

ESTUDIO DE CONSUMOS DE GAS EN ENTORNOS RESIDENCIALES BASADO EN REDES NEURONALES

Alain Porto

DISA, EIB, UPV/EHU, Alda. Urquijo S/N, aporto001@ikasle.ehu.es

Eloy Irigoyen, Xabier Basogain

DISA, EIB, UPV/EHU, Alda. Urquijo S/N, {eloy.irigoyen@ehu.es, xabier.basogain@ehu.es}

Resumen

El objetivo de este trabajo es la mejora de la eficiencia de suministro de gas en distritos residenciales. Para alcanzar tal logro, se han empleado Redes Neuronales Artificiales (RNA), que son técnicas no paramétricas muy utilizadas en diversos ámbitos de la ciencia e ingeniería dado que permiten abstraer relaciones fuertemente no lineales.

Haciendo uso de RNA se ha construido un modelo que obtiene el consumo de gas (en Kwh) total diario en distritos residenciales, con un horizonte de predicción de 7 días. Se han introducido series temporales de consumo para obtener este modelo y variables meteorológicas para mejorar la predicción.

Con el fin de encontrar la mejor RNA que modele el comportamiento de dicha variable de consumo se ha diseñado una batería de experimentos, considerando el número de neuronas en la capa oculta, el número de realimentaciones a la entrada y el número de realimentaciones a la salida. Este estudio utiliza el error cuadrático medio cometido por cada una de las redes para calificar su fiabilidad y precisión. El análisis se ha llevado a cabo mediante una serie de herramientas específicas diseñadas con tal fin.

Palabras Clave: redes neuronales, predicción de consumo de gas, predicción basada en RNA, optimización con RNA.

1. INTRODUCCIÓN

El gas natural es una de las fuentes de energía fósil más utilizada dado su gran potencial calorífico. Se obtiene directamente de yacimientos naturales, en la mayor parte de los casos asociado a perforaciones petrolíferas. La demanda mundial de gas natural para calefacción se ha visto incrementada considerablemente durante las últimas décadas, especialmente en el sector residencial y consumo doméstico (agua caliente sanitaria, gas calefactor, gas para cocina...). El gas almacenado para éstas funciones es extraído del subsuelo y transportado

mediante gasoductos y buques especialmente desarrollados para tal fin. En el caso de los distritos residenciales, el gas está almacenado en los Sistemas de Calefacción por Distrito (DHS en inglés), donde éste es suministrado en camiones cisterna que abastecen la demanda variable de gas. El gas es almacenado en tanques en estado líquido, lo que conlleva que los almacenes tengan que cumplir rigurosas especificaciones para poder almacenarlo.

En este estudio, se pretende predecir la variabilidad de la demanda de gas, con el fin de optimizar específicamente el suministro de gas de los DHS, y así aumentar la durabilidad de los almacenes de gas, y reducir los costes de transporte de los mismos en camiones cisterna. Este tipo de problemas puede ser solucionado por herramientas software específicas diseñadas para abstraer relaciones no lineales difíciles de modelar matemáticamente. Algunas de estas herramientas son, Extreme Learning Machine (ELM), Redes Neuronales Artificiales Networks (RNA) o Genetic Programming (GP). En contraste con el campo de la energía eléctrica, donde las publicaciones sobre predicción son abundantes [1-3], la actividad de predicción en gas natural todavía es escasa [4-5].

Con el fin de encontrar la mejor de estas herramientas para la predicción de consumo de gas en distritos residenciales, Nima Izadyar et al.[6], realizan diferentes experimentos para predicciones mensuales, concluyendo que ELM, en términos de precisión, supera a RNA y GP.

