



ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI)

MÁSTER EN INGENIERÍA DE TELECOMUNICACIÓN

DETERMINACIÓN DE PERFILES DE CONSUMO DE ENERGÍA ELÉCTRICA EN UNA MUESTRA DE CLIENTES DEL SECTOR NO RESIDENCIAL EN ESPAÑA

Autor: Jaime Fernández Sánchez

Director: Miguel Ángel Sanz Bobi

Director: Miguel Ángel Rodríguez López

Madrid

Julio 2018

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título
Determinación de Perfiles de Consumo de Energía Eléctrica en una Muestra de Clientes
del Sector no Residencial en España

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico 2017/18 es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido
tomada de otros documentos está debidamente referenciada.

Fdo.: Jaime Fernández Sánchez

Fecha: 10/07/2018

Autorizada la entrega del proyecto

LOS DIRECTORES DEL PROYECTO

Fdo.: Miguel Ángel Sanz Bobi

Fdo.: Miguel Ángel Rodríguez López

Fecha: 10/07/2018

AUTORIZACIÓN PARA LA DIGITALIZACIÓN, DEPÓSITO Y DIVULGACIÓN EN RED DE PROYECTOS FIN DE GRADO, FIN DE MÁSTER, TESIS O MEMORIAS DE BACHILLERATO

1º. Declaración de la autoría y acreditación de la misma.

El autor D. Jaime Fernández Sánchez DECLARA ser el titular de los derechos de propiedad intelectual de la obra: Determinación de Perfiles de Consumo de Energía Eléctrica en una Muestra de Clientes del Sector no Residencial en España, que ésta es una obra original, y que ostenta la condición de autor en el sentido que otorga la Ley de Propiedad Intelectual.

2º. Objeto y fines de la cesión.

Con el fin de dar la máxima difusión a la obra citada a través del Repositorio institucional de la Universidad, el autor **CEDE** a la Universidad Pontificia Comillas, de forma gratuita y no exclusiva, por el máximo plazo legal y con ámbito universal, los derechos de digitalización, de archivo, de reproducción, de distribución y de comunicación pública, incluido el derecho de puesta a disposición electrónica, tal y como se describen en la Ley de Propiedad Intelectual. El derecho de transformación se cede a los únicos efectos de lo dispuesto en la letra a) del apartado siguiente.

3º. Condiciones de la cesión y acceso

Sin perjuicio de la titularidad de la obra, que sigue correspondiendo a su autor, la cesión de derechos contemplada en esta licencia habilita para:

- a) Transformarla con el fin de adaptarla a cualquier tecnología que permita incorporarla a internet y hacerla accesible; incorporar metadatos para realizar el registro de la obra e incorporar “marcas de agua” o cualquier otro sistema de seguridad o de protección.
- b) Reproducir la en un soporte digital para su incorporación a una base de datos electrónica, incluyendo el derecho de reproducir y almacenar la obra en servidores, a los efectos de garantizar su seguridad, conservación y preservar el formato.
- c) Comunicarla, por defecto, a través de un archivo institucional abierto, accesible de modo libre y gratuito a través de internet.
- d) Cualquier otra forma de acceso (restringido, embargado, cerrado) deberá solicitarse expresamente y obedecer a causas justificadas.
- e) Asignar por defecto a estos trabajos una licencia Creative Commons.
- f) Asignar por defecto a estos trabajos un HANDLE (URL *persistente*).

4º. Derechos del autor.

El autor, en tanto que titular de una obra tiene derecho a:

- a) Que la Universidad identifique claramente su nombre como autor de la misma
- b) Comunicar y dar publicidad a la obra en la versión que ceda y en otras posteriores a través de cualquier medio.
- c) Solicitar la retirada de la obra del repositorio por causa justificada.
- d) Recibir notificación fehaciente de cualquier reclamación que puedan formular terceras personas en relación con la obra y, en particular, de reclamaciones relativas a los derechos de propiedad intelectual sobre ella.

5º. Deberes del autor.

El autor se compromete a:

- a) Garantizar que el compromiso que adquiere mediante el presente escrito no infringe ningún derecho de terceros, ya sean de propiedad industrial, intelectual o cualquier otro.
- b) Garantizar que el contenido de las obras no atenta contra los derechos al honor, a la intimidad y a la imagen de terceros.
- c) Asumir toda reclamación o responsabilidad, incluyendo las indemnizaciones por daños, que pudieran ejercitarse contra la Universidad por terceros que vieran infringidos sus derechos e intereses a causa de la cesión.
- d) Asumir la responsabilidad en el caso de que las instituciones fueran condenadas por infracción

de derechos derivada de las obras objeto de la cesión.

6º. Fines y funcionamiento del Repositorio Institucional.

La obra se pondrá a disposición de los usuarios para que hagan de ella un uso justo y respetuoso con los derechos del autor, según lo permitido por la legislación aplicable, y con fines de estudio, investigación, o cualquier otro fin lícito. Con dicha finalidad, la Universidad asume los siguientes deberes y se reserva las siguientes facultades:

- La Universidad informará a los usuarios del archivo sobre los usos permitidos, y no garantiza ni asume responsabilidad alguna por otras formas en que los usuarios hagan un uso posterior de las obras no conforme con la legislación vigente. El uso posterior, más allá de la copia privada, requerirá que se cite la fuente y se reconozca la autoría, que no se obtenga beneficio comercial, y que no se realicen obras derivadas.
- La Universidad no revisará el contenido de las obras, que en todo caso permanecerá bajo la responsabilidad exclusiva del autor y no estará obligada a ejercitar acciones legales en nombre del autor en el supuesto de infracciones a derechos de propiedad intelectual derivados del depósito y archivo de las obras. El autor renuncia a cualquier reclamación frente a la Universidad por las formas no ajustadas a la legislación vigente en que los usuarios hagan uso de las obras.
- La Universidad adoptará las medidas necesarias para la preservación de la obra en un futuro.
- La Universidad se reserva la facultad de retirar la obra, previa notificación al autor, en supuestos suficientemente justificados, o en caso de reclamaciones de terceros.

Madrid, a 10 de julio de 2018

ACEPTA

Fdo. Jaime Fernández Sánchez

Motivos para solicitar el acceso restringido, cerrado o embargado del trabajo en el Repositorio Institucional:



ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI)

MÁSTER EN INGENIERÍA DE TELECOMUNICACIÓN

DETERMINACIÓN DE PERFILES DE CONSUMO DE ENERGÍA ELÉCTRICA EN UNA MUESTRA DE CLIENTES DEL SECTOR NO RESIDENCIAL EN ESPAÑA

Autor: Jaime Fernández Sánchez

Director: Miguel Ángel Sanz Bobi

Director: Miguel Ángel Rodríguez López

Madrid

Julio 2018

Agradecimientos

Me gustaría expresar mi gratitud a dos personas que han estado presentes en todo momento durante la elaboración de este trabajo de fin de máster.

En primer lugar, quisiera agradecerle a Miguel Ángel Sanz sus valiosos comentarios, recomendaciones y su continua ayuda. Por todo ello, hoy finaliza este proyecto.

Desde lo personal, por su incansable entusiasmo, su aliento diario, y sus ánimos en los momentos más difíciles, me gustaría mencionar a Teresa. Gracias a su incondicional estímulo y apoyo, ha sido posible finalizar esta etapa de mi vida con grandes resultados y con una sonrisa en la cara.

DETERMINACIÓN DE PERFILES DE CONSUMO DE ENERGÍA ELÉCTRICA EN UNA MUESTRA DE CLIENTES DEL SECTOR NO RESIDENCIAL EN ESPAÑA

Autor: Fernández Sánchez, Jaime.

Director: Sanz Bobi, Miguel Ángel.

Director: Rodríguez López, Miguel Ángel.

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas.

RESUMEN DEL PROYECTO

Se han extraído los patrones de consumo de energía eléctrica más característicos de una muestra de clientes del sector no residencial en España. Además, se ha estudiado la influencia de las circunstancias geográficas, de calendario y de temperatura sobre estos patrones y sobre la demanda agregada de energía eléctrica, todo ello con vistas a extraer conocimiento sobre la demanda eléctrica de este sector y a la optimización de la gestión activa de la demanda.

Palabras clave: Patrones, demanda eléctrica, optimización, sector no residencial

1. Introducción

El uso de la energía eléctrica supone un gran aumento en la calidad de vida de nuestra sociedad. Por este motivo su uso es cada vez más elevado y, por tanto, la explotación de los recursos primarios es también más elevada.

Con el paso de los años, el consumo de energía eléctrica total en España está aumentando. Se obtiene como consecuencia un aumento de coste para el cliente final, debido a que los proveedores de energía eléctrica tienen que dar solución a cada vez mayores demandas y picos de energía.

El presente proyecto, *Determinación de Perfiles de Consumo de Energía Eléctrica en una Muestra de Clientes del Sector no Residencial en España*, plantea el estudio del consumo de la energía eléctrica a nivel del sector industrial y del sector servicios con objeto de conocer mejor los perfiles característicos de esta demanda que es una parte significativa del consumo energético total en España, y la similitud de comportamiento de los consumidores bajo estos perfiles. Este conocimiento permitirá tomar decisiones sobre posibles medidas a poner en marcha para optimizar el uso de la energía eléctrica responsable, reduciendo tanto el impacto ambiental como el gasto económico a nivel usuario.

2. Definición del proyecto

El proceso realizado comienza con la obtención de la información. Para la realización de este trabajo, se han adquirido datos de dos fuentes distintas; la primera es de donde se obtuvieron los datos referentes a la energía activa y reactiva consumida por un cliente en una fecha en un municipio concreto, y la segunda fuente es la Agencia Estatal de Meteorología (AEMET), donde se consiguieron los datos relativos a la temperatura en una ciudad un día concreto. Los datos de la temperatura ayudarán a complementar el estudio de los datos de consumos eléctricos, que son la piedra angular de este trabajo.

El siguiente paso fue el preprocesamiento de los datos. Para ello, centrándose en los datos de consumo eléctrico, primeramente, hubo que adaptar los datos para poder trabajar con ellos de una forma cómoda, ya que el conjunto inicial del que se partía constaba de 83 columnas y más de 32 millones de filas. Seguidamente, se hizo una limpieza de los datos que consistió en eliminar aquellos datos que estaban incompletos, y por último se realizó una reducción de los datos, eliminando aquellas columnas que no añadían ninguna información, así como seleccionando aquellas filas que eran importantes para el estudio.

Posteriormente, se procedió a realizar el modelado, para lo cual hubo que dividir los datos originales en un conjunto de entrenamiento y uno de test. Se implantó el algoritmo, se entrenó con el conjunto de entrenamiento y se seleccionó el modelo más adecuado. Con el conjunto de test se pasó a validar el modelo, asegurando que no se había realizado sobreajuste.

Siguiendo a lo anterior, se decidió realizar un análisis individualizado a cada uno de los clientes, estudiando cómo de fieles son a su patrón de consumo, reconociendo así a aquellos clientes que normalmente tienen el mismo consumo y a los que son más impredecibles.

Se realizó una interfaz gráfica de usuario que agrupara toda la funcionalidad desarrollada en un mismo punto y se pasó a realizar el análisis de los resultados, pudiendo entonces proponer acciones con vistas a la optimización de la gestión activa de la demanda e integración con el consumo residencial.

3. Descripción del sistema

La finalidad del trabajo es la de optimizar la demanda de energía eléctrica, y para ello se cubren dos funcionalidades que son el cálculo de demanda agregada y el cómputo de fiabilidad de los clientes. Para ello, y posterior a la recolección de todos los datos, es necesario realizar un procesamiento de los datos, como se observa en la Ilustración 1.




Ilustración 1 – Flujo del sistema

El presente proyecto realiza su estudio sobre una muestra de clientes del sector no residencial en España, pero la idea es que este estudio sirva como prototipo para otros estudios que integren la obtención de datos en tiempo real, permitiendo generar la curva de la demanda de energía eléctrica de forma instantánea para cada momento, y creando la oportunidad de desarrollar un sistema de mensajes informativos y alarmas tanto para los clientes como para los suministradores de energía eléctrica en tiempo real.

Así pues, tanto la recolección de datos como el sistema de mensajes informativos y alarmas ha sido estático en el presente proyecto. Se han utilizado datos de seis municipios distintos de España y se han obtenido los datos de la temperatura propios de las fechas de los datos de consumo eléctrico con los que se contaba.

Dentro del procesamiento de datos, se han implementado algoritmos de clustering con vistas al descubrimiento de patrones de consumo de energía eléctrica dentro de los clientes. Se han realizado distintos modelos de datos para las diferentes tablas con las que se ha desarrollado el trabajo.

En el cálculo de la demanda agregada, se han tenido en cuenta factores geográficos, de calendario y de temperatura, y se ha estudiado la influencia de estos factores en el consumo de los clientes, así como la fiabilidad de los clientes a su patrón de consumo, esto es, la estabilidad del cliente a seguir siempre el mismo patrón de consumo eléctrico.

4. Resultados

El desarrollo de la interfaz gráfica de usuario implementa las dos funcionalidades principales en las que se ha centrado el estudio, estas son, el cálculo de la demanda agregada para las distintas casuísticas, y la fiabilidad de los clientes a su patrón de consumo de energía eléctrica.

En la Ilustración 2 se encuentra el programa desarrollado, donde el usuario puede introducir los datos de forma sencilla y obtener todos los resultados de manera visual y agrupada.




Ilustración 2 – Interfaz gráfica de usuario desarrollada

5. Conclusiones

Gracias al perfilado de los distintos clientes en función de su geografía y características de calendario y de temperatura, se conoce mejor el consumo del sector no residencial, así como los patrones de consumo más recurrentes y los más característicos.

Las conclusiones extraíbles de esta prueba realizada con la muestra de datos son que la demanda y el patrón de consumo de los clientes cambia en función del día de la semana, e incluso lo hace también en función de la temperatura que haga ese día.

Se han propuesto acciones con vistas a la optimización de la gestión activa de la demanda, que, con la ayuda de la implementación de la arquitectura de comunicaciones en dos niveles, serán capaces de comunicarse de forma instantánea a los consumidores no residenciales objetivos.

Se deja abierto como un posible trabajo futuro la integración de este estudio con un sistema de recopilación de datos en tiempo real, pudiendo así implementar alarmas y mensajes instantáneos que puedan servir de ayuda para la optimización de la gestión activa de la demanda, tanto para los consumidores como para los productores de energía.

DETERMINATION OF ELECTRICAL POWER CONSUMPTION PROFILES IN A SAMPLE OF CLIENTS OF THE NON-RESIDENTIAL SECTOR IN SPAIN

Author: Fernández Sánchez, Jaime.

Supervisor: Sanz Bobi, Miguel Ángel.

Supervisor: Rodríguez López, Miguel Ángel.

Collaborating Entity: ICAI – Universidad Pontificia Comillas.

ABSTRACT

The most characteristic patterns of electricity consumption have been extracted from a sample of clients from the non-residential sector in Spain. In addition, the influence of geographical, calendar and temperature circumstances on these patterns and on the aggregate demand for electrical energy has been studied, with the objective of extracting knowledge about the electrical demand of this sector and the optimization of the active management of the demand.

Keywords: Patterns, electrical demand, optimization, non-residential sector

1. Introduction

The use of electric power represents a great increase in the quality of life of our society. For this reason, its use is increasingly high and, therefore, the exploitation of primary resources is also higher.

Over the years, the total electricity consumption in Spain is increasing. Consequently, an increase in cost for the final customer is obtained, since electric power suppliers must give solution to the growing demands and peaks of energy.

The present project, *Determination of Electrical Power Consumption Profiles in a Sample of Clients of the Non-Residential Sector in Spain*, raises the study of the consumption of electric power at the level of the industrial sector and the service sector to better know the characteristic profiles of this demand that is a significant part of total energy consumption in Spain, and the similarity of consumer behavior under these profiles. This knowledge will allow decisions to be made on possible measures to be implemented to optimize the use of responsible electric power, reducing both the environmental impact and the economic expense at the user level.

2. Project definition

The process carried out begins with obtaining the information. For the realization of this project, data has been acquired from two different sources; the first is from where the data referring to the active and reactive energy consumed by a client was obtained at a date in a specific municipality, and the second source is the Agencia Estatal de Meteorología (AEMET), where the relative data to the temperature in a city on a specific day was obtained. The temperature data will complement the study of electrical consumption data, which are the most important of this project.

