocomputing*, Vol. 170. Pp. 448-465.
- [4] Haykin, S., (1994) *Neural Networks: A Comprehensive Foundation*. Ed., Prentice Hall, New Jersey.
- [5] Kizilaslan, R. & Karlik, B., (2008) "Comparison neural networks models for short term forecasting of natural gas consumption in Istanbul". *Applications of Digital Information and Web Technologies, 2008. ICADIWT 2008*.
- [6] Szoplik, J., (2015) "Forecasting of natural gas consumption with artificial neural networks". *Energy*, Volumen 85, pp. 208 - 220.
- [7] Viñuela, P. I., (2004) *Redes Neuronales Artificiales. Un Enfoque Práctico*. Ed., Prentice Hall, New Jersey.



© 2018 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC 3.0 license (<https://creativecommons.org/licenses/by-nc/3.0>).