Por otra parte, para predecir el consumo diario y mensual de gas natural se han creado aproximaciones en base a RNA realizadas por Azari et al. [7] con dos capas ocultas de 15 neuronas cada una. Las entradas están compuestas por 29 elementos, parámetros meteorológicos, consumo previo de cinco días y parámetros meteorológicos para el día de predicción. Para el consumo mensual se ha implementado una RNA con una sola capa oculta con siete neuronas en su interior. El vector de entrada está compuesto de tres elementos, la temperatura efectiva mensual

anterior y actual y el consumo de gas del mes anterior. Para entrenar la red, se ha utilizado datos de consumo de gas desde 21 de marzo de 2001 al 8 de agosto de 2005, un total de 1611 datos. El 90% de estos se han utilizado para entrenar y el resto para validación.

En otro estudio llevado a cabo por Recep Kizilaslan y Bekir Karlik [8] se obtiene una RNA para la predicción de consumo semanal de gas para la ciudad de Estambul. En este caso se utiliza una red neuronal con una sola capa oculta con 50 neuronas en su interior. Las variables de entrada son, temperatura máxima y mínima para el día de predicción y el día anterior, el consumo anterior, el precio del gas y de otros recursos, velocidad del viento y mes. En el estudio se analizan los diferentes algoritmos de entrenamiento y se obtiene el más eficiente para este tipo de problemática. En este caso el óptimo resulta ser el entrenamiento Lenberg-Marquardt, que es el que mejor compromiso ofrece entre precisión, rapidez y rendimiento. Cabe destacar que el estudio concluye que el consumo del día anterior influye significativamente en el siguiente.

En el texto de Mohammad Moradi Dalvand et al. [9] se hace uso de una RNA con 12 entradas, producto Interno Bruto (PIB), PIB sin contar petróleo, Producto Nacional Bruto, precio del petróleo en Irán, impuesto de valor añadido, población, índice de consumo, consumo de gas, suministro de electricidad y agua, tipo de intercambio y el precio del oro. Utilizando una capa oculta con 19 neuronas entradas con el algoritmo de Backpropagation (BP), se obtuvo para la predicción de consumo de gas de 2004, 2005 y 2006, un error que rondaba el 1 %.

No obstante, los modelos planteados por estos autores no son una alternativa real, dado que en el problema que se plantea es necesario una predicción a corto plazo ya que se necesita saber la demanda para suministrar correctamente a los tanques de almacenamiento mediante los camiones cisterna. El presente estudio, se ha llevado a cabo en colaboración con la empresa suministradora EDP-Naturgas [11], con el fin de encontrar el modelo más acertado con el que proporcionar pronósticos de consumo de gas a corto plazo

2. METODOLOGÍA

2.1. Sistema a modelar

En este estudio, se han considerado las variables meteorológicas de temperatura media y los consumos de gas diarios que se han dado en la localidad Lasarte-Oria, que está constituida por unidades industriales y residenciales, siendo las últimas las mayoritarias. La Figura 1 muestra el consumo de gas

en dicha localidad y la temperatura media asociada a cada día de consumo, desde el día 21/01/2013 hasta el 18/01/2015.

Claramente, la temperatura media exterior afecta a la demanda de gas natural para consumo doméstico, en términos de calefacción, es por ello que se aprecia como el consumo es inversamente proporcional a la temperatura medida.

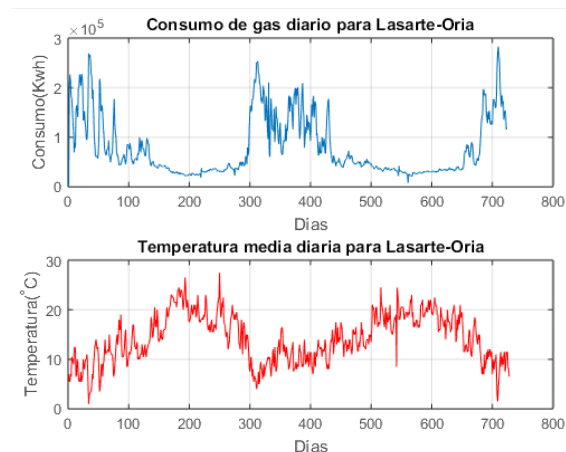


Figura 1: Consumo y Temperatura para Lasarte-Oria

2.2. Variables a Considerar

Dada la dependencia que se ha descrito anteriormente, una de las variables más significativas que se han tenido en cuenta para introducir en la RNA, ha sido la temperatura media medida para cada día. La obtención de estos datos ha sido vía AEMET [10], la agencia estatal de meteorología. En la web se pueden encontrar catálogos de datos abiertos para localidades españolas, pudiéndose encontrar todo tipo de variables meteorológicas con un horizonte de predicción de 7 días.