The next step was the preprocessing of the data. For this, focusing on the data of electric consumption, firstly, the data had to be adapted in order to be able to work with them in

a comfortable way, because the initial set had 83 columns and more than 32 million rows. Afterwards, the data was cleaned, which consisted in eliminating those data that were incomplete, and finally a reduction of the data was made, eliminating those columns that did not add any valuable information, as well as selecting those rows that were important for the study.

Subsequently, modeling was carried out, for which the original data had to be divided into a training set and a test set. The algorithm was implemented, the model was trained with the training set and the most appropriate model was selected. With the test set, the model was validated, ensuring that no adjustment was made.

Following the above, it was decided to carry out an individualized analysis to each of the clients, studying how faithful they are to their consumption pattern, thus recognizing those customers who normally have the same consumption and those who are more unpredictable.

A graphical user interface was created which grouped all the functionality developed in a single point. Lastly, the analysis of the results was carried out, being able to propose actions trying to optimize the active management of demand and integration with residential consumption.

3. System description

The purpose of the work is to optimize the demand for electrical energy, and for this purpose, mainly two functionalities are covered, which are the aggregate demand calculation and the reliability calculation of the clients. For this, and after the collection of all data, it is necessary to perform a data processing, as it is shown in Illustration 1.




Illustration 1 – System flow

The present project carries out its study on a sample of clients of the non-residential sector in Spain, but the idea is that this study serves as a prototype for other studies that integrate the obtaining of data in real time, allowing to generate the curve of the energy demand electric instantaneously for each moment, and creating the opportunity to develop a system of informative messages and alarms both for customers and for electric power suppliers in real time.

Thus, both the data collection and the system of informative messages and alarms has been static in the present project. Data from six different municipalities in Spain have been used and the temperature data of the dates of the electricity consumption data that were available were obtained.

Within the data processing, clustering algorithms have been implemented with the objective of discovering patterns of electric power consumption within the clients. Different data models have been made for the different tables with which the work has been developed.

In calculating aggregate demand, geographic, calendar and temperature factors have been considered, and the influence of these factors on the customers' consumption has been studied, as well as the reliability of the customers to their consumption pattern, that is, the stability of the client to always follow the same pattern of electrical consumption.

4. Results

The development of the graphical user interface implements the two main functionalities on which the study has focused, these are, the calculation of the aggregate demand for the different cases, and the reliability of the clients to their electric power consumption pattern.

In the Illustration 2 the developed program is shown, where the user can enter the data in a simple way and obtain all the results in a visual and grouped way.




Illustration 2 – Graphical user interface developed

5. Conclusions

Thanks to the profiling of the different clients according to their geography and calendar and temperature characteristics, the consumption of the non-residential sector is better known, as well as the most recurrent and most characteristic consumption patterns.

The extractable conclusions of this test carried out with the data sample is that the demand and the consumption pattern of the customers change according to the day of the week, and even it does so depending on the temperature that day.

Actions have been proposed with a view to optimizing the active management of demand, which, with the help of the implementation of the two-level communications architecture, will be able to communicate instantaneously to target non-residential consumers.

It is left open as a possible future work the integration of this study with a system of data collection in real time, being able to implement alarms and instant messages that can help to optimize the active management of demand, both for the consumers as well as for energy producers.

Índice de la memoria

Capítulo 1. Introducción	11
1.1 Motivación del Proyecto	12
1.2 Definición del Proyecto.....	13
Capítulo 2. Descripción de las Tecnologías.....	15
2.1 Herramientas	15
2.1.1 MATLAB.....	15
2.1.2 Terminal de Linux.....	15
2.2 Algoritmos Machine Learning Utilizados	16
2.2.1 Mapas Autoorganizados de Kohonen.....	16
2.2.2 Clustering Jerárquico.....	16
2.2.3 K-means.....	17
Capítulo 3. Estado del Arte.....	19
3.1 El Consumo Eléctrico en Nuestra Sociedad	19
3.2 El Consumo no Residencial en Nuestra Sociedad.....	20
3.2.1 El Consumo del Sector Industrial.....	21
3.2.2 El Consumo del Sector Servicios.....	21
Capítulo 4. Definición del Trabajo	23
4.1 Justificación.....	23
4.2 Objetivos	23
4.2.1 Estudiar las Necesidades de un Sistema de Comunicaciones de Consumo de Energía entre Suministrador y Cliente con Objeto de Proporcionar una Arquitectura Adecuada a los Servicios Requeridos	24
4.2.2 Análisis del Consumo de la Energía Eléctrica en una Muestra del Sector no Residencial en España	24
4.2.3 Proponer Acciones con Vistas a la Optimización de la Gestión Activa de la Demanda e Integración con el Consumo Residencial	25
4.3 Metodología de Trabajo	26
4.4 Planificación.....	28
4.5 Estimación Económica	29
Capítulo 5. Arquitectura de Comunicaciones	33

Capítulo 6. Obtención de la Información	35
Capítulo 7. Preprocesamiento de los Datos	39
7.1 Adaptación de los Datos.....	39
7.2 Limpieza de los Datos	40
7.3 Reducción de los Datos	41
7.3.1 Selección de Características	41
7.3.2 Selección de Instancias.....	43
7.4 Incorporación de Nuevas Características	45
7.4.1 Día de la Semana.....	45
7.4.2 Temperatura del Día	45
7.5 División en Distintas Tablas.....	48
Capítulo 8. Modelado	51
8.1 Muestra de Entrenamiento y de Test	51
8.2 Implementación de Algoritmos	54
8.2.1 Kmeans	54
8.2.2 Clustering Jerárquico.....	59
8.2.3 Mapas Autoorganizados de Kohonen.....	62
8.3 Entrenamiento del Modelo	65
Capítulo 9. Validación del Modelo.....	69
9.1 Prueba del Modelo.....	69
Capítulo 10. Fidelidad de los Clientes	73
Capítulo 11. Interfaz Gráfico de Usuario	81
11.1 Capa de Presentación.....	81
11.2 Capa de Consultas	85
Capítulo 12. Análisis de Resultados.....	91
12.1 Madrid	91
12.2 Barcelona.....	94
12.3 Cáceres	96
12.4 La Coruña	99
12.5 Málaga	102

12.6 Valencia.....	106
12.7 Comparativa	109
Capítulo 13. Conclusiones y Trabajos Futuros.....	113
Capítulo 14. Bibliografía.....	115
ANEXO A – Error de Cuantificación.....	119
ANEXO B – Error de Clustering	143
ANEXO C – Patrones de Consumo Eléctrico.....	165

Índice de figuras

Figura 1. Generación y demanda anuales de energía eléctrica en España	11
Figura 2. Porcentaje de consumo de energía eléctrica en España por sector [2].....	12
Figura 3. Consumo horario de energía eléctrica por sectores en España en un día de invierno [4]	19
Figura 4. Centro de Control Eléctrico de Red Eléctrica de España [12]	20
Figura 5. Uso porcentual de energía eléctrica en relación con el gasto energético total por actividad [13].....	21
Figura 6. Porcentaje de consumo de energía eléctrica del sector servicios por actividad [14]	22
Figura 7. Diagrama de Gantt del proyecto	29
Figura 8. Arquitectura de comunicaciones en dos niveles	34
Figura 9. Reducción de características e instancias.....	41
Figura 10. Histograma de las temperaturas medias de Valencia.....	46
Figura 11. Histograma de las temperaturas máximas de Cáceres	47
Figura 12. División de cada tabla de municipio en distintas tablas.....	48
Figura 13. División en conjuntos de entrenamiento y de test [17].....	51
Figura 14. Subajuste, ajuste correcto y sobreajuste [21]	53
Figura 15. Descenso de error cuantificado para los domingos de Barcelona.....	55
Figura 16. Descenso de error cuantificado para los lunes de Barcelona	55
Figura 17. Clusters obtenidos por kmeans para los domingos de Barcelona	56
Figura 18. Clusters obtenidos por kmeans para los lunes de Barcelona.....	57
Figura 19. Clusters obtenidos por kmeans para los distintos días de la semana de Madrid	58
Figura 20. Dendrogramas de los clusters obtenidos para los distintos días de la semana de Madrid	59
Figura 21. Patrones obtenidos en los martes de Valencia	66
Figura 22. Número de instancias que se han clasificado en cada neurona los martes de Valencia	66
Figura 23. Consumo total en W*h por cada neurona en los martes de Valencia	67

Figura 24. Consumo medio en W*h por hora y por cada neurona en los martes de Valencia	67
Figura 25. Consumos de energía eléctrica por un cliente por día de la semana a lo largo de un año	73
Figura 26. Consumo medio horario del cliente 5649 los lunes con temperatura media en Barcelona.....	77
Figura 27. Clasificación por neurona para días de la semana de los consumos del cliente 5649	77
Figura 28. Clasificación por neurona para las distintas temperaturas de los consumos del cliente 5649	78
Figura 29. Consumo medio horario del cliente 14408 los lunes con temperatura media en Barcelona.....	78
Figura 30. Clasificación por neurona para días de la semana de los consumos del cliente 14408	79
Figura 31. Clasificación por neurona para las distintas temperaturas de los consumos del cliente 14408	79
Figura 32. Presentación de la interfaz gráfica de usuario.....	81
Figura 33. Ejemplo de la interfaz gráfica de usuario con datos de entrenamiento.....	82
Figura 34. Ejemplo de la interfaz gráfica de usuario con las últimas cuatro lecturas de los datos de test	83
Figura 35. Pantalla explicativa de la fidelidad al patrón	83
Figura 36. Ejemplo de la interfaz gráfica de usuario con datos de entrenamiento y de test	84
Figura 37. Demanda agregada para Valencia durante distintos miércoles.....	86
Figura 38. Consumos similares de un cliente con los datos de entrenamiento y de test	87
Figura 39. Consumos distintos de un cliente con los datos de entrenamiento y de test	88
Figura 40. Consumo eléctrico agregado por día de la semana en Madrid a lo largo de un año	91
Figura 41. Demanda eléctrica agregada estimada para Madrid.....	93
Figura 42. Consumo eléctrico agregado por día de la semana en Barcelona a lo largo de un año	94

Figura 43. Demanda eléctrica agregada estimada para Barcelona	96
Figura 44. Consumo eléctrico agregado por día de la semana en Cáceres a lo largo de un año	97
Figura 45. Demanda eléctrica agregada estimada para Cáceres.....	98
Figura 46. Consumo eléctrico agregado por día de la semana en La Coruña a lo largo de un año	99
Figura 47. Consumo eléctrico agregado por día de la semana en La Coruña a lo largo de tres meses	100
Figura 48. Demanda eléctrica agregada estimada para La Coruña	102
Figura 49. Consumo eléctrico agregado por día de la semana en Málaga a lo largo de un año	103
Figura 50. Demanda eléctrica agregada estimada para Málaga	104
Figura 51. Consumo eléctrico agregado por día de la semana en Valencia a lo largo de un año	106
Figura 52. Demanda eléctrica agregada estimada para Valencia	108
Figura 53. Consumo eléctrico agregado por día de la semana con todos los datos a lo largo de un año.....	109
Figura 54. Consumo eléctrico agregado por día de la semana con todos los datos durante tres meses	110
Figura 55. Demanda eléctrica estimada para el caso de los datos de todos los municipios unidos	111

Índice de tablas

Tabla 1. Relación entre tareas y objetivos	27
Tabla 2. Desglose de costes de personal del proyecto.....	31
Tabla 3. Relación entre tareas y objetivos	61
Tabla 4. Dimensiones para las distintas tablas	65
Tabla 5. Porcentaje de clientes cuya neurona predominante fue la misma con los datos de test.....	72
Tabla 6. Dimensiones utilizadas para los mapas autoorganizados en Madrid	92
Tabla 7. Porcentaje de clientes cuya neurona predominante fue la misma en Madrid.....	92
Tabla 8. Dimensiones utilizadas para los mapas autoorganizados en Barcelona	95
Tabla 9. Porcentaje de clientes cuya neurona predominante fue la misma en Barcelona ...	95
Tabla 10. Dimensiones utilizadas para los mapas autoorganizados en Cáceres	97
Tabla 11. Porcentaje de clientes cuya neurona predominante fue la misma en Cáceres.....	98
Tabla 12. Dimensiones utilizadas para los mapas autoorganizados en La Coruña	101
Tabla 13. Porcentaje de clientes cuya neurona predominante fue la misma en La Coruña	101
Tabla 14. Dimensiones utilizadas para los mapas autoorganizados en Málaga	103
Tabla 15. Porcentaje de clientes cuya neurona predominante fue la misma en Málaga ...	104
Tabla 16. Dimensiones utilizadas para los mapas autoorganizados en Valencia.....	107
Tabla 17. Porcentaje de clientes cuya neurona predominante fue la misma en Valencia .	107
Tabla 18. Clientes por provincia en porcentaje	109
Tabla 19. Dimensiones utilizadas para los mapas autoorganizados para todos los datos juntos	111
Tabla 20. Porcentaje de clientes cuya neurona predominante fue la misma para todos los datos juntos	111

Capítulo 1. INTRODUCCIÓN

Con el paso de los años, el consumo de energía eléctrica total en España está aumentando. Se obtiene como consecuencia un aumento de coste para el cliente final, debido a que los proveedores de energía eléctrica tienen que dar solución a cada vez mayores demandas y picos de energía.

En la Figura 1 se muestra en azul la generación anual de energía eléctrica en España, y en rojo la demanda anual. Como se observa, el consumo ha superado la producción en los últimos dos años, obteniendo como consecuencia una importación de energía eléctrica mayor a la exportación. Los datos para la elaboración de esta figura se han extraído de Red Eléctrica de España [1].




Figura 1. Generación y demanda anuales de energía eléctrica en España

El uso de la energía eléctrica supone un gran aumento en la calidad de vida de nuestra sociedad. Por este motivo su uso es cada vez más elevado y, por tanto, la explotación de los recursos primarios es también más elevada.

En la actualidad, la energía eléctrica se obtiene fundamentalmente de los combustibles fósiles, pero el aumento en su demanda origina un gran impacto medioambiental. En los últimos años la preocupación se ha extendido a nivel mundial y, por este motivo, se han

fomentado el uso de las energías renovables, además, del intento de concienciar a la sociedad del consumo responsable. La finalidad de estas medidas es reducir las consecuencias del problema expuesto anteriormente.

El presente proyecto, *Determinación de Perfiles de Consumo de Energía Eléctrica en una Muestra de Clientes del Sector no Residencial en España*, plantea el estudio del consumo de la energía eléctrica a nivel del sector industrial y del sector servicios con objeto de conocer mejor los perfiles característicos de esta demanda que es una parte significativa del consumo energético total en España, y la similitud de comportamiento de los consumidores bajo estos perfiles. Este conocimiento permitirá tomar decisiones sobre posibles medidas a poner en marcha para optimizar el uso de la energía eléctrica responsable, reduciendo tanto el impacto ambiental como el gasto económico a nivel usuario.

1.1 MOTIVACIÓN DEL PROYECTO

Se han llevado a cabo distintos estudios sobre la determinación de perfiles en el sector residencial, pero no ocurre lo mismo en el sector no residencial [2][3][4]. Es por ello por lo que se cree conveniente indagar este aspecto mediante la realización de este trabajo de fin de máster *Determinación de Perfiles de Consumo de Energía Eléctrica en una Muestra de Clientes del Sector no Residencial en España*.



Figura 2. Porcentaje de consumo de energía eléctrica en España por sector [2]

Además, como se observa en la Figura 2, el sector residencial constituye tan solo el 25,1% del consumo eléctrico en España, y a pesar de ello es el sector en el que más estudios se centran. Del 74,9% del consumo restante, el 26,3% pertenece al sector servicios y el 44,1% al sector industrial. Hay un 4,5% que pertenece al transporte, la agricultura y otros.

La motivación de este escrito es, por tanto, conocer mejor las demandas de energía eléctrica en el sector no residencial con objeto de analizar si hay posibilidad de tomar alguna medida de mejor uso de la energía y de mejorar la integración con el consumo residencial, además de servir de gran ayuda para la planificación del suministro eléctrico.

1.2 DEFINICIÓN DEL PROYECTO

El presente proyecto surge con la necesidad de conocer mejor el consumo de energía eléctrica del sector no residencial en España. Como se ha observado, mientras que una gran cantidad de estudios se centran en el consumo eléctrico del sector residencial, el sector no residencial se encuentra más inexplorado, a pesar de que tiene un mayor peso en el consumo eléctrico total en España.

Como se ha explicado en [la motivación de este proyecto](#), la finalidad será conocer mejor las demandas de energía eléctrica en el sector no residencial. Para ello, primero se tratará de identificar tipos de perfiles de consumo de la energía eléctrica dentro de este sector, más adelante se hará un estudio por zonas geográficas y por influencia de los factores estacionales y de calendario. Una vez se conozca todo esto, se tratará de prever los consumos de los usuarios, para más adelante predecir la demanda agregada de energía eléctrica para un día cualquiera, con objeto de planificar recursos. Por último, se tratará de proponer acciones con vistas a la optimización de la gestión activa de la demanda e integración con el consumo residencial que se comunicarán al cliente vía mensajes instantáneos de correo electrónico ofreciéndole alternativas para cambiar, en los momentos necesarios, el perfil de demanda eléctrica.

Para ello, el proceso que se va a realizar comienza con la obtención de la información. Para la realización de este trabajo, se han adquirido datos de dos fuentes distintas; la primera es de donde obtuvimos los datos referentes a la energía activa y reactiva

consumida por un cliente en una fecha en un municipio concreto, y la segunda fuente es la Agencia Estatal de Meteorología (AEMET), donde se consiguieron los datos relativos a la temperatura en una ciudad un día concreto [5]. Los datos de la temperatura ayudarán a complementar el estudio de los datos de consumos eléctricos, que son la piedra angular de este trabajo.

El siguiente paso fue el preprocesamiento de los datos. Para ello, centrándonos en los datos de consumo eléctrico, primeramente, hubo que adaptar los datos para poder trabajar con ellos de una forma cómoda, debido a que el conjunto inicial del que se partía constaba de 83 columnas y más de 32 millones de filas. Seguidamente, se hizo una limpieza de los datos que consistió en eliminar aquellos datos que estaban incompletos, y por último se realizó una reducción de los datos, eliminando aquellas columnas que no nos añadían ninguna información, así como seleccionando aquellas filas que eran importantes para el estudio.

Posteriormente, se procedió a realizar el modelado, para lo cual hubo que dividir los datos originales en un conjunto de entrenamiento y uno de test. Se implantó el algoritmo, se entrenó con el conjunto de entrenamiento y se seleccionó el modelo más adecuado. Con el conjunto de test se pasó a validar el modelo, asegurando que no se había realizado sobreajuste.

Siguiendo a lo anterior, se decidió realizar un análisis individualizado a cada uno de los clientes, estudiando cómo de fieles son a su patrón de consumo, reconociendo así a aquellos clientes que normalmente tienen el mismo consumo y a aquellos que son más impredecibles.

Se realizó una interfaz gráfica de usuario que agrupara toda la funcionalidad desarrollada en un mismo punto desde la simplicidad.

Con esto, ya se pasó a realizar el análisis de los resultados, pudiendo entonces proponer acciones con vistas a la optimización de la gestión activa de la demanda e integración con el consumo residencial.

Capítulo 2. DESCRIPCIÓN DE LAS TECNOLOGÍAS

Dada la naturaleza del proyecto, en este apartado se van a describir tanto las herramientas utilizadas como los algoritmos de aprendizaje automático utilizados para identificar patrones.

2.1 HERRAMIENTAS

2.1.1 MATLAB

MATLAB es un entorno de cálculo técnico de altas prestaciones para cálculo numérico y visualización que integra análisis numérico, cálculo matricial, procesamiento de señales y gráficos [6].

Se ha utilizado esta herramienta para el desarrollo de scripts utilizados para tratar los datos, ejecutar los modelos creados con la ayuda de los distintos algoritmos y obtener los resultados del proyecto.

Además, MATLAB también proporciona una serie de soluciones específicas denominadas toolboxes. Son conjuntos de funciones MATLAB que extienden el entorno MATLAB para resolver clases particulares de problemas [7]. En el caso de este trabajo de fin de máster, se utilizará la toolbox de redes neuronales artificiales, que permite diseñar, entrenar, visualizar y simular una red.

2.1.2 TERMINAL DE LINUX

Debido a que el archivo original con el que se ha trabajado es de un gran tamaño, no se podía ejecutar directamente desde MATLAB. Por ello, se buscó una herramienta de apoyo simple pero potente como es el terminal de Linux, el cual permite hacer consultas sobre los datos.

De esta forma, se pudo realizar un análisis previo de los datos antes de empezar a tratarlos con MATLAB.

2.2 ALGORITMOS MACHINE LEARNING UTILIZADOS

Se han empleado distintos algoritmos de aprendizaje automático con la finalidad de agrupar a los distintos clientes según su consumo de energía eléctrica.

El campo de aprendizaje automático que se encarga de agrupar instancias u obtener clusters según su comportamiento es el aprendizaje no supervisado [8]. En estos casos, los datos que se proporcionan al algoritmo están constituido solamente por entradas, no hay una salida preestablecida, sino que será el propio algoritmo el encargado de proporcionar la salida, como puede ser la agrupación de los datos de entrada.

2.2.1 MAPAS AUTOORGANIZADOS DE KOHONEN

Los mapas autoorganizados de Kohonen son un tipo de red neuronal artificial que trata de descubrir rasgos comunes, regularidades, correlaciones o categorías en los datos de entrada, e incorporarlos a su estructura interna de conexiones. Se dice, por tanto, que las neuronas deben autoorganizarse en función de los estímulos (datos) procedentes del exterior [9].

El objetivo de este aprendizaje es categorizar los datos que se introducen en la red. Se clasifican valores similares en la misma categoría y, por tanto, deben activar la misma neurona de salida.

2.2.2 CLUSTERING JERÁRQUICO

La finalidad del clustering jerárquico es la agrupación de datos para formar clusters minimizando las distancias entre datos clasificados [10].

Los métodos jerárquicos permiten la construcción de un árbol de clasificación, que recibe el nombre de dendrograma, en el cual se puede seguir de forma gráfica y sencilla el procedimiento de unión seguido, mostrando qué grupos se van uniendo y el nivel concreto en el que lo hacen.

2.2.3 K-MEANS

K-means es un algoritmo machine learning utilizado para agrupar datos. El algoritmo funciona iterativamente para asignar cada ejemplo incluido en los datos de entrenamiento a uno de los grupos K en función de las características que se proporcionan. Los ejemplos se agrupan según la similitud de características [11]. Una vez el modelo ha convergido, los centroides obtenidos sirven como prototipo o patrón de los clusters que se pueden encontrar en los datos.

Capítulo 3. ESTADO DEL ARTE

Este trabajo de fin de máster trata de complementar el trabajo de fin de grado realizado por Jorge García-Morales Merino en la Universidad Pontificia Comillas en el curso 2016-2017 titulado *Análisis de perfiles de consumo de energía eléctrica en una muestra de clientes del sector residencial* [3].

En este capítulo se van a enumerar los distintos estudios que se han realizado sobre el consumo eléctrico en España.

3.1 EL CONSUMO ELÉCTRICO EN NUESTRA SOCIEDAD

Como se observa en la Figura 3, el consumo eléctrico en España tiene unas horas valle durante la noche y unas horas punta a media mañana y a última hora de la tarde. Además, también se puede ver que el sector industrial es aproximadamente el mismo a cualquier hora del día, sin embargo, el sector residencial y el sector servicios son muy desiguales a lo largo de las horas del día. Estos dos sectores bajan mucho su consumo eléctrico durante la noche, siendo los causantes de las horas valle. El sector servicios es el que tiene mayor peso en las horas punta de la mañana y el sector residencial tiene mayor peso en las horas de la tarde.




Figura 3. Consumo horario de energía eléctrica por sectores en España en un día de invierno [4]

Como se ha explicado en [la motivación de este proyecto](#), el 25,1% del consumo eléctrico en España es constituido por el sector residencial, el 26,3% por el sector servicios, el 44,1% por el sector industrial y el 4,5% restante por el transporte, la agricultura y otros.

Debido a que la energía eléctrica no puede almacenarse en grandes cantidades, es necesario igualar la producción de forma precisa al consumo que hay en cada momento. El operador que se encarga de este equilibrio en España es Red Eléctrica, para ello, prevé el consumo, opera y supervisa las instalaciones de generación y transporte para que la producción programada en las centrales coincida en todo momento con la demanda real de los consumidores.

En la Figura 4 podemos ver el Centro de Control Eléctrico de Red Eléctrica de España, que es responsable de la operación y supervisión coordinada en tiempo real de las instalaciones de generación y transporte del sistema eléctrico nacional [12].



Figura 4. Centro de Control Eléctrico de Red Eléctrica de España 0[12]

3.2 EL CONSUMO NO RESIDENCIAL EN NUESTRA SOCIEDAD

En este apartado se va a explicar cómo es el consumo de energía eléctrica en el sector industrial y en el sector servicios, esto es, los sectores en los que se basa este proyecto.

3.2.1 EL CONSUMO DEL SECTOR INDUSTRIAL

El sector industrial tiene un consumo eléctrico muy estable y continuo, como ya vimos en la Figura 3. Muchas industrias necesitan hacer el mismo consumo durante todas las horas de la noche y del día debido a su actividad, pero hay otro gran grupo de industrias que desplazan todo lo posible su consumo hacia las horas nocturnas debido a que a esas horas el coste de la electricidad es menor. El consumo eléctrico de este sector es el mayor de todos los sectores, siendo el 44,1% del consumo eléctrico total.

Como se observa en la Figura 5, sea cual sea su actividad, la gran mayoría de industrias del sector industrial hacen un gran uso de energía eléctrica dentro de todo el consumo energético que realizan, por lo que son unos grandes consumidores de energía eléctrica, y de ahí que se infiera que sea el sector que más consumo de energía eléctrica realiza.

Sectores de actividad	% Electricidad
Fabricación de componentes electrónicos y circuitos impresos ensamblados	92,8
Fabricación de productos electrónicos de consumo	91,9
Fabricación de artículos de peletería	86,7
Fabricación de artículos de joyería, bisutería y similares	86,4
Fabricación de instrumentos y suministros médicos y odontológicos	86,4
Fabricación de cables y dispositivos de cableado	84,2
Fabricación de ordenadores y equipos periféricos	84,0
Fabricación de equipos de telecomunicaciones	83,2
Equipos de radiación y electromédicos; instrumentos de óptica y fotográficos; soportes magnéticos y ópticos	82,2
Fabricación de artículos de corcho, cestería y espartería y otros productos de madera	80,2

Figura 5. Uso porcentual de energía eléctrica en relación con el gasto energético total por actividad [13]

3.2.2 EL CONSUMO DEL SECTOR SERVICIOS

El consumo eléctrico del sector servicios constituye el 26,3% del total. Presenta su hora punta a mediodía, aunque tiene un segundo máximo a últimas horas de la tarde. Durante las horas nocturnas decrece mucho, pero en ningún momento llega a ser despreciable su consumo.

**Estructura del consumo eléctrico del sector servicios
por ramas, 2015 ⁽⁷⁾⁽⁸⁾⁽⁹⁾**




Figura 6. Porcentaje de consumo de energía eléctrica del sector servicios por actividad [14]

En la Figura 6 podemos observar que la mayor parte del consumo eléctrico del sector servicios proviene de la actividad del comercio, seguido por las oficinas. La hostelería y restauración, seguido por la sanidad y la educación formarían las cinco áreas de actividad del sector servicio que mayor consumo eléctrico realizan.

Capítulo 4. DEFINICIÓN DEL TRABAJO

4.1 JUSTIFICACIÓN

El consumo eléctrico del sector no residencial es el gran desconocido. Mientras que el sector residencial se ha analizado numerosas veces de forma muy detallada y minuciosa, los análisis realizados sobre el sector no residencial son muy superficiales.

Como se ha visto en [el estado del arte](#), el 70,4% del consumo eléctrico en España proviene del sector no residencial, y es por ello por lo que tratar de conocerlo mejor puede tener un gran impacto en la optimización de la gestión activa de la demanda.

Este proyecto trata de estudiar una muestra de clientes del sector no residencial con el objetivo de comprender los perfiles característicos de demanda de energía eléctrica en dicho sector. Para ello, se tratará de asociar a los distintos clientes según su consumo eléctrico. Se estudiará también la incidencia que tiene la región de los clientes, así como la repercusión en el consumo eléctrico de los factores estacionales y de calendario.

Una vez se conozca mejor la muestra de clientes, se pasará a prever el consumo de los clientes durante un día cualquiera, para más adelante agregarlos y obtener la demanda total pronosticada.

De esta forma, se podrán proponer acciones que se comunicarán de forma instantánea a los consumidores no residenciales con vistas a la optimización de la gestión activa de la demanda y se procederá a la integración con el consumo residencial.

4.2 OBJETIVOS

En este apartado se muestran los objetivos del proyecto, los cuales se engloban en tres grandes bloques.

4.2.1 ESTUDIAR LAS NECESIDADES DE UN SISTEMA DE COMUNICACIONES DE CONSUMO DE ENERGÍA ENTRE SUMINISTRADOR Y CLIENTE CON OBJETO DE PROPORCIONAR UNA ARQUITECTURA ADECUADA A LOS SERVICIOS REQUERIDOS

A pesar de que se ha realizado un análisis del consumo de energía eléctrica sobre una muestra del sector no residencial en España, y más adelante se ha realizado la propuesta de acciones con vistas a la optimización de la gestión activa de la demanda, con los resultados obtenidos, este proyecto ambiciona ser capaz en tiempo real de detectar cambios en el consumo de los distintos clientes, predecir la demanda agregada de energía eléctrica y enviar alertas tanto al consumidor que usa más energía que otros consumidores de características similares, o que simplemente está cambiando su forma de consumo, como al suministrador, informándole de las necesidades de generar más o menos energía dependiendo de las lecturas de los medidores que están en los hogares o en las industrias de los clientes. Sería necesario un sistema de comunicaciones con unos concentradores de datos que recojan la información a nivel local y que enviaran esta información a un nivel nacional que fuera capaz de hacer todas estas gestiones.

Todo lo que se crea en este proyecto es una prueba piloto, pero lo que se pretende es crear una arquitectura con servicios tanto de cara al comercial de la electricidad como al consumidor. Este trabajo puede ayudar a reducir la información a tratar y concentrar la atención en lo más significativo del servicio al cliente.

4.2.2 ANÁLISIS DEL CONSUMO DE LA ENERGÍA ELÉCTRICA EN UNA MUESTRA DEL SECTOR NO RESIDENCIAL EN ESPAÑA

El objetivo más importante fue analizar el consumo de energía eléctrica en una muestra del sector no residencial en España. Con ello, se buscó obtener un mejor conocimiento de los hábitos de consumo de los distintos clientes que formaban la muestra, así como descubrir cómo dicho consumo cambia en función de las condiciones geográficas, de calendario y de temperatura. Dentro de este objetivo, se definen otros tres subobjetivos.

A. Identificar Tipos de Perfiles de Uso de la Energía Eléctrica

Para tener un mejor entendimiento del consumo de energía eléctrica, un objetivo fundamental es la identificación de distintos tipos de perfiles de uso de la energía eléctrica. La agrupación de los clientes en función de sus consumos es de gran ayuda a la hora de interpretar qué tipos de perfil de consumo y qué clientes son los predominantes y cuáles son los más importantes.

B. Detectar Cambios en el Consumo de Energía Eléctrica de los Clientes

Para conocer cuándo la determinación de los perfiles de uso de la energía eléctrica para cada cliente es necesario saber interpretar los cambios en el consumo para cada cliente. Cuando los datos que se vayan integrando en el sistema para cada cliente no guarden relación con los datos utilizados para la realización del modelo, habrá que reajustar el mismo, y para ello, habrá que ser capaz de interpretar estos cambios.