Debido a que se obtienen datos de un modelo como el de AEMET, se ha cuantificado el error que éste comete a la hora de predecir temperatura, ya que el error que se cometa será intrínseco de la red que se diseñe. Para caracterizarlo se han comparado las predicciones de temperatura media con los datos reales (tomando como reales los datos de temperatura media para el día en el que se hace la predicción). Se ha obtenido la media y la varianza para obtener una distribución normal de acuerdo con la Ec 1

$$y = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\bar{x})^2}{2\sigma^2}} \quad (1)$$

Donde \bar{x} es la media y σ^2 representa la varianza. En la Figura 2 se presentan las distribuciones acompañadas de la Tabla 1, donde se especifican la varianza y la media para cada uno de los casos. Se

aprecia claramente que el error mínimo se da para la predicción del día “H+1” (donde H significa el día donde se hizo la predicción), con un error medio de 0.157°C y varianza de 2.169°C.

A partir del segundo día de predicción el error va aumentando progresivamente errando en 0.905°C y con una desviación típica de 5.932°C para el día “H+2” y terminando en un error medio de 1.333°C y una varianza de 15.734°C.

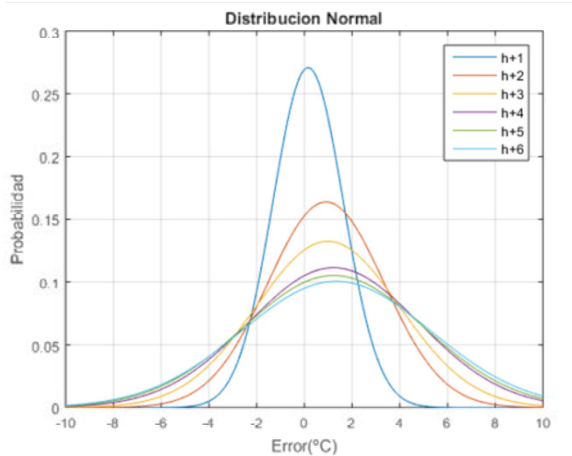


Figura 2: Distribuciones del error de la Temperatura para diferentes horizontes de predicción

Tabla 1: Media y varianza de los errores de predicción de la Temperatura

Día de predicción	Media	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

Además de la temperatura, se pueden añadir más entradas con el fin de mejorar la predicción que haga la RNA. Se ha realizado un estudio, donde se correlaciona el error que comete cierta red en predicción con variables meteorológicas, para observar si incluyendo éstas en la RNA mejoran el error. Estas correlaciones se resumen en la Tabla 2, utilizando el coeficiente de correlación de la Ec 2,

$$r = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \quad (2)$$

Dónde σ_x es la desviación típica de x, σ_y la desviación típica de y, y σ_{xy} la desviación de x respecto a y.

Tabla 2: Correlaciones entre errores y variables meteorológicas

Variable meteorológica	correlación (r) respecto al error
Sensación térmica	-0.526
Probabilidad de precipitación	0.189
Humedad relativa	0.056
Velocidad del viento	0.039

Se puede tener en cuenta la sensación térmica como entrada a la red, dado que se aprecia una relación entre el error y ésta variable.

2.3. Arquitectura

El objetivo de la red es obtener el consumo total de gas natural para cada día, de modo que se establecerá éste como salida. Ya que el problema trata de predecir gas a lo largo del tiempo, se ha seleccionado una estructura RNA tipo NARX (Nonlinear-AutoRegressive network with eXogenous inputs), puesto que es de vital importancia la tendencia de los valores de las variables en momentos anteriores para una predicción con mayor exactitud.