C. Predecir la Demanda Agregada de Energía Eléctrica

El último objetivo dentro del análisis del consumo de la energía eléctrica en el sector no residencial es el de predecir la demanda agregada para todos los clientes conocidas ciertas condiciones como son la ciudad, el día de la semana y la temperatura del día. Conocida la demanda agregada, es posible sacar conclusiones sobre el efecto que tienen las distintas variables.

4.2.3 PROPONER ACCIONES CON VISTAS A LA OPTIMIZACIÓN DE LA GESTIÓN ACTIVA DE LA DEMANDA E INTEGRACIÓN CON EL CONSUMO RESIDENCIAL

Una vez se ha realizado el estudio sobre el consumo de energía eléctrica en la muestra del sector no residencial en España, es posible la propuesta de acciones con vistas a la optimización de la gestión activa de la demanda. Como se observó en el [estado del arte](#), la energía eléctrica no puede almacenarse en grandes cantidades, es necesario igualar la producción de forma precisa al consumo que hay en cada momento, y por ello adquiere una gran importancia ser capaz de optimizar la demanda. También es interesante integrar

las acciones con el consumo residencial, dado que partimos del estudio realizado sobre este sector [3].

4.3 METODOLOGÍA DE TRABAJO

Los algoritmos de aprendizaje automático que se han desarrollado han permitido caracterizar el comportamiento observado a través de patrones que extraen las características más significativas de consumo eléctrico no residencial a partir de una muestra representativa de usuarios y sus consumos.

Se han realizado modelos de pronóstico basados en los patrones encontrados teniendo en cuenta factores de geografía, temperatura y de calendario.

A continuación, se enumeran las distintas tareas que se han realizado.

- T1. Obtención de los conjuntos de datos de consumo eléctrico y de AEMET.
- T2. Pre-análisis de datos, pre-filtrado y preparación de conjuntos de entrenamiento para crear los patrones de uso de la energía eléctrica.
- T3. Segmentación de la población disponible.
- T4. Aplicación de técnicas de machine learning para descubrimiento de patrones: mapas autoorganizados, clustering jerárquico, k-means.
- T5. Análisis de las influencias de factores geográficos, de temperatura y de calendario en los patrones encontrados.
- T6. Verificación de la bondad de patrones. Métodos de chequeo cruzado de consistencias.
- T7. Estudio individual del consumo eléctrico de los usuarios. Validación de los datos de test.
- T8. Agregación de las demandas eléctricas individuales.
- T9. Elaboración de una interfaz gráfica de usuario donde mostrar la demanda agregada filtrando para distintas situaciones.
- T10. Propuesta de acciones de mejora.
- T11. Informe de trabajo de fin de máster.

DEFINICIÓN DEL TRABAJO

Las tareas se han realizado de acuerdo con la consecución de los [objetivos planteados](#) para este proyecto. En la Tabla 1 se muestran las relaciones entre las tareas y los objetivos enunciados.

<i>Tarea</i>	<i>Objetivo</i>	<i>Subobjetivo</i>
T1	O1. Estudio Sistema de Comunicaciones	-
T2	O2. Análisis del Consumo	-
T3	O2. Análisis del Consumo	-
T4	O2. Análisis del Consumo	A. Identificar Tipos de Perfiles
T5	O2. Análisis del Consumo	A. Identificar Tipos de Perfiles
T6	O2. Análisis del Consumo	A. Identificar Tipos de Perfiles
T7	O2. Análisis del Consumo	B. Detectar Cambios de Consumo
T8	O2. Análisis del Consumo	C. Predecir la Demanda Agregada
T9	O2. Análisis del Consumo	C. Predecir la Demanda Agregada
T10	O3. Proponer Acciones	-
T11	General	-

Tabla 1. Relación entre tareas y objetivos

La última tarea, T11, es indispensable para la buena realización del resto de los objetivos, pero no está directamente relacionada con ninguno de los objetivos, dado que actúa como soporte de todo el estudio realizado.

Dentro de las tareas realizadas con la finalidad de cumplir el primer objetivo, las tareas T2 y T3 son previas a los tres subobjetivos que se encuentran dentro del primer objetivo, y por ello no están relacionadas de forma directa con ningún subobjetivo.

4.4 PLANIFICACIÓN

Una vez se obtuvieron los datos de consumo eléctrico, fue necesario preparar el conjunto de datos antes de empezar a trabajar con él, además de seleccionar las variables y las tuplas de interés.

Se trabajó a continuación en la identificación de perfiles en el consumo de los clientes, para lo cual se necesitó la ayuda de tres algoritmos machine learning. De forma paralela, se fue estudiando la influencia estacional y de calendario. Además, se decidió realizar también el estudio sobre la influencia de la temperatura en el consumo eléctrico. Para ello, fue necesario obtener datos de AEMET.

Una vez se había avanzado en la identificación de los distintos perfiles en el consumo y en el análisis de la influencia de los factores estacionales y de calendario, se trabajó en la previsión de consumo de cada cliente, y cuando el estudio de esta previsión acabó, se pasó a calcular la demanda agregada de energía eléctrica en función de los distintos factores.

Todo el trabajo se fue realizando primeramente para las ciudades de Barcelona y de Madrid, y una vez se habían confirmado los avances para estas dos ciudades, se realizaba el mismo estudio sobre el resto de las ciudades seleccionadas en las que había diferentes condiciones ambientales y geográficas, que son Cáceres, La Coruña, Málaga y Valencia.

Por último, cuando se empezó a obtener resultados, se inició la redacción de la memoria de fin de máster, realizando al final del todo y una vez el estudio sobre los datos habían acabado las propuestas de acciones con vistas a la optimización de la gestión activa de la demanda.

Se realizaron reuniones con el director a lo largo de todo el proyecto para establecer las directrices en cada fase de este, así como para confirmar que el avance que se obtenía era el adecuado.

En la Figura 7 se puede observar el diagrama de Gantt del proyecto, donde se pueden apreciar las tareas principales, así como las subtareas en las que se ha dividido la realización de este proyecto.




Figura 7. Diagrama de Gantt del proyecto

4.5 ESTIMACIÓN ECONÓMICA

En esta sección se va a llevar a cabo una estimación del coste económico del proyecto. En primer lugar, se deben definir los diferentes costes que existen en la realización del proyecto. Estos son costes de: hardware, software y personal.

- **Coste hardware.** Para la realización de este proyecto se necesitó un ordenador para realizar todo el estudio sobre los datos. En el caso que nos corresponde, se utilizó una Surface Pro 3 con 8 GB de RAM y un procesador i5. Este dispositivo no se incluyó en el resultado final, ya que no es un producto que se entregara con el proyecto. Solo fue necesario para el desarrollo, por lo que no se cuenta con coste hardware.
- **Coste software.** No se requirió de ningún software de pago, debido a que la licencia de MATLAB es gratuita para los universitarios, por lo que el coste de este tipo es nulo.
- **Coste de personal.** Un crédito académico equivale a 25 horas de trabajo del alumno [15]. Dado que este proyecto tiene asignados 12 créditos académicos, se

estima en 300 horas el trabajo empleado por el alumno en él. También hay que contar con las horas de trabajo empleadas por el director del proyecto, que se estiman en 50 horas.

En cuanto al coste de personal, se definen los diferentes actores que han participado en el proyecto, para explicar las horas estimadas para cada actor:

- Director de proyecto. Se trata de un experto en el área de la analítica de datos, con experiencia en la dirección de proyectos. Fue el encargado de asegurar que los plazos estimados se fueran cumpliendo y de que el resultado siguiera los objetivos que se habían de cumplir. Planificó y controló todo el proyecto, por lo que participó en toda su duración.
- Analista de datos. Fue el encargado de llevar a cabo el proyecto. Sobre él recayó la mayor parte del peso y de las horas del proyecto. Conoce a fondo la programación en MATLAB y tiene conocimientos de analítica de datos. Su deber fue desarrollar los scripts necesarios en los que se apoyó para aportar las soluciones al proyecto.

El director de proyecto tuvo una mayor carga de trabajo al empezar el proyecto, teniendo que definir el alcance del proyecto y los requerimientos de este, pero, más adelante, su labor se redujo a reunirse con el analista de datos para comprobar que todo iba según lo planificado, y para explicarle con detalle las necesidades del proyecto. También aportó su visión del problema o incluso soluciones cuando el analista de datos no pudo avanzar por sí mismo.

El analista de datos, una vez el proyecto estuvo definido, tuvo que realizar la mayor parte de las tareas. Sobre él recayó el desarrollo de las funcionalidades que tiene el proyecto.

En la Tabla 2 se puede encontrar el coste total desglosado para cada actor involucrado en el proyecto. Se muestra el número de horas estimado dedicado por cada uno, así como el precio por hora de su trabajo.

DEFINICIÓN DEL TRABAJO

<i>Actor</i>	<i>Horas trabajadas</i>	<i>Precio por hora</i>	<i>Coste total</i>
Director de proyecto	50 horas	60 €/hora	3.000 €
Analista de datos	300 horas	20 €/hora	6.000 €

Tabla 2. Desglose de costes de personal del proyecto

Como se ha explicado anteriormente, tanto el coste hardware como el coste software es nulo, y por tanto el coste total del proyecto cuenta tan solo con el coste de personal, que asciende a la cifra de 9.000€.

Capítulo 5. ARQUITECTURA DE COMUNICACIONES

El presente trabajo ha sido llevado a cabo con una muestra de consumo eléctrico de clientes del sector no residencial en España, con la idea de ser un estudio piloto para un posible trabajo a futuro a mayor escala, capaz de realizar la monitorización a tiempo real del consumo eléctrico de los distintos clientes.

El principal beneficio de la monitorización del consumo eléctrico a tiempo real es la posibilidad de ofrecer servicios que en este trabajo serán solamente conclusiones, como por ejemplo la propuesta de acciones con vistas a la optimización de la gestión activa de la demanda eléctrica. Mientras que en este trabajo se ofrecerán propuestas a posteriori que podrían haber optimizado la demanda, o que en caso de que el cliente siga haciendo el mismo consumo se podrá optimizar, gracias a la monitorización a tiempo real, sería posible procesar y analizar los datos de forma casi instantánea, ofreciendo soluciones ante elevados picos de demanda de energía eléctrica, y enviando alertas a aquellos clientes que estén siendo causantes de estos picos, beneficiándoles a ellos si tienen la posibilidad de realizar estos consumos eléctricos a otras horas del día, y beneficiando a los suministradores de energía al conseguir que la demanda eléctrica sea más constante, necesitando una menor generación instantánea de energía eléctrica.

Por un lado, los clientes recibirían mensajes informativos, así como alarmas cuando su consumo sobrepase unos límites o la demanda agregada haga lo propio, haciendo que la tarifa flexible de energía eléctrica afecte a los clientes. De esta forma, el cliente tendría la posibilidad de gestionar mejor su demanda de energía eléctrica, con un mayor conocimiento tanto de su consumo como del agregado.

Por otro lado, los suministradores de energía conocerían mejor las necesidades de sus clientes en todo momento, pudiendo planear de manera óptima la activación de generadores de energía en función de la demanda agregada de energía de sus clientes, y controlando aquellos consumos que muestren un comportamiento extraño al contar con más información.

Las necesidades indican que la mejor solución sería una arquitectura en dos niveles como la que se muestra en la Figura 8. A nivel local, las lecturas de demanda eléctrica individuales irían a unos concentradores, indicado en la imagen con las líneas azules. Esta información, una vez recogida, se recogería a nivel nacional, indicado en la imagen mediante las líneas rojas.




Figura 8. Arquitectura de comunicaciones en dos niveles

Esta información se trataría como en este trabajo se pretende hacer, tanto agregando los datos como ofreciendo soluciones individuales para cada cliente, mediante el sistema de envío de mensajes y alarmas explicado anteriormente.

Capítulo 6. OBTENCIÓN DE LA INFORMACIÓN

Como se ha explicado en la [definición del proyecto](#), los datos con los que se ha trabajado proceden de dos fuentes distintas; por un lado, se encuentran los datos sobre consumo eléctrico y por otro, los que se obtuvieron de la Agencia Estatal de Meteorología.

Estos son los datos que se han obtenido para realizar el modelo, pero en un futuro se desea integrar la incorporación continua de los datos con el modelo desarrollado, de tal forma que se vayan obteniendo resultados en función de los últimos consumos de energía eléctrica y las últimas temperaturas.

El conjunto inicial de datos de consumo eléctrico constaba de 83 variables y más de 32 millones de observaciones. Los datos que comprenden este conjunto están relacionados con el consumo eléctrico de una muestra de clientes no residenciales en España. Cuenta con datos completos desde octubre del año 2014, hasta octubre del año 2015, ambos meses incluidos, aunque también cuenta con algunos datos desde de hasta tres años anteriores. A continuación, se enumeran y explican las variables que se encuentran en el conjunto inicial:

- **Día:** fecha en la que se realizó el consumo. Sigue el formato AAAAMMDD (Año/mes/día).
- **H1, H2, ..., H25:** hora dentro del día correspondiente. El registro extra existe debido a que hay un día al año en el que el cambio horario ocasiona que tenga 25 horas.
- **Activa_H1, Activa_H2, ..., Activa_H25:** energía activa consumida para cada hora. Está medida en medida en vatios-hora (Wh). La energía activa es de la energía útil que los clientes absorben de la red y transforman en trabajo y/o calor.
- **Reactiva_H1, Reactiva_H2, ..., Reactiva_H25:** energía reactiva consumida para cada hora. Está medida en voltio-amperio reactivo hora (VARh). La energía reactiva es un consumo suplementario que los clientes no pueden aprovechar.

Actualmente, esta empresa no factura la energía reactiva, aunque podría facturarse en el futuro como medida para mejorar la eficiencia energética en el hogar.

- **De_Municip:** municipio en el que se encuentra el cliente sobre el que se dan los datos de consumo horario.
- **Fecha_Alta_Stro:** fecha en la que dio de alta su suministro el cliente en cuestión. Sigue el siguiente formato QXAAAA (cuatrimestre/año).
- **Target_Tenencia_Cups:** probabilidad de que en el municipio en el que se encuentra el cliente exista distribución de gas natural.
- **Identificador:** código identificador correspondiente a cada cliente. Permite individualizar los consumos por cliente.
- **CNAE:** indica si el cliente es doméstico, con el valor T1, o si no lo es, con el valor T2.
- **Producto:** tarifa/producto eléctrico que el cliente tiene contratado como servicio. Existen hasta 120 productos.
- **Mercado:** indica si se trata de un cliente con tarifa regulada, con el valor M1, o de un cliente con tarifa de mercado libre, con el valor M2. Tarifa regulada significa que el precio de la electricidad viene regulado de forma periódica por el organismo competente, mientras que, en mercado libre, el precio de la electricidad es libremente pactado entre la comercializadora y el cliente.

Para complementar estos datos, se trató de encontrar la temperatura que había hecho en los municipios de interés durante los días de los que se disponían datos. Gracias a la herramienta de descarga de climatologías diarias de AEMET se obtuvieron estos datos [5]. Las variables que se obtuvieron se enumeran y explican a continuación:

- **Fecha:** indica la fecha del día en la que se realiza la medida. Sigue el formato AAAA-MM-DD (Año/mes/día).
- **Indicativo:** código identificador de la estación meteorológica en la que se ha realizado la medida.
- **Nombre:** nombre o ubicación de la estación meteorológica en la que se ha realizado la medida.
- **Provincia:** provincia a la que pertenece la estación meteorológica.

- **Altitud:** altitud a la que se encuentra la estación meteorológica sobre el nivel del mar. Está medida en metros (m).
- **Tmed:** temperatura media diaria. Está medida en grados Celsius (°C).
- **Prec:** precipitación diaria de 7:00 a 6:59 del día siguiente. Está medida en milímetros de agua (mm).
- **Tmin:** temperatura mínima del día. Está medida en grados Celsius (°C).
- **HoraTmin:** hora y minuto en la que ha ocurrido la temperatura mínima del día.
- **Tmax:** temperatura máxima del día. Está medida en grados Celsius (°C).
- **HoraTmax:** hora y minuto en la que ha ocurrido la temperatura máxima del día.
- **Dir:** dirección de la racha máxima de viento. Está medida en decenas de grados sexagesimales (°/10).
- **Velmedia:** velocidad media del viento. Está medida en metros partido segundo (m/s).
- **Racha:** racha máxima del viento. Está medida en metros partido segundo (m/s).
- **HoraRacha:** hora y minuto en la que ha ocurrido la racha máxima del día.
- **Sol:** suma de intervalos de tiempo durante los cuales la radiación solar directa supera el umbral de 120 W/m² [16]. Está medida en horas (h).
- **PresMax:** presión máxima al nivel de referencia de la estación. Está medida en hectopascales (hPa).
- **HoraPresMax:** hora en la que ha ocurrido la presión máxima, redondeada a la hora entera más cercana.
- **PresMin:** presión mínima al nivel de referencia de la estación. Está medida en hectopascales (hPa).
- **HoraPresMin:** hora en la que ha ocurrido la presión mínima, redondeada a la hora entera más cercana.

Capítulo 7. PREPROCESAMIENTO DE LOS DATOS

Una vez se ha entendido el problema que se quiere abordar y se han entendido también los datos que se tienen, es el momento de realizar el preprocesamiento y preparación de los datos, que es el paso más importante a la hora de realizar un modelado machine learning, debido a que, sin datos de calidad, no hay calidad en los resultados, y los datos del mundo real suelen ser incompletos, ruidosos e inconsistentes [17]. En la mayoría de los casos, el tiempo empleado en esta fase es cercano al 80% del tiempo total.

La preparación de los datos tiene distintas fases; adaptación de datos, limpieza de datos, integración de datos, transformación de datos, reducción de datos y discretización de datos [18], que dependiendo de la tipología del problema será necesario realizar unas u otras fases y en distinto orden.

7.1 ADAPTACIÓN DE LOS DATOS

Como se ha comentado en [la sección de herramientas utilizadas](#), el proyecto se ha desarrollado en MATLAB, pero, primeramente, hubo que realizar consultas básicas en la terminal de Linux para conocer cómo era el conjunto de datos inicial de consumo eléctrico, pues MATLAB era incapaz de procesar un archivo tan pesado.

Con las consultas realizadas, se llegó a la conclusión de que lo más práctico sería recortar el fichero inicial en múltiples ficheros más ligeros y que MATLAB pudiera procesar. Con el Fragmento de código 1 se consiguió dividir la tabla inicial en 261 tablas de cerca de 12.300 filas que ya resultaban manejables. Se han omitido algunas partes del código y se ha dejado la parte que explica el funcionamiento del mismo.

```
% Separación del conjunto de entrenamiento en varias tablas
ssds = datastore(' ../DATATHON_secuencial.csv '); % Crea un objeto data store
                                              % a partir del conjunto
inicial
ssds.ReadSize = 1000000; % Determina el número de campos que se desean leer
Tabla1=read(ssds); % Crea una tabla con los datos anteriores, si se utiliza
Tabla2=read(ssds); % más de una vez lee los datos que vienen a continuación
[...]
```

```
Tabla261=read(ssds);

for i=1:261
    if i<10 % De la tabla 1 a la 9
        Name='Tablaz.mat'; % De esta forma se ha automatizado la forma de
        Name2='Tablaz'; % guardar el nombre de cada tabla
        Name(6)=num2str(i);
        Name2(6)=num2str(i);
    elseif i<100 % De la tabla 10 a la 99
        [...]
    else % Resto de tablas (hasta la 261 en este caso)
        [...]
    end
    save(Name,Name2); % Guardamos la tabla
end
```

Fragmento de código 1. División de la tabla primaria en otras más ligeras

En el caso de los datos procedentes de AEMET, el formato inicial de los mismos era JSON. Con una herramienta de internet se consiguió pasar a formato CSV [19]. Una vez en formato CSV, ya es posible manipular los datos con facilidad desde MATLAB.

7.2 LIMPIEZA DE LOS DATOS

Para los datos de consumo eléctrico, no hubo que realizar ninguna acción de limpieza de datos, pero los datos procedentes de AEMET, al llegar con formato JSON, tenía algunos campos de datos que interesaban para nuestro estudio y que no estaban completos. Incluso, en alguna ocasión, faltaban todos los datos referentes a un día.

Para arreglarlo, una vez en formato CSV y desde el Microsoft Excel, se estimaron estos datos que faltaban y que nos interesaban. Como solo resultaban interesantes los datos referentes a las temperaturas, se estimó como una media ponderada de la temperatura de los dos días anteriores y los dos posteriores, tanto para la temperatura media como la mínima y la máxima, mediante el cálculo observable en la Ecuación 1.

$$Temp_d = 0,15 * Temp_{d-2} + 0,35 * Temp_{d-1} + 0,35 * Temp_{d+1} + 0,15 * Temp_{d+2}$$

Ecuación 1. Cálculo de la temperatura de datos incompletos

7.3 REDUCCIÓN DE LOS DATOS

Una vez se contaron con los datos manejables y completos, se pasó a la reducción de los datos, descartando aquellos que no resultaban de interés para el estudio y transformando otros para una manipulación más sencilla una vez se implanten los algoritmos de machine learning. En la Figura 9 encontramos un ejemplo gráfico de reducción de datos, pasando de n características a 3 y de m instancias a 4.




Figura 9. Reducción de características e instancias

En esta fase se encuentran tres pasos diferentes, primeramente, se realizó la reducción de variables, seguidamente, se seleccionaron aquellas instancias que son relevantes para nuestro estudio en función de sus características, y, por último, se decidió discretizar algunas variables.

7.3.1 SELECCIÓN DE CARACTERÍSTICAS

En las dos tablas de las que parte el estudio se encuentran algunas variables que son irrelevantes para el estudio que se va a realizar. Para el caso de la tabla con datos de consumo eléctrico, se decidió eliminar las 25 columnas que nos indican la hora del día, ya que es información redundante. En el Fragmento de código 2 se puede encontrar el procedimiento seguido con este propósito. Se han omitido algunas líneas de código.

```
% Selección de características de interés
for i=1:261
    if i<10
        Name = 'Tablaz.mat';      % De esta forma cargamos las 261 tablas de
forma
        Name(6) = num2str(i);    % iterativa
        Name3 = 'Tablaz';
        Name3(6) = num2str(i);
```

```
elseif i>=10 && i<100
    [...]
else
    [...]
end

data = load(Name);
TablaAModif = data.(Name3); % A continuación seleccionamos las variables
TablaModif =
TablaAModif(:, [1, 3, 4, 6, 7, 9, 10, 12, 13, 15, 16, 18, 19, 21, 22, 24, 25, 27,
28, 30, 31, 33, 34, 36, 37, 39, 40, 42, 43, 45, 46, 48, 49, 51, 52, 54, 55, 57, 58, 60, 61, 63, 64, 66,
67, 69, 70, 72, 73, 75, 76, 77, 78, 79, 80, 81, 82, 83]);

if i<10
    Name2 = 'Tabzm.mat'; % Así, de forma iterativa, vamos a guardar
    Name2(4) = num2str(i); % las 261 tablas sin las variables que son
elseif i>=10 && i < 100 % irrelevantes
    [...]
else
    [...]
end

Name4 = 'TablaModif';
save(Name2, Name4);
end
```

Fragmento de código 2. Selección de variables en los datos de consumo eléctrico

En el caso de los datos de AEMET, el procedimiento fue similar, pues solamente resultaba interesante para el proyecto conservar las columnas de fecha y de temperatura, al contar con una tabla distinta para cada provincia. De esta forma, se decidió eliminar el resto de las variables, como las precipitaciones o rachas de viento.

En este caso, también se realizaron algunas transformaciones. Se contaba con las tablas en formato Excel, y se guardaron como matriz, y el formato de la fecha se pasó de aaaa-mm-dd a aaaammdd para tener una mayor comodidad a la hora de comparar fechas. Todo este proceso se puede observar en el Fragmento de código 3, en el que se muestra el proceso para la tabla de Barcelona.

```
% Selección de variables de interés
Tabla = readtable('..\Temperaturas\Temperaturas Barcelona.xlsx');

Fechas = string(Tabla.fecha); % Nos quedamos con la fecha
Temperaturas = str2double(Tabla.tmed)/10; % y con la temperatura

fechaFinal = zeros(length(Fechas),1);
for i=1:length(Fechas) % Realizamos la transformación
    auxFecha = strsplit(Fechas(i,1), '-'); % de formato de fecha
    fechaFinal(i) =
    str2double(strcat(auxFecha(1,1), auxFecha(1,2), auxFecha(1,3)));
```


end

```
temperaturasBarcelona = [fechaFinal, Temperaturas];
save('temperaturasBarcelona', 'temperaturasBarcelona'); % Se guarda la
matriz
```

Fragmento de código 3. Selección de variables en los datos de AEMET

7.3.2 SELECCIÓN DE INSTANCIAS

En este apartado se seleccionan aquellas instancias que cumplen ciertas condiciones y que, por tanto, resultan interesantes para el proyecto. Nos basaremos en las selecciones que se hicieron para los datos de consumo eléctrico, dado que para los datos de AEMET no hubo que realizar ninguna selección al haber conseguido solo aquellos datos que eran necesarios para el objetivo.

La primera selección que se hizo fue la de aquellos datos que pertenecen a consumo eléctrico del sector servicios y del sector industrial. Como se explicó en [el apartado anterior](#), la variable CNAE tiene el valor T1 cuando se trata de un cliente residencial, mientras que adquiere el valor T2 cuando el cliente pertenece al sector no residencial. De esta forma, en el Fragmento de código 4 se muestra una función que elimina todas las instancias que no tienen en la variable CNAE el valor T2.

```
function tabla_out=quitT2(tabla)
% QUITT2 quita las filas de la tabla cuyo valor de la columna CNAE es T2
CNAE_mat=cell2mat(tabla.CNAE); % Convierte la columna CNAE en Matriz
ind_T2=(CNAE_mat(:,2)=='1'); % Devuelve las filas en las cuales tenemos un 2
tabla_out=tabla(~ind_T2,:); % Devuelve la tabla sin dichas filas
end
```

Fragmento de código 4. Función de selección de instancias de consumo no residencial

Para automatizar la llamada a esta función, se desarrolló un script que hacía la llamada para las 261 tablas con las que contamos. Este código se muestra en el Fragmento de código 5.

```
for i=1: 261 % Iteramos el proceso para todas las tablas que tenemos
    Nombre=['Paso2/Tab', num2str(i), 'm.mat']; % Se obtienen los nombres de
    tablas

    try % Esta parte del código intenta cargar el archivo
        load(Nombre); % y devuelve mensaje si no encuentra el archivo
    catch
        disp(['no se ha encontrado el archivo ', Nombre])
    end
```

PREPROCESAMIENTO DE LOS DATOS

```

name_tabla=['Tab',num2str(i),'_T2']; % Da nombre a la tabla en función de
i
assignin('base',name_tabla,quitT2(TablaModif)); % Incluye lo que devuelve
la
                                % función en el Workspace
Nombre2=['Tab',num2str(i),'_T2.mat']; % Da el nombre a la tabla como .mat
save(Nombre2,name_tabla); % Guarda la variable name_tabla
end

```

Fragmento de código 5. Selección de instancias de consumo del sector no residencial

Una vez realizado este paso y antes de seguir seleccionando instancias, se decidió juntar las 261 tablas en 9. Esto fue posible debido a la cantidad de información que ya se había descartado, como son las 25 variables desechadas, así como todos los consumos de clientes residenciales que se eliminaron de las tablas.

Se procedió a crear 6 tablas de las 9 que se parten, siendo una de cada ellas para cada ciudad. Para ello, se desarrolló la función que se encuentra en el Fragmento de código 6, y el script que llama a la función y se encarga de cargar y crear las tablas que se observa en el Fragmento de código 7. En el ejemplo se muestra para el municipio de Valencia.

```

function tab_muni = Seleccionmunicipios(tabla)
    Index = strcmp(tabla.DE_MUNICIP,'VALENCIA');% Devuelve una tabla solo con
las
    tab_muni = tabla(Index,:); % filas cuyo municipio es el
buscado
end

```

Fragmento de código 6. Función de selección de instancias de los municipios del estudio

```

for i=1:9
    Nombre=['Paso5/T',num2str(i)]; % Se obtiene el nombre de forma
iterativa
    Nom=['T',num2str(i)]; % de las 9 tablas de las que partimos

    try % Esta parte del código intenta cargar el archivo y
        load(Nombre); % devuelve mensaje sino encuentra el archivo
    catch
        disp(['no se ha encontrado el archivo ',Nombre])
    end

    tab = evalin('base',Nom);
    name_tabla=['Tab',num2str(i)];
    assignin('base',name_tabla,Seleccionmunicipios(tab)); % Llama a la función
    Nombre2=['Tab',num2str(i),'_VALENCIA.mat'];
end
% Las dos últimas líneas unen las tablas y luego las guardan en una sola
Tab_VALENCIA =[Tab1;Tab2;Tab3;Tab4;Tab5;Tab6;Tab7;Tab8;Tab9];
save('Tab_VALENCIA','Tab_VALENCIA');

```

Fragmento de código 7. Selección de instancias de los municipios de interés

Así, se han eliminado todos los datos que no corresponden a los municipios de Madrid, Barcelona, Cáceres, La Coruña, Málaga ni Valencia.

7.4 INCORPORACIÓN DE NUEVAS CARACTERÍSTICAS

7.4.1 DÍA DE LA SEMANA

Cuando ya se han desechado todos aquellos datos que no resultaban atractivos para el proyecto, se pensó en la inclusión de otros datos que facilitaran el estudio.

Una de las variables que se decidió añadir fue la del día de la semana. Así, se creó la columna que indicaba el día de la semana y se agregó a la tabla actual. En el Fragmento de código 8 se puede encontrar todo el proceso, con el ejemplo para el municipio de Madrid, que se ha realizado de igual manera para el resto de los municipios.

```
load('Paso6bis/Tab_Bis_MADRID'); % Se carga la tabla

Dia = zeros(1, size(Tab_Bis_MADRID,1));
for i=1: size(Tab_Bis_MADRID,1)
    S = num2str (Tab_Bis_MADRID.DIA(i)); % Se pasa a string y se transforma la
    X = datetime([S(1:4), '-', S(5:6), '-', S(7:8)]); % fecha a otro formato
    Dia(i) = weekday(X); % Con la función weekday se obtiene el día de la
    semana
end % con la forma 1-Domingo, 2-Lunes, ..., 7-Sábado

Dia = Dia';
Dia = array2table(Dia);
T_MADRID = [Tab_Bis_MADRID Dia]; % Añade la columna día a la tabla de Madrid
save('T_MADRID.mat', 'T_MADRID'); % Se guarda
```

Fragmento de código 8. Incorporación de la columna día

7.4.2 TEMPERATURA DEL DÍA

Se quiso incluir la temperatura que hizo el día de cada lectura de consumo eléctrico, categorizando en temperatura alta, media o baja. Para ello, se decidió analizar la temperatura en los distintos municipios.

Debido a los resultados obtenidos a la hora de dibujar los histogramas propios de las temperaturas en cada municipio, se decidió seguir el criterio de la temperatura media para los municipios de Barcelona, La Coruña, Málaga, Valencia, el criterio de temperatura máxima para el municipio de Cáceres y el criterio de temperatura mínima para el

municipio de Madrid. Estos distintos criterios difieren en las temperaturas elegidas a la hora de dibujar el histograma, y, por tanto, de dividir entre temperatura alta, media o baja.

Una vez realizados los histogramas para las temperaturas, se eligieron las temperaturas a partir de las cuales se considerarían como altas, medias o bajas. En la Figura 10 se muestra el caso de Valencia, para la cual se eligieron como temperaturas límites $14,8^{\circ}\text{C}$ y $25,2^{\circ}\text{C}$. De esta forma, los días que hizo menos de $14,8^{\circ}\text{C}$ se considera que hubo temperatura baja, y los días que hizo más de $25,2^{\circ}\text{C}$ se considera que hizo temperatura alta.




Figura 10. Histograma de las temperaturas medias de Valencia

De igual manera se muestra en la Figura 11 el ejemplo para el caso de Cáceres, en el cual, como se ha dicho, se eligió el criterio de la temperatura máxima. Las temperaturas límite elegidas fueron $14,6^{\circ}\text{C}$ y $25,5^{\circ}\text{C}$, considerándose que en los días en los que hubo menos de $14,6^{\circ}\text{C}$ de temperatura máxima hubo temperatura baja, y que en los días que hubo más de $25,5^{\circ}\text{C}$ de temperatura máxima hubo temperatura alta.