En consecuencia, se ha optado por introducir a la red como entradas, tanto el consumo de días anteriores como las temperaturas anteriores y la temperatura del día del que se quiere obtener el consumo de manera realimentada. La red se ilustra en la Figura 3, donde x(t) representa la temperatura e y(t) el consumo de gas natural en días anteriores.




Figura 3: Red NARX con las correspondientes entradas

2.4. Batería de experimentos

Una vez elegida la arquitectura de la RNA, se han lanzado una serie de experimentos con la intención de entrenar diferentes configuraciones de redes y

obtener la mejor red que se adapte al problema de predicción. En estas pruebas se entrena una configuración específica guardando las variables más significativas para un posterior análisis de minería de datos. Los elementos que se han modificado han sido, el número de neuronas en la capa oculta, el número de realimentaciones en la entrada y el número de realimentaciones a la salida. Cada configuración se ha entrenado 10 veces para poder medir estadísticamente las variables significativas que se detallan en la Tabla 3.

Tabla 3: Variables significativas

variable	Descripción
Errores	Error absoluto cometido por la red para cada uno de los días pronosticados
MSE	Error cuadrático medio del error absoluto
Porcentaje	El porcentaje de muestras pronosticadas que cometen un error que está por debajo del 10% de la medida real
Redes	La configuración específica de la RNA
validación	Los datos pronosticados por la red para cada día

A fin de asociar un nombre único a cada configuración de las redes que se han entrenado, se utiliza la nomenclatura,

OL_H#N_T#M_RE#L_RS#K

Dónde OL significa el tipo de red (Open Loop/Closed Loop), H#N número de neuronas en la capa oculta, T#M el número de tanda, recordar que se van a hacer 10 repeticiones por cada configuración para estadísticas. RE#L simboliza el número de realimentaciones en entrada y RS#K el número de realimentaciones en salida. Por ejemplo, si se deseara reflejar la red en lazo cerrado con 15 neuronas en capa oculta correspondiente a la tanda número 4 con 9 realimentaciones de entrada y 10 de salida, el código correspondiente sería el siguiente:

CL_H#15_T#4_RE#9_RS#10

Para el entrenamiento se ha utilizado el 70% de los datos de consumo que se han presentado en la Figura 1, y el 30% restante para la validación, el algoritmo de entrenamiento utilizado es Levenberg-Marquadt, dada su rapidez y precisión. Dado que se quiere obtener un modelo capaz de predecir siete días de consumo, se ha optado por entrenar siete redes diferentes (una para cada día de predicción), cuyas entradas sean las

temperaturas del día del que se quiere pronosticar el consumo, y los targets el consumo real de ese día.

La batería de experimentos se separa en dos etapas. En la primera se varían el número de neuronas en la capa oculta de 5 a 25, el número de realimentaciones de 0 a 10, en el caso de las de entrada (RE) y de 1 a 10 en las de salida (RS), y cada una de estas configuraciones se entrena 10 veces. Se ha utilizado esta etapa para entrenar las redes H y H+1 (donde H representa el día en que se hace la predicción). Con la información que se dispone de estos dos entrenamientos se ha analizado para qué configuraciones de la red se han hallado las mejores RNA, con el fin de encontrar una zona específica en la cual entrenar las otras redes (H+2, H+3, H+4...). Este análisis ha dado como resultado la Figura 4, que representa un histograma donde el eje vertical muestra las veces que cierta configuración ha resultado ser la más eficiente, utilizando como discriminante la variable significativa "Porcentaje".




Figura 4: Histograma de configuraciones que mejor resultado han obtenido

Se ha concluido que los mejores resultados se dan para redes con RE de 0 a 3 y RS de 1 a 3, por lo que para los entrenamientos posteriores se han utilizado estas variaciones para reducir el tiempo de entrenamiento, se considera ésta la segunda etapa del entrenamiento.