Figura 11. Histograma de las temperaturas máximas de Cáceres

Una vez se calcularon los límites de las temperaturas para decidir si la temperatura es baja, media o alta en cada ciudad para cada uno de los días en los que se hizo cada una de las lecturas, se pasó a cruzar la tabla que se creó en el Fragmento de código 3 y las tablas de consumo eléctrico. Para ello, se utilizó el Fragmento de código 9, el cual genera una nueva columna con los valores 1, 2 ó 3 en función de si la temperatura fue baja, media o alta respectivamente durante el día en el que se realizó cada una de las lecturas de demanda de energía eléctrica. En el código se muestra el ejemplo para la ciudad de Valencia, aunque el procedimiento fue similar para cada una de las ciudades.

```
% Cruce de tablas de demanda de energía eléctrica y temperaturas
load('..\Temperaturas\temperaturasValencia'); % Se carga la tabla de
temperaturas
limitesValencia = [14.8 25.2]; % Se establecen las temperaturas límites
load('Paso7\T_VALENCIA'); % Se carga la tabla de demanda eléctrica

temperaturas_Valencia = zeros(length(T_VALENCIA),1);
for i = 1:size(T_VALENCIA,1)
    dia = T_VALENCIA(i,53); % Se obtiene el día de la lectura
    temperaturaCorresponde =
temperaturasValencia(temperaturasValencia(:,1)==dia,2);
    if(temperaturaCorresponde<limitesValencia(1)) % Comprueba en qué rango
        temperaturas_Valencia(i)=1; % se encuentra la
    elseif(temperaturaCorresponde<limitesValencia(2))% temperatura que hizo
ese
        temperaturas_Valencia(i)=2; % día, y se le da el valor
1
    else % si la temperatura fue
baja
```

```
temperaturas_Valencia(i)=3;           % 2 si fue media y 3 si
fue                                     % alta
end
end

T_VALENCIA_TEMP = horzcat(T_VALENCIA,temperaturas_Valencia); % Se añade
columna
save(T_VALENCIA_TEMP, T_VALENCIA_TEMP); % Se guarda la tabla nueva
```

Fragmento de código 9. Cruce de tablas para saber la temperatura en cada lectura

7.5 DIVISIÓN EN DISTINTAS TABLAS

Para analizar el impacto geográfico en la demanda de energía eléctrica, [previamente](#) se decidieron elegir seis municipios, y para una mayor comodidad, se dividieron los datos en seis tablas distintas, una correspondiente a cada municipio.

Ahora, para poder estudiar el impacto de los factores de temperatura y de calendario en cada uno de los municipios, se decidieron crear diez tablas a partir de cada una de las seis tablas de municipios, esto es, dividir la tabla original de cada municipio en siete, una correspondiente a cada día de la semana, y dividirla también en tres, una correspondiente a cada rango de temperaturas (alta, media o baja). Se puede observar de una forma visual en la Figura 12.




Figura 12. División de cada tabla de municipio en distintas tablas

En el Fragmento de código 10 se encuentra el procedimiento realizado. Además, se eligieron las columnas de interés para el estudio en cada uno de los dos casos. Se muestra el ejemplo para la ciudad de Madrid, aunque se realizó de igual manera para los otros cinco municipios. Se han omitido algunas líneas de código para mostrar la funcionalidad de una forma más simple y limpia.

```
load('Paso9bis/T_MADRID_SOM'); % Se carga la tabla del municipio

colDia = horzcat((2:2:48),1,52,54); % Se eligen las variables de interés para
colTem = horzcat((2:2:48),1,52,53); % las tablas de día de la semana y las
tablas                                     % de temperatura. Estos datos son: la
energía
T_MADRID_LUNES_SOM = []; % activa para las 24h, la fecha, el ID de
[...]; % cliente y la temperatura o el día de la
T_MADRID_SABADO_SOM = []; % semana
T_MADRID_DOMINGO_SOM = [];
T_MADRID_TEMP_BAJA_SOM = [];
[...];

for i=1:length(T_MADRID_SOM) % Se crean las nuevas tablas en función del
    if T_MADRID_SOM(i,53) == 1 % día de semana que es / temperatura que hizo
        T_MADRID_DOMINGO_SOM = [T_MADRID_DOMINGO_SOM;T_MADRID_SOM(i,colDia)];
    elseif T_MADRID_SOM(i,53) == 2
        T_MADRID_LUNES_SOM = [T_MADRID_LUNES_SOM;T_MADRID_SOM(i,colDia)];
    [...]
    elseif T_MADRID_SOM(i,53) == 7
        T_MADRID_SABADO_SOM = [T_MADRID_SABADO_SOM;T_MADRID_SOM(i,colDia)];
    end
    if T_MADRID_SOM(i,54) == 1
        T_MADRID_TEMP_BAJA_SOM =
[T_MADRID_TEMP_BAJA_SOM;T_MADRID_SOM(i,colTem)];
    [...]
    end
end

save('T_MADRID_LUNES_SOM','T_MADRID_LUNES_SOM'); % Se guardan las tablas
[...]; % que se han ido creando
save('T_MADRID_SABADO_SOM','T_MADRID_SABADO_SOM');
save('T_MADRID_DOMINGO_SOM','T_MADRID_DOMINGO_SOM');
save('T_MADRID_TEMP_BAJA_SOM','T_MADRID_TEMP_BAJA_SOM');
[...];
```

Fragmento de código 10. División en tablas por día de la semana y temperatura

Capítulo 8. MODELADO

En este capítulo se va a exponer el procedimiento seguido para realizar el modelado de los datos. Se presentaba un problema de clustering, tratando de agrupar aquellos casos que son parecidos entre sí, como se explicó en un [capítulo anterior](#).

Tratando de conseguir que el sistema de clustering fuera óptimo y lo más robusto posible, el primer paso fue el de dividir el conjunto inicial en un conjunto de entrenamiento y uno de test, como sus nombres indican, el primero sirve para generar y entrenar el modelo, y el segundo se guardará para validar que los resultados obtenidos son correctos.

Después, se implementaron distintos algoritmos sobre los datos con distintas parametrizaciones, se entrenan cada uno de estos modelos y se selecciona aquel que tenga un buen compromiso entre error de clustering y complejidad del modelo.

8.1 MUESTRA DE ENTRENAMIENTO Y DE TEST

Para la división del conjunto en una muestra de entrenamiento y otra de test se decidieron elegir de cada cuatro semanas, tres para training y una para test. De esta forma, con las lecturas de las tres primeras semanas, se trataría de predecir la demanda de energía eléctrica para cada cliente en la cuarta semana. En la Figura 13 se muestra de forma gráfica el proceso de división en los dos conjuntos y su utilidad.




Figura 13. División en conjuntos de entrenamiento y de test [17]

El conjunto de test se utilizará para saber cómo de bien ha funcionado el modelo, pues, cuando se prueban diferentes y variados modelos, puede que haya uno que cometa poco

error de clustering por casualidad, y de esta forma se confirmará que realmente el modelo trabaja de forma correcta [20].

Se desarrolló el Fragmento de código 11 con este propósito. La separación en conjuntos de entrenamiento y test se realizó antes de la [división en tablas](#) de días de la semana y temperatura, para realizar el procedimiento seis veces en vez de sesenta.

La proporción buscada con esta división de los datos es de un 75% para entrenamiento y 25% para test, aunque al no dividir por instancias si no por semanas, las proporciones obtenidas para las distintas ciudades fueron desde el 73,1/26,9 al 77,3/22,7.

```
load("Paso9/Tab_MADRID");
tablaCompletaOrdenada = sortrows(Tab_MADRID, 1)); % Se ordena la tabla por
fecha

cont = 0;
dia = tablaCompletaOrdenada{1,1}; % Se obtiene la primera fecha de la tabla

% Se calcula la semana a la que pertenece el primer día. Se asigna para test
semanaTest =
week(datetime(floor(dia/10000),mod(floor(dia/100),100),mod(dia,100)));
conjuntoTrainingTest = zeros(size(tablaCompletaOrdenada,1),1);
for i=1:size(tablaCompletaOrdenada,1) % Se itera para todas las lecturas de
la
    dia = tablaCompletaOrdenada{i,1}; % table, y se calcula su semana
    semana =
week(datetime(floor(dia/10000),mod(floor(dia/100),100),mod(dia,100)));
    if semanaTest <= semana % De esta forma, se van asignando
        semanaTest = semana +4; % las lecturas de una semana para test,
        cont = 0; % y las lecturas de las siguientes tres
    end % semanas para training, intentando que
    if semanaTest == semana + 3 % haya una proporción 75%/25% en datos
        cont = 1; % de training y datos de test
    end
    if semanaTest == semana + 2
        cont = 2;
    end
    if semanaTest == semana + 1
        cont = 3;
    end
    if semana == 1 && semanaTest > 4
        semanaTest = 4 - cont;
    end
    if semana < semanaTest - 1
        conjuntoTrainingTest(i) = 0; % Se asigna un 0 al vector de control
si
    else % dicha lectura pertenece a training,
        conjuntoTrainingTest(i) = 1; % y un 1 si pertenece a test
    end
end
```

```
end
% Se calcula el ratio por si variase demasiado del 75%/25% deseado
ratioTestMadrid = sum(conjuntoTrainingTest)/size(conjuntoTrainingTest,1);
% Se obtienen las nuevas tablas y se guardan
T_MADRID_SOM = tablaCompletaOrdenada((conjuntoTrainingTest==0),:);
T_MADRID_SOM_Test = tablaCompletaOrdenada((conjuntoTrainingTest==1),:);
save('T_MADRID_SOM.mat','T_MADRID_SOM');
save('T_MADRID_SOM_Test.mat','Tab_Bis_MADRID_Test');
```

Fragmento de código 11. Separación en conjunto de training y de test

Los datos de test serán útiles a la hora de evitar que se produzca sobreajuste en el modelo, esto es, que el modelo tenga un buen rendimiento con los datos de entrenamiento, pero mala generalización a otros datos.

Este problema nace en la fase de entrenamiento, cuando el algoritmo, tratando de maximizar el poder predictivo del modelo, ajusta demasiado el modelo a los datos de entrenamiento, llegando a explicar el ruido de estos datos [21]. Cuando se prueben los datos de test, si se observa una gran bajada en el poder predictivo del modelo, podrá haber ocurrido sobreajuste.

Por otro lado, existe el subajuste, esto es, que el modelo no sea capaz ni si quiera de explicar los datos de entrenamiento, y, por tanto, no pueda generalizarse para datos nuevos. Normalmente, es el resultado de un modelo demasiado simple. Estos problemas se encuentran explicados de forma gráfica en la Figura 14.




Figura 14. Subajuste, ajuste correcto y sobreajuste [21]

8.2 IMPLEMENTACIÓN DE ALGORITMOS

Una vez hecha la división entre datos de entrenamiento y datos de test, estos últimos se guardaron para una [fase posterior](#) y en esta fase se trató únicamente el conjunto de entrenamiento.

8.2.1 KMEANS

El primer algoritmo probado fue kmeans, pues, además de ser un algoritmo sencillo y con poca parametrización, como se explicó en un [apartado anterior](#), una vez el modelo ha convergido, los centroides obtenidos sirven como prototipo o patrón de los clusters que se pueden encontrar en los datos. Así, de una manera rápida se puede obtener bastante información sobre el problema al que nos enfrentamos.

Kmeans permite indicarle el número de clusters que se esperan, y, para cada una de las sesenta tablas con las que se trabajó, se calculó el error de cuantización que se obtenía con distinto número de clusters, desde uno hasta treinta. Una vez estaba calculado, para cada una de las tablas se visualizó el error que se había cometido para cada número de clusters. En el Fragmento de código 12 se puede encontrar el ejemplo seguido para el caso de Barcelona durante los domingos.

```
load("Paso10/T_BARCELONA_DOMINGO_SOM"); % Se carga la tabla
%Quantization Error
qe_BARCELONA_DOMINGO=[];
for k = 1:30 % Para distintos valores de k se obtiene el error y se guarda
    [idx_BARCELONA_DOMINGO, ctrs_BARCELONA_DOMINGO, sumd_BARCELONA_DOMINGO] =
    kmeans(T_BARCELONA_DOMINGO_SOM,k, 'distance','sqeuclidean');
    qe_BARCELONA_DOMINGO(k)=sum(sumd_BARCELONA_DOMINGO);
end
figure; bar(qe_BARCELONA_DOMINGO);axis tight; % Se muestra el error
xlabel('K'); ylabel('QE');title('BARCELONA DOMINGO EnAct');
```

Fragmento de código 12. Obtención del error de cuantización para distinto número de clusters

La conclusión a la que se llegó es que, en todos los casos, había una gran bajada del error de cuantización cuando se aumentaba el número de clusters hasta llegar a los doce clusters. A partir de entonces, dependiendo del caso, a veces seguía descendiendo a gran velocidad, y otras veces empezaban a ser descensos del error cada vez más pequeños, incluso despreciables. Lo que sí se observó es que más o menos a partir de los veinticinco clusters, en todos los casos se había estabilizado bastante el descenso de error

cuantificado. En la Figura 15 y en la Figura 16 se encuentran los ejemplos de Barcelona durante los domingos y durante los lunes respectivamente. Si se quieren observar todas las figuras que se obtuvieron, se recomienda ver el [anexo](#) donde se exponen.




Figura 15. Descenso de error cuantificado para los domingos de Barcelona




Figura 16. Descenso de error cuantificado para los lunes de Barcelona

Como se observa en la Figura 15, el descenso del error cuantificado es grande hasta llegar a los quince clusters, donde se estabiliza el descenso de error, mientras que como se observa en la Figura 16, el descenso del error cuantificado es elevado no solo hasta llegar a los quince clusters, si no hasta los veintidós clusters más o menos.

Con el Fragmento de código 13 se dibujó el ejemplo para dieciséis clusters para todas las tablas, y así obtener una primera impresión de los datos con los que se contaba.

```
% Se calculan los clusters para el caso de k=16
K=16;
[idx_BARCELONA_DOMINGO, ctrs_BARCELONA_DOMINGO, sumd_BARCELONA_DOMINGO] =
kmeans(T_BARCELONA_DOMINGO_SOM(:,1:24),K, 'distance','sqeuclidean');

% Se dibuja el centro de los clusters
figure;
plot(ctrs_BARCELONA_DOMINGO,'-s','linewidth',1);
xlim([1 24]);xlabel('Hora');ylabel('Consumo eléctrico (W*h)');
legend(strcat('Cluster ',num2str([1:K])));title('BARCELONA DOMINGO EnAct');
```

Fragmento de código 13. Prueba de clustering con kmeans

En la Figura 17 se muestran los dieciséis clusters obtenidos con kmeans para los domingos de Barcelona. Se divisan algunos clusters con un consumo más o menos grande, pero la gran mayoría de clusters obtenidos tienen un consumo bajo o muy bajo. Esto es porque muchas industrias y empresas de servicios no trabajan durante los domingos. Se detectan ya algunos patrones característicos, como uno industrial que tiene un consumo casi idéntico a cualquier hora del día, otro que tiene un consumo alto durante la tarde y primeras horas de la noche, y otros con picos a mediodía y durante la tarde.




Figura 17. Clusters obtenidos por kmeans para los domingos de Barcelona

En la Figura 18 se muestran los dieciséis clusters obtenidos con kmeans para los lunes de Barcelona. Si se compara con la Figura 17, se observa la aparición de clusters con consumo más elevado, especialmente durante la mañana y la tarde. Obviamente, al ser en este caso lunes mientras que en el otro era domingo, aquí se encuentran industrias y empresas de servicios mucho más activas durante todo el día. También se encuentra el mismo patrón que para el domingo que tiene un consumo constante durante todo el día.




Figura 18. Clusters obtenidos por kmeans para los lunes de Barcelona

Para comprobar si había similitudes entre las demandas de energía eléctrica durante los distintos días de la semana, se decidió dibujar juntos todos los centroides de los clusters realizados por kmeans para cada municipio y para cada día de la semana. Se puede ver en la Figura 19 el caso de Madrid, en el que se han dibujado los centroides obtenidos por kmeans para los siete días de la semana.




Figura 19. Clusters obtenidos por kmeans para los distintos días de la semana de Madrid

De forma visual, se encuentran similitudes entre los clusters formados en distintos días. Por ejemplo, si se observan el lunes y el martes, o el miércoles y el jueves, o incluso el sábado y domingo, hay muchos clusters parecidos, que parecen indicar que se podrían considerar estos pares de días como un único día, así que se decidió seguir investigando por esta línea para tratar de generar menos modelos.

8.2.2 CLUSTERING JERÁRQUICO

El siguiente paso entonces, fue el de realizar clustering jerárquico con los centroides obtenidos para cada día de la semana, para ver si aquellos clusters que tenían similitudes, realmente se parecen entre ellos. En la Figura 20 se pueden encontrar los resultados, y en el Fragmento de código 14 el procedimiento seguido para el caso de Madrid. Se han omitido algunas partes del código para permitir una lectura más simplificada.




Figura 20. Dendrogramas de los clusters obtenidos para los distintos días de la semana de Madrid

```
K=16; % Se elige el número de clusters, se realiza el kmeans, y con los
      % centroides obtenidos, se realiza un clustering jerárquico
load("Paso10/T_MADRID_DOMINGO_SOM");
[idx_MADRID_DOMINGO, ctrs_MADRID_DOMINGO, sumd_MADRID_DOMINGO] =
kmeans(T_MADRID_DOMINGO_SOM,K, 'distance','sqeuclidean');
z_MADRID_DOMINGO= linkage(ctrs_MADRID_DOMINGO,'average','correlation');
load("Paso10/T_MADRID_LUNES_SOM");
[idx_MADRID_LUNES, ctrs_MADRID_LUNES, sumd_MADRID_LUNES] =
kmeans(T_MADRID_LUNES_SOM,K, 'distance','sqeuclidean');
z_MADRID_LUNES= linkage(ctrs_MADRID_LUNES,'average','correlation');
[...]

figure; % Finalmente, se representan los dendrogramas
subplot(2,2,1);dendrogram(z_MADRID_LUNES,16); title('MADRID LUNES EnAct');
subplot(2,2,2);dendrogram(z_MADRID_MARTES,16); title('MADRID MARTES EnAct');
[...]
```

Fragmento de código 14. Dendrogramas para los días de la semana de Madrid

Si se observa detalladamente, se vuelven a encontrar similitudes entre los dendrogramas formados para los centroides de los clusters en distintos días. De igual manera que antes, si se observan por pares el lunes y el martes, el miércoles y el jueves o el sábado y el domingo, aunque el número asignado a cada cluster no coincide, las estructuras que se forman son parecidas.

Este hecho invitó al optimismo, y para tener un dato numérico que permitiera tratar estos días emparejados como si del mismo día se tratase, se decidió calcular el coeficiente de correlación cofenético entre los dendrogramas creados para los distintos días de la semana, esta vez con todos los datos en vez de a partir de los centroides de los clusters formados para que el resultado sea más exacto. El coeficiente de correlación cofenético muestra la relación entre el dendrograma y la matriz de proximidades original, de esta forma, se puede comprobar si el dendrograma creado a partir de los datos de un día, tiene relación con los datos de otro día [22]. De esta forma, podríamos pasar a juntar aquellos días que se parecen y considerarlos como uno único, simplificando el modelo que se llegara a obtener. El proceso del cálculo del coeficiente de correlación cofenético para todos los pares de días se encuentra en el Fragmento de código 15.

```
load("Paso10/T_MADRID_DOMINGO_SOM"); % Se carga la tabla
Yh_MADRID_DOMINGO = pdist(T_MADRID_DOMINGO_SOM(:,1:24), 'euclidean');
maximo_MADRID_DOMINGO=max(Yh_MADRID_DOMINGO); % Se realiza clustering
jerárquico
minimo_MADRID_DOMINGO=min(Yh_MADRID_DOMINGO); % de los datos y se normalizan
Yh_MADRID_DOMINGO= ((Yh_MADRID_DOMINGO -
minimo_MADRID_DOMINGO). *100)./(maximo_MADRID_DOMINGO-minimo_MADRID_DOMINGO);
```

```
Zh_MADRID_DOMINGO = linkage(Yh_MADRID_DOMINGO, 'average'); % Genera el
dendrograma

load("Paso10/T_MADRID_LUNES_SOM"); % Se hace lo mismo para el resto de los
días
Yh_MADRID_LUNES = pdist(T_MADRID_LUNES_SOM, 'euclidean');
maximo_MADRID_LUNES=max(Yh_MADRID_LUNES);
minimo_MADRID_LUNES=min(Yh_MADRID_LUNES);
Yh_MADRID_LUNES= ((Yh_MADRID_LUNES -
minimo_MADRID_LUNES). *100)./(maximo_MADRID_LUNES-minimo_MADRID_LUNES);
Zh_MADRID_LUNES = linkage(Yh_MADRID_LUNES, 'average');
[...]
```

```
Ch_MADRID_D_L=cophenet(Zh_MADRID_DOMINGO, Yh_MADRID_LUNES); % Calcula el
coef.
Ch_MADRID_D_M=cophenet(Zh_MADRID_DOMINGO, Yh_MADRID_MARTES); % para todos
los
Ch_MADRID_D_X=cophenet(Zh_MADRID_DOMINGO, Yh_MADRID_MIERCOLES); % pares de días
[...]
```

Fragmento de código 15. Cálculo del coeficiente cofenético de correlación

Los resultados obtenidos tras ejecutar el Fragmento de código 15 se pueden encontrar en la Tabla 3. Como se puede observar, los valores obtenidos para los coeficientes para todos los pares de días son muy pequeños, casi cero. Lo mismo ocurrió para todas las ciudades.

Variable	Valor	Variable	Valor
Ch_MADRID_D_L	$1,8 \cdot 10^{-3}$	Ch_MADRID_LUNES	0,94
Ch_MADRID_D_M	$1,8 \cdot 10^{-3}$	Ch_MADRID_M_L	$1,3 \cdot 10^{-3}$
Ch_MADRID_D_V	$2,9 \cdot 10^{-3}$	Ch_MADRID_M_V	$8,4 \cdot 10^{-4}$
Ch_MADRID_D_X	$1,7 \cdot 10^{-4}$	Ch_MADRID_M_X	$1,2 \cdot 10^{-3}$
Ch_MADRID_DOMINGO	0,97	Ch_MADRID_MARTES	0,93
Ch_MADRID_J_D	$-1,6 \cdot 10^{-3}$	Ch_MADRID_MIERCOLES	0,94
Ch_MADRID_J_L	$-1,1 \cdot 10^{-3}$	Ch_MADRID_S_D	$4,3 \cdot 10^{-4}$
Ch_MADRID_J_M	$3,1 \cdot 10^{-3}$	Ch_MADRID_S_L	$4,1 \cdot 10^{-4}$
Ch_MADRID_J_S	$-1,1 \cdot 10^{-3}$	Ch_MADRID_S_M	$-8,2 \cdot 10^{-4}$
Ch_MADRID_J_V	$-1,9 \cdot 10^{-4}$	Ch_MADRID_S_V	$1,7 \cdot 10^{-4}$
Ch_MADRID_J_X	$-3,2 \cdot 10^{-4}$	Ch_MADRID_S_X	$2,2 \cdot 10^{-3}$
Ch_MADRID_JUEVES	0,92	Ch_MADRID_SABADO	0,94
Ch_MADRID_L_V	$4,8 \cdot 10^{-3}$	Ch_MADRID_V_X	$-2,3 \cdot 10^{-3}$
Ch_MADRID_L_X	$-2,7 \cdot 10^{-3}$	Ch_MADRID_VIERNES	0,94

Tabla 3. Relación entre tareas y objetivos

8.2.3 MAPAS AUTOORGANIZADOS DE KOHONEN

Tras comprobar finalmente gracias al coeficiente cofenético de correlación que no era posible juntar los datos de distintos días y tratarlos como un único día a la hora de generar el modelo, se pasó a realizar un mapa autoorganizado de Kohonen para cada una de las diez tablas que se tienen para cada municipio.

Para elegir las dimensiones del mapa autoorganizado, se desarrolló una función que, pasándole los datos y las dimensiones, devolvía el error medio y error cuadrático medio cometido con el clustering. Para calcular estos errores, se calculaba la distancia de cada una de las instancias al centroide del patrón como el que se había clasificado. Se eligió dibujar siempre una red rectangular de neuronas, con un factor de aprendizaje de 0,6, un radio de vecindad de 1 y 600 iteraciones hasta obtener el modelo de clustering. Esta función se puede encontrar en el Fragmento de código 16, donde se han omitido algunas partes del código.

```
function [errorMedio, errorCuadraticoMedio] =  
obtenerErrorJaime(tabla,dim1,dim2)  
  
    Neurona = tabla(:,1:24);    % Se cargan los datos de la tabla a la que se  
    input=Neurona';            % va a realizar el mapa autoorganizado  
    [...]  
  
    dimension1 = dim1;         % Se construirá un mapa de dimension1*dimension2  
    dimension2 = dim2;         % Anchura mapa - dimension X  
    [...]                      % Altura mapa - dimension Y  
  
    iteraciones = 600;         % Se establecen los parámetros: 600 iteraciones,  
    radio_v=1;                 % radio de vecindad igual a 1,  
    top='gridtop';             % se establece una red rectangular  
    net = selforgmap([dimension1 dimension2], iteraciones,radio_v, top);  
    net.trainParam.lr = 0.6;    % Factor de aprendizaje  
  
    [net,tr] = train(net,input); % Se entrena la red  
    [...]  
  
    y=net(input);              % Una vez ajustada la red, se clasifican los casos  
  
    neuronaPertenece = []; % Se calcula como qué neurona se ha clasificado  
    for i=1:size(y,2)          % cada uno de los casos para calcular más  
comódamamente  
        cont = 0;              % la distancia de cada caso a su centroide  
        for j=1:size(y,1)  
            cont = cont + 1;  
            if(y(j,i))  
                neuronaPertenece = horzcat(neuronaPertenece,cont);
```

```

        end
    end
end

errorMedio = 0; % Se calcula el error medio cometido por el
for i=1:size(Neurona,1) % modelo para los datos de training
    for j=1:size(Neurona,2)
        errorMedio = errorMedio + abs(Neurona(i,j)-
pesos(neuronaPertenece(i),j));
    end
end
errorMedio = errorMedio / size(Neurona,1);

errorCuadraticoMedio = 0; % Se calcula el error cuadrático medio
cometido
for i=1:size(Neurona,1) % por el modelo para los datos de training
    for j=1:size(Neurona,2)
        errorCuadraticoMedio = errorCuadraticoMedio + (Neurona(i,j)-
pesos(neuronaPertenece(i),j))^2;
    end
end
errorCuadraticoMedio = errorCuadraticoMedio / size(Neurona,1);
end

```

Fragmento de código 16. Función para calcular el error de clustering

Se decidió automatizar la llamada a esta función, calculando para cada una de las sesenta tablas el error obtenido para las dimensiones 3x4, 4x3, 4x4, 4x5, 5x4, 4x6, 6x4 y 5x5, es decir, todos los mapas posibles entre doce y veinticinco neuronas, que fueron las estimaciones que se habían sacado del estudio de kmeans. Este proceso se puede entender observando el Fragmento de código 17, de donde se ha omitido una gran parte del código para simplificar su entendimiento, ya que se realiza de igual manera para las sesenta tablas.

```

dim1 = [3 4 4 4 5 4 6 5]; % Inicializo las dimensiones de las que se quiere
dim2 = [4 3 4 5 4 6 4 5]; % calcular los errores de clustering cometidos

%% BARCELONA
load('..../Scriptsyfunciones/Paso10/T_BARCELONA_TEMPALTA_SOM.mat'); % Cargar
tabla
errorMedioBARCELONATEMPALTA = zeros(1,length(dim1)); % Inicializar
errorCuadraticoMedioBARCELONATEMPALTA = zeros(1,length(dim1)); % errores
for i=1:length(dim1)
    dimension1 = dim1(i);
    dimension2 = dim2(i);
    [errorMedioBARCELONATEMPALTA(i), errorCuadraticoMedioBARCELONATEMPALTA(i)]
= obtenerErrorJaime(T_BARCELONA_TEMPALTA_SOM,dimension1,dimension2);
end
disp('BARCELONA TEMPALTA');
[...]
```

```
load(' ../Scriptsyfunciones/Paso10/T_BARCELONA_LUNES_SOM.mat');
errorMedioBARCELONALUNES = zeros(1, length(dim1));
errorCuadraticoMedioBARCELONALUNES = zeros(1, length(dim1));
for i=1:length(dim1)
    dimension1 = dim1(i);
    dimension2 = dim2(i);
    [errorMedioBARCELONALUNES(i), errorCuadraticoMedioBARCELONALUNES(i)] =
    obtenerErrorJaime(T_BARCELONA_LUNES_SOM, dimension1, dimension2);
end
disp('BARCELONA LUNES');
[...]
```

Fragmento de código 17. Llamada a la obtención del error de clustering

También se decidió juntar las tablas de los seis municipios para cada uno de los días de la semana y cada una de las temperaturas para tener una estimación a nivel nacional, o al menos a un mayor nivel. Para esto se siguió el proceso del Fragmento de código 18 del que se han omitido partes del código. Después de juntar las tablas, se llamó también a la obtención del error de clustering para saber qué mapa y con qué dimensiones establecer para estas tablas.

```
load(' ../Scriptsyfunciones/Paso10/T_BARCELONA_DOMINGO_SOM.mat'); % Cargar las
load(' ../Scriptsyfunciones/Paso10/T_CACERES_DOMINGO_SOM.mat'); % distintas
load(' ../Scriptsyfunciones/Paso10/T_CORUNA_DOMINGO_SOM.mat'); % tablas para
load(' ../Scriptsyfunciones/Paso10/T_MADRID_DOMINGO_SOM.mat'); % cada día de
load(' ../Scriptsyfunciones/Paso10/T_MALAGA_DOMINGO_SOM.mat'); % la semana
load(' ../Scriptsyfunciones/Paso10/T_VALENCIA_DOMINGO_SOM.mat'); % y temperat.
todos_DOMINGO =
[T_BARCELONA_DOMINGO_SOM; T_CACERES_DOMINGO_SOM; T_CORUNA_DOMINGO_SOM; T_MADRID_D
OMINGO_SOM; T_MALAGA_DOMINGO_SOM; T_VALENCIA_DOMINGO_SOM];
[...]
```

Fragmento de código 18. Unión de tablas

Tras analizar los errores de clustering cometidos, que se pueden encontrar en un [anexo](#), se decidieron elegir las dimensiones que se encuentran en la Tabla 4, ya que ofrecen un buen compromiso entre error de clustering y complejidad del modelo. Una vez conocidas las dimensiones de los mapas que se iban a utilizar, se pasó al entrenamiento del modelo.

<i>Municipio</i>	<i>Tabla</i>	<i>Mapa</i>	<i>Municipio</i>	<i>Tabla</i>	<i>Mapa</i>
Barcelona	Diario	6x4	La Coruña	Diario	4x6
	Sábado	6x4		Sábado	4x6
	Domingo	4x3		Domingo	4x6
	Temperatura	6x4		Temperatura	5x5
Madrid	Diario	5x5	Málaga	Diario	5x5
	Sábado	5x5		Sábado	5x4
	Domingo	4x4		Domingo	5x4
	Temperatura	5x5		Temperatura	5x5
Cáceres	Diario	5x5	Valencia	Diario	6x4
	Sábado	5x4		Sábado	6x4
	Domingo	4x3		Domingo	3x4
	Temperatura	6x4		Temperatura	6x4
Todos	Diario	6x4			
	Sábado	4x5			
	Domingo	4x3			
	Temperatura	6x4			

Tabla 4. Dimensiones para las distintas tablas

8.3 ENTRENAMIENTO DEL MODELO

Llegado el momento de entrenar el modelo para cada una de las tablas, se siguió un código muy parecido al que se vio en la función utilizada a la hora de calcular el error cometido por cada mapa en el Fragmento de código 16, pero realizando algunas representaciones de interés y guardando en una tabla los datos con una nueva columna; el número de la neurona con la cual se habían clasificado.