2.5. Búsqueda de las mejores RNA

Después de haber entrenado la totalidad de las redes se emprende la búsqueda de la red que tenga la mejor respuesta. Con tal fin se ha hecho uso de las variables significativas que se habían guardado en el entrenamiento, utilizando el MSE como discriminante principal, y el porcentaje de predicciones que cometen un error que está por debajo del 10% de la medida real (variable Porcentaje).

Ya que se trata de una tarea monótona, se han creado herramientas software que son capaces de analizar todos los datos y seleccionar las mejores redes del conjunto total. En primer lugar, se hace una discriminación mediante el MSE buscando el menor entre las medias de las diez repeticiones, y se muestra en gráficas en función de la configuración de realimentaciones en entrada y en salida, que indicarán que configuraciones en promedio tienen un mejor rendimiento. Las gráficas descritas se pueden observar en la Figura 5, éstas están en escala logarítmica ya que los consumos están en Kwh.

Por otra parte, la herramienta crea histogramas donde se representan las configuraciones de RE y RS que tengan el MSE mínimo por cada gráfica, para poder

observar si hay alguna tendencia en cuanto a configuraciones se refiere.

Además, se dispone de otra herramienta de búsqueda exhaustiva, esta es capaz de hacer dos tipos de análisis y mostrar los datos de rendimiento. Uno de los análisis se basa en encontrar la RNA que menor MSE comete, el otro trata de encontrar las redes fijándose en la variable significativa “Porcentaje”, que no es más que un número que indica que porcentaje de las muestras predichas por la red (la salida de la red ante las temperaturas medias de validación), cometen un error menor del 10% respecto del consumo real para ese día. Esta herramienta se puede observar en la Figura 6

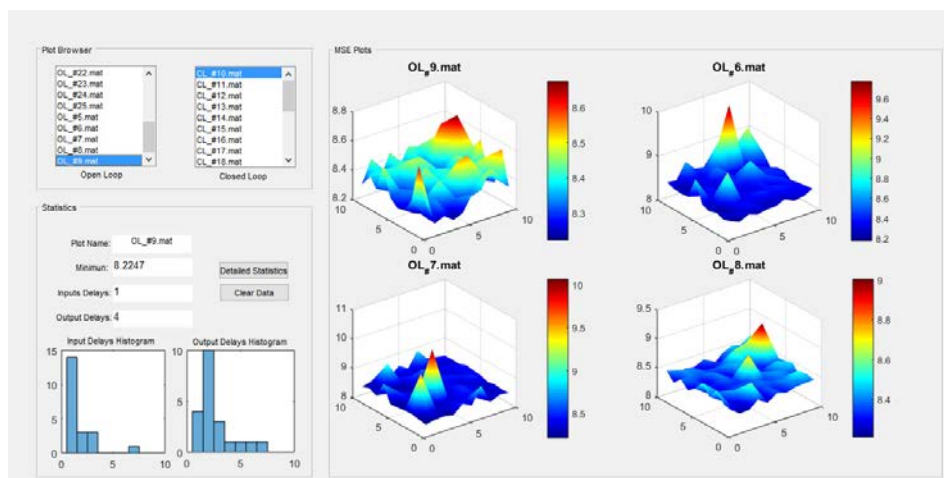


Figura 5: Herramienta software de búsqueda de RNA

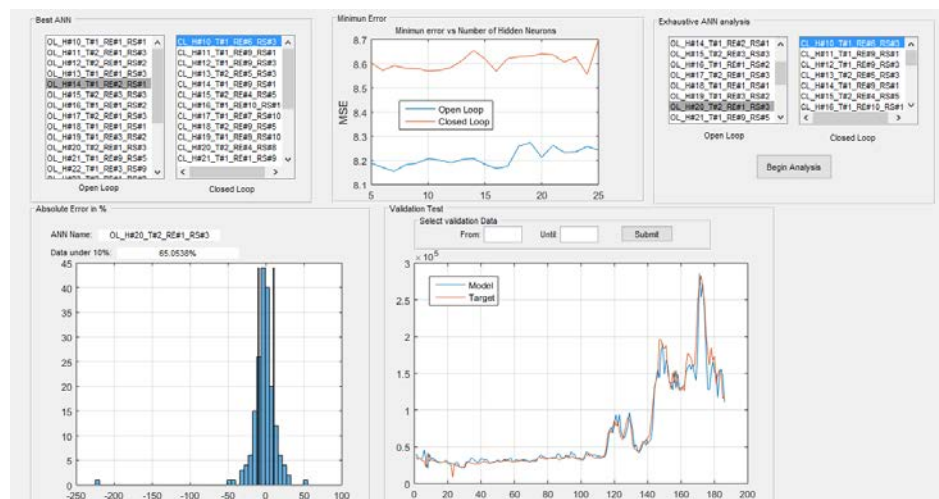


Figura 6: Herramienta de búsqueda exhaustiva

Con toda la información que se dispone, se han seleccionado las cinco mejores redes neuronales por cada día de predicción

2.6. Obtención del modelo

Una vez seleccionadas las cinco mejores redes neuronales, dado que éstas rondaban un error del 74%, se ha aplicado un filtro de mediana, con el fin de omitir datos que sean dispares de la tendencia principal. Se ha repetido este mismo proceso con cada uno de los días (H, H+1, H+2, H+3, H+4, H+5 y H+6) de los que se quiere obtener pronóstico de consumo de gas.

Finalmente, el modelo por cada día de predicción de consumo de gas está compuesto 5 RNA como se indica en la Figura 7. A la salida de éstas, se aplica la mediana que será la salida del modelo.

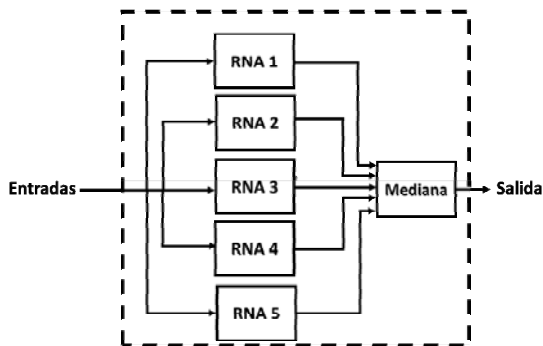


Figura 7: Modelo de predicción de un día 'H'

De modo que al unir 7 de éstas “cajas”, se obtendrá tendrá el modelo que obtiene el consumo de gas a siete días. Las entradas serán las correspondientes a los retardos de las redes que haya en su interior. El modelo se ilustra en la Figura 8

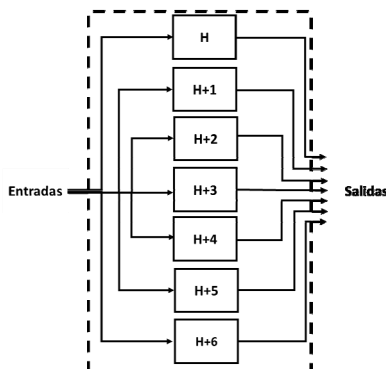


Figura 8: Modelo completo de predicción de 7 días

3. Resultados y Discusión

3.1. Las cinco mejores RNA

Mediante la metodología anteriormente expuesta, se han entrenado un conjunto de configuraciones de

RNA, y utilizando las herramientas presentadas, se han conseguido las 5 mejores RNA para cada caso.

En la tabla 4, se muestran las redes más eficientes para H, acompañadas por la variable significativa “Porcentaje”, que representa el porcentaje de muestras pronosticadas por la red que cometen un error menor del 10% respecto al valor real de consumo.

Tabla 4: Las 5 mejores redes para H

RED	ERROR(10%)
OL_H#5_T#2_RE#2_RS#1	74.3316
OL_H#6_T#1_RE#3_RS#1	74.1935
OL_H#8_T#2_RE#3_RS#2	73.1189
OL_H#10_T#2_RE#3_RS#1	73.6559
OL_H#13_T#2_RE#3_RS#2	73.1183

3.2. Filtro de Mediana

Con todas las redes obtenidas, y con el fin de mejorar la precisión de éstas, se obtiene la mediana de las salidas de las redes y se compara error que comete ésta respecto al valor real. Utilizando la variable significativa “Porcentaje”, se presenta la Tabla 5 el mismo concepto, pero aplicado al 15% y al 20%, puede observarse visualmente esta tabla en la Figura 9, donde se aprecia que la precisión de las predicciones no varía mucho en función del día pronosticado. También se puede apreciar el ajuste de las medianas de las redes en las series temporales de consumo en la Figura 10.

Tabla 5: Medianas de las mejores RNA

Día	Error		
	10%	15%	20%
H+1	84.3316	97.3118	98.3871
H+2	81.0811	92.4324	98.3784
H+3	82.6087	97.2826	99.4565
H+4	80.3279	96.1749	98.9071
H+5	80.2198	92.8571	97.2527
H+6	84.4444	97.2222	98.8889




Figura 9: Visualización de la Tabla 11

Se aprecia un aumento significativo en la respuesta de la red al aplicar el filtro de mediana, comparando

los resultados obtenidos con el error que comete la mejor red entrenada, que rondaba un acierto del 74%, para la mayor parte de los casos. En contraposición, la mediana de las cinco mejores redes aumenta la eficiencia hasta rondar un acierto del 84%, lo que significa un aumento del 10% en la exactitud. Además, casi la totalidad de los datos pronosticados por las redes entrenadas está debajo de un 20% del

error. Cabe destacar el caso de la mediana de las redes para H+3, donde el 99.4565% de los datos no supera el 20% de error.

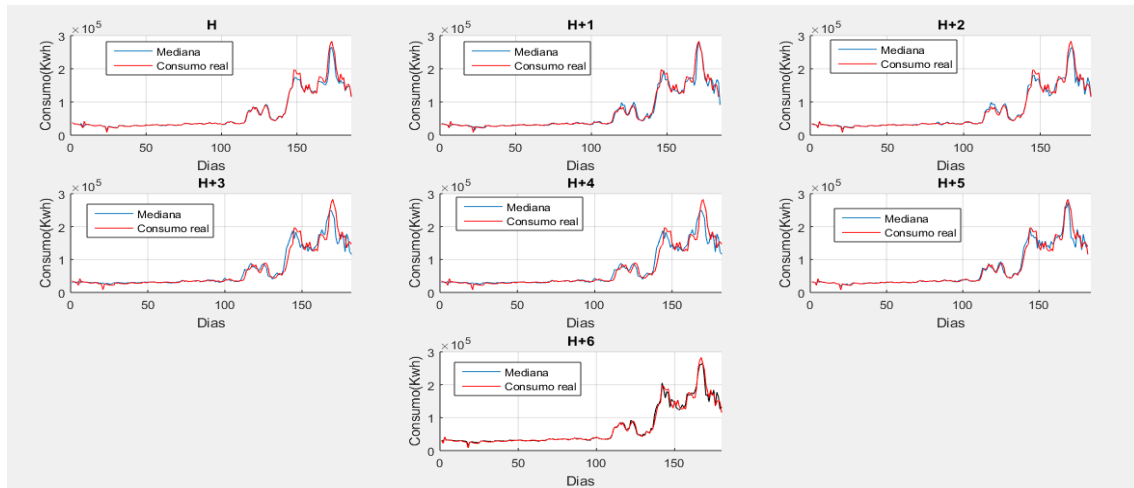


Figura 10: Ajuste de la mediana de cada una de las RNA al consumo real

3.3. Identificación de los errores más significativos

Con el objetivo de identificar el porqué de los errores más considerables, se han etiquetado las fechas donde se comete más error. Estas coinciden con los días 23-24-25/12/2014 y 1-5/12/2014, que coincide

con fechas cercanas a nochebuena y al puente de diciembre respectivamente, donde el consumo puede fluctuar significativamente respecto de la dinámica principal. Se puede observar este fenómeno en la Figura 7, donde se muestra el error absoluto.




Figura 11: Etiquetado de los errores absolutos más significativos

4. Conclusiones

En este estudio se ha presentado una metodología para la obtención de modelos basados de redes neuronales para obtener un modelo específico de optimización de gas para los DHS. Así como un modelo de predicción de consumo de gas a siete días, con un porcentaje de acierto del 74% (muestras con un error menor al 10%). Además, se ha planteado un procedimiento para mejorar éste porcentaje hasta obtener un acierto del 97% (muestras por debajo de un 20%) con un horizonte de predicción de 7 días. Por otra parte también se han creado herramientas para facilitar la búsqueda de RNA para un conjunto grande de ellas, según diferentes criterios.

Como trabajo futuro, se plantea la posibilidad de añadir a la red nuevas variables meteorológicas como la sensación térmica, con el fin de disminuir el error en cuanto a consumo de gas. También se añade la posibilidad de extender los datos de entrenamiento obteniendo estos de la página web de Aemet. Además, se pueden ponderar los días de mayor consumo para evitar errores producidos en fechas señaladas de diciembre.

Agradecimientos

Este trabajo se ha realizado en colaboración con el grupo de investigación de control inteligente (GICI) de la Universidad del País Vasco (UPV/EHU). Los datos de consumo han sido facilitados por la empresa EDP-Naturgas, mediante el aula con el mismo nombre de la Escuela Técnica Superior de Ingenieros de Bilbao (ETSI Bilbao). Así como la financiación para conseguir los datos históricos meteorológicos.

Referencias

- [1] Moon, J. W., Kim, K., Min, H. (2015). ANNbased prediction and optimization of cooling system in hotel rooms. *Energies*, 8(10), 1077510795. doi:10.3390/en81010775
- [2] S. MohammadZadeh, A. A. Masoumi. (2010). Modeling residential electricity demand using neural network and econometrics approaches. Paper presented at the Computers and Industrial Engineering (CIE), 2010 40th International Conference on, pp. 16. doi:10.1109/ICCIE.2010.5668322
- [3] Chae, Y. T., Horesh, R., Hwang, Y., Lee, Y. M. (2016). Artificial neural network model for forecasting subhourly electricity usage in commercial buildings. *Energy and Buildings*, 111, 184194. doi:http://dx.doi.org/10.1016/j.enbuild.2015.11.045
- [4] Fagiani, M., Squartini, S., Gabrielli, L., Spinsante, S., Piazza, F. (2015). A review of data sets and load forecasting techniques for smart natural gas and water grids: Analysis and experiments. *Neurocomputing*, 170, 448465. doi:10.1016/j.neucom.2015.04.098
- [5] Popescu, D., Ungureanu, F. (2014). Prediction of space heating consumption in district heated apartments.
- [6] Izadyar, N., Ong, H. C., Shamshirband, S., Ghadamian, H., Tong, C. W. (2015). Intelligent forecasting of residential heating demand for the district heating system based on the monthly overall natural gas consumption. *Energy and Buildings*, 104, 208214. doi:10.1016/j.enbuild.2015.07.006
- [7] A. Azari, M. Shaeiaty-Niassar, M. Alborzi, Short term and medium term gas demand load forecasting by neural networks, *Iran J.Chem. Chem. Eng.* 31 (4)(2012) 77-84
- [8] R. Kizilaslan, B. Karlik. (2008). Comparison neural networks models for short term forecasting of natural gas consumption in Istanbul. Paper presented at the Applications of Digital Information and Web Technologies, 2008. ICADIWT 2008. First International Conference on the, pp. 448453. doi:10.1109/ICADIWT.2008.4664390
- [9] M. M. Dalvand, S. B. Z. Azami, H. Tarimoradi. (2008). Longterm load forecasting of iranian power grid using fuzzy and artificial neural networks. Paper presented at the Universities Power Engineering Conference, 2008. UPEC 2008. 43rd International, pp. 14. doi:10.1109/UPEC.2008.4651538
- [10] Portal de la Agencia Estatal de Meteorología (AEMET) <http://www.aemet.es/es/portada>
- [11] Portal de EDP Naturgas Energía. <https://www.edpnaturgasenergia.es/>