A continuación, se muestra un ejemplo de los resultados obtenidos al entrenar el modelo, pero la explicación de estos resultados se llevará a cabo en detalle en un capítulo posterior. El ejemplo corresponde a los martes de Valencia. En la Figura 21 se muestran los patrones

obtenidos mediante el mapa autoorganizado de Kohonen. En un [anexo](#) se muestran todos los resultados obtenidos al entrenar los distintos modelos.

SOM_patterns




Figura 21. Patrones obtenidos en los martes de Valencia

En la Figura 22 se pueden observar el número de observaciones que se han clasificado como cada una de las neuronas. Así, se puede saber qué patrones han sido los más comunes y cuáles aquellos que han aparecido menos veces.




Figura 22. Número de instancias que se han clasificado en cada neurona los martes de Valencia

En la Figura 23 se muestran los consumos totales por neurona, conociendo así cuáles son aquellas neuronas que tienen una mayor repercusión en el consumo eléctrico total.




Figura 23. Consumo total en W*h por cada neurona en los martes de Valencia

El consumo eléctrico medio por hora y por neurona se puede ver en la Figura 24. Así, se puede conocer mejor la forma de los patrones y el tipo de consumo de cada uno de ellos.




Figura 24. Consumo medio en W*h por hora y por cada neurona en los martes de Valencia

Capítulo 9. VALIDACIÓN DEL MODELO

En este capítulo se utilizarán los datos del conjunto de test que en el [capítulo anterior](#) se obtuvieron de dividir el conjunto inicial en dos subconjuntos. El propósito es el de saber cómo de bien se ha realizado el clustering, y, en medida de lo posible, evitar un modelo que no sea óptimo.

9.1 PRUEBA DEL MODELO

Debido a que se trataba de un problema de clustering y no de clasificación, hubo que definir una medida de la calidad de los clusters debido a que las observaciones no tienen una clase, una variable de salida o una etiqueta.

Esta medida de calidad se decidió que fuera que, para un mismo cliente, la neurona predominante, tanto con el conjunto de entrenamiento como con el conjunto de test, fuera la misma.

El primer paso seguido fue el de organizar en clusters los datos de test, a través del modelo creado con los datos de entrenamiento para cada una de las tablas. En el Fragmento de código 19 se encuentra el procedimiento seguido para un caso específico.

```
load(' ../Scriptsyfunciones/Paso10Test/T_MALAGA_TEMPBAJA_SOM_Test.mat ');

NeuronaTest = T_MALAGA_TEMPBAJA_SOM_Test(:,1:24);
yTest = sim(net,NeuronaTest');
neuronaPerteneceTest = [];
for i=1:size(yTest,2)
    cont = 0;
    for j=1:size(yTest,1)
        cont = cont + 1;
        if(yTest(j,i))
            neuronaPerteneceTest = horzcat(neuronaPerteneceTest,cont);
        end
    end
end

todosMalagaTempBajaTest = [T_MALAGA_TEMPBAJA_SOM_Test, neuronaPerteneceTest'];
save(' todosMalagaTempBajaTest ', ' todosMalagaTempBajaTest ');
```

Fragmento de código 19. Organización en clusters de los datos de test

Gracias a esto, ahora se contaba con una nueva columna tanto en los conjuntos de entrenamiento y de test; la neurona con la cual cada una de las observaciones se había clasificado.

A la hora de calcular la medida de calidad del clustering, se diseñó un algoritmo que calculaba el número de veces que las lecturas de consumo eléctrico de cada cliente se habían clasificado como cada una de las distintas neuronas, tanto para los datos de entrenamiento como para los datos de test. Una vez se había calculado este número, se ordena de mayor a menor y se pasa a porcentaje de veces, y entonces se compara si la neurona predominante en los datos de entrenamiento coincide con la neurona predominante en los datos de test. Este proceso se encuentra en el Fragmento de código 20, en el cual se ha eliminado buena parte del código para mantener la simplicidad.

```
%% Valencia
load("Paso9bis/T_VALENCIA_SOM");           % Se cargan todas las
load("../Temperaturas/temperaturasValencia.mat") % tablas y datos
limitesValencia = [14.8 25.2];             % necesarios para
load("Paso11/todosValenciaLunes");          % calcular la medida de
[...]                                       % calidad del clustering
load("Paso11Test/todosValenciaLunesTest");
[...]

identif = [];                               % Se cargan en esta variable
cont = 0;                                   % todos los ID de clientes que
for i=1:length(T_VALENCIA_SOM)              % hay en este municipio
    if ismember(T_VALENCIA_SOM(i,52),identif) % mediante este algoritmo
    else
        cont= cont +1;
        identif = horzcat(identif,T_VALENCIA_SOM(i,52));
    end
end

numVecesLunes = horzcat(zeros(cont,24),identif'); % Se inicializan las
[...]                                             % variables que indican
                                                % el número de veces que
for j=1:cont                                     % cada cliente se ha
    id = identif(j);                             % clasificado como cada
    for i=1:size(todosValenciaLunes,1)          % neurona en el conjunto
        if id == todosValenciaLunes(i,26)       % de entrenamiento
            neuronaClasificado = todosValenciaLunes(i,28);
            numVecesLunes(j,neuronaClasificado) =
numVecesLunes(j,neuronaClasificado) + 1;
        end
    end
[...]
end                                             % Se utilizan dos variables que ordenan para cada cliente
[...]                                         % en función de cuáles son las neuronas en las que
```

```

% más veces han caído, y se pasa a porcentaje de veces
[auxVeces,auxIndice]=sort(numVecesLunes(1:cont,1:24),2,'descend');
ratioVecesLunes =
horzcat(identif',100*auxVeces(:,1)./sum(numVecesLunes(1:cont,1:24),2),auxIndic
e(:,1),100*auxVeces(:,2)./sum(numVecesLunes(1:cont,1:24),2),auxIndice(:,2),100
*auxVeces(:,3)./sum(numVecesLunes(1:cont,1:24),2),auxIndice(:,3));
[...]
```

```

ratioTestIguales = zeros(7,1);           % Se inicializan a 0 las medidas de
ratioTestTempIguales = zeros(3,1);       % calidad de clustering

numVecesTestLunes = horzcat(zeros(cont,24),identif');
[...]
```

```

% El mismo proceso se realiza para el conjunto de
% datos de test
for j=1:length(identif)
    id = identif(j);
    for i=1:size(todosValenciaLunesTest,1)
        if id == todosValenciaLunesTest(i,26)
            neuronaClasificadoTest = todosValenciaLunesTest(i,28);
            numVecesTestLunes(j,neuronaClasificadoTest) =
numVecesTestLunes(j,neuronaClasificadoTest) + 1;
        end
    end
end
[...]
```

```

end

[auxVeces,auxIndice]=sort(numVecesTestLunes(1:cont,1:24),2,'descend');
ratioTestVecesLunes =
horzcat(identif',100*auxVeces(:,1)./sum(numVecesTestLunes(1:cont,1:24),2),auxI
ndice(:,1),100*auxVeces(:,2)./sum(numVecesTestLunes(1:cont,1:24),2),auxIndice(
:,2),100*auxVeces(:,3)./sum(numVecesTestLunes(1:cont,1:24),2),auxIndice(:,3));
[...]
```

```

auxCont = zeros(1,10);
for i=1:length(identif)
    if ratioVecesLunes(i,3) == ratioTestVecesLunes(i,3)
        auxCont(1) = auxCont(1) + 1; % Se compara cuál es la neurona en la
    end % que más veces ha caído cada cliente
    [...]
```

```

End % en los conjuntos de entrenamiento y
% de test. Se cuenta las veces que son
for i= 1:7 % la misma neurona
    ratioTestIguales(i) = auxCont(i)/length(identif)*100;
end % Finalmente se pasa a porcentaje de clientes
for i=1:3 % que coincide la misma neurona clasificada
    ratioTestTempIguales(i) = auxCont(i+7)/length(identif)*100;
end
```

Fragmento de código 20. Prueba de la calidad del clustering

Las salidas de este código son los ratios que determinan el porcentaje de clientes cuya neurona predominante es la misma en los datos de entrenamiento y en los datos de test, y cuyos valores se encuentran en la Tabla 5.

VALIDACIÓN DEL MODELO

<i>Municipio</i>	<i>L</i>	<i>M</i>	<i>X</i>	<i>J</i>	<i>V</i>	<i>S</i>	<i>D</i>	<i>T.Alta</i>	<i>T.Media</i>	<i>T.Baja</i>
Barcelona	83%	85%	79%	87%	83%	83%	88%	89%	90%	84%
Madrid	78%	79%	76%	79%	79%	83%	84%	75%	80%	78%
Cáceres	75%	75%	72%	70%	71%	84%	91%	85%	77%	70%
La Coruña	83%	76%	74%	88%	83%	90%	79%	76%	88%	86%
Málaga	86%	86%	89%	84%	88%	84%	82%	91%	92%	86%
Valencia	80%	84%	84%	72%	78%	81%	91%	80%	79%	75%
Todos	77%	80%	78%	79%	79%	83%	85%	78%	83%	79%

Tabla 5. Porcentaje de clientes cuya neurona predominante fue la misma con los datos de test

Como se pueda observar, en ninguno de los casos la medida de calidad de clustering baja por debajo del 70%, que, teniendo en cuenta que el número de neuronas va desde doce hasta veinticinco, parece un porcentaje de conserva de neurona predominante en ambos conjuntos de datos bastante elevado y que indica que el modelo de clustering establecido es bueno.

Capítulo 10. FIDELIDAD DE LOS CLIENTES

En este capítulo se analiza la fidelidad de los clientes a sus patrones de consumo. La idea de este estudio nació al visualizar a la vez todos los consumos en un año para cada cliente. Se pudo concluir que, aunque algunos clientes no seguían ningún patrón de consumo de energía eléctrica a lo largo del año, había un gran número de clientes que tenían unos consumos muy similares a lo largo de todo el año.

Se decidió visualizar cada día de la semana por separado, y se descubrió que algunos clientes tenían un consumo idéntico para cada uno de los días de la semana durante todo el período de los que se tienen datos. En la Figura 25 se puede encontrar un ejemplo de estos clientes.




Figura 25. Consumos de energía eléctrica por un cliente por día de la semana a lo largo de un año

Promovido por el hecho de haber encontrado clientes que siempre tenían un patrón similar, se decidió programar una función capaz de calcular el consumo medio por cliente dentro de los datos que se le mandasen, que se encuentra en el Fragmento de código 21.

```
function [consumoClienteDef, limiteSuperiorClienteDef,
limiteInferiorClienteDef, cambioConsumo] =
calcularConsumoVariasTablasJaime(identificadores, tablaTemperatura, diaSemana,
tablaSemana, temperatura, relacionDiaTemperatura, limitesTemperatura,
tablaTemperaturaTest, tablaSemanaTest)

    consumoCliente = zeros(length(identificadores),24,2);
    limiteSuperiorCliente = zeros(length(identificadores),24,2);
    limiteInferiorCliente = zeros(length(identificadores),24,2);

% TablaTemperaturas: De toda la tabla de temperaturas se seleccionan los días
    if diaSemana(1) > 0 % de la semana que interesen
        tablaTemperatura =
tablaTemperatura(ismember(tablaTemperatura(:,27),diaSemana),:);
        tablaTemperaturaTest =
tablaTemperaturaTest(ismember(tablaTemperaturaTest(:,27),diaSemana),:);
    end
    numVeces =
horzcat(zeros(length(identificadores),max(tablaTemperatura(:,28))),identificad
ores');

[...]
```

```
[auxVeces,auxIndice]=sort(numVeces(1:length(identificadores),1:max(tablaTemper
atura(:,28))),2,'descend');

[...]
```

```
for i=1:length(identificadores)
    varId = identificadores(i);
    consumoCliente1 = zeros(1,24);
    consumoCliente2 = zeros(1,24);
    consumoCliente3 = zeros(1,24);

    neuronaDia = ratioVeces(i,2:7); % Calcula el % de veces que ha caído
    auxComprobarLimites = false; % en las 3 neuronas predominantes
    auxNeurona = neuronaDia; % para cada cliente
    neuronaDia(1) = auxNeurona(1) /
(auxNeurona(1)+auxNeurona(3)+auxNeurona(5));
    neuronaDia(3) = auxNeurona(3) /
(auxNeurona(1)+auxNeurona(3)+auxNeurona(5));
    neuronaDia(5) = auxNeurona(5) /
(auxNeurona(1)+auxNeurona(3)+auxNeurona(5));
    for j=1:size(neuronaDia,2)
        if(isnan(neuronaDia(j))) % Corrige si ha realizado alguna
            neuronaDia(j) = 0; % división entre cero
        end
    end
    if neuronaDia(1) < 1
        auxComprobarLimites = true;
    end

    auxContador1 = 0; % Calcula el consumo medio que ha hecho el
    auxContador2 = 0; % cliente cuando ha caído en cada una de sus
    auxContador3 = 0; % tres neuronas predominantes
```



```

for j=1:size(tablaTemperatura,1)
    if (tablaTemperatura(j,26) == varId) && (tablaTemperatura(j,28) ==
neuronaDia(2))
        consumoCliente1 = consumoCliente1 + tablaTemperatura(j,1:24);
        auxContador1 = auxContador1 + 1;
        [...]

    end
end

if ismember(1,consumoCliente1 > 0)    % Se normaliza
    consumoCliente1 = consumoCliente1/auxContador1;
end
[...]
```

% Y se calcula el consumo del cliente como la media
% ponderada del consumo en cada una de estas tres neuronas

```

consumoCliente(i,:,1) = consumoCliente1 * neuronaDia(1) +
consumoCliente2 * neuronaDia(3) + consumoCliente3 * neuronaDia(5);
if auxComprobarLimites    % Si un cliente no ha sido fiel siempre a la
    if ismember(1,consumoCliente3 > 0)    % misma neurona, habrá que
        for k=1:24    % calcular sus límites de consumo esperados
            [auxConsSuperior, auxIndiceConsSuperior] =
max([consumoCliente1(k), -inf, consumoCliente2(k), -inf, consumoCliente3(k)]);
            [auxConsInferior, auxIndiceConsInferior] =
min([consumoCliente1(k), inf, consumoCliente2(k), inf, consumoCliente3(k)]);
            limiteSuperiorCliente(i,k,1) = consumoCliente(i,k,1)*(1-
neuronaDia(auxIndiceConsSuperior)) + (neuronaDia(auxIndiceConsSuperior) *
auxConsSuperior);
            limiteInferiorCliente(i,k,1) = consumoCliente(i,k,1)*(1-
neuronaDia(auxIndiceConsInferior)) + (neuronaDia(auxIndiceConsInferior) *
auxConsInferior);
        end
    else
        [...]
    end
end
else
    limiteSuperiorCliente(i,:,1) = consumoCliente(i,:,1);
    limiteInferiorCliente(i,:,1) = consumoCliente(i,:,1);
end
end

% TablaSemana
if temperatura(1) > 0 % Baja=1, Media=2, Alta=3
[...]
```

% Se eligen aquellos registros que cumplen con la temperatura

```

    tablaSemana = tablaSemana(ismember(tablaSemana(:,27),temperatura),:);
end
[...]
```

% Se realiza el mismo proceso que se hizo con la tabla de
% temperaturas. Una vez hecho, se hace la media obtenida por los
% dos caminos, que siempre es muy parecida.

```

consumoClienteDef=mean(consumoCliente,3);
limiteSuperiorClienteDef=mean(limiteSuperiorCliente,3);
limiteInferiorClienteDef=mean(limiteInferiorCliente,3);
[...]
```

end

Fragmento de código 21. Cálculo de consumo por cliente

Como se observa, esta función calcula el consumo eléctrico medio horario de cada uno de los clientes que se encuentran dentro de los datos que se mandan. Es capaz de calcular este consumo para todo un municipio, aunque también tiene la posibilidad de filtrar por día de la semana y/o por temperatura. De esta manera, la función se queda con los datos que cumplen con estas características y calcula el consumo medio.

También se calculan unos límites esperados de consumo eléctrico, calculados a partir de la probabilidad que el cliente tiene de ser fiel a su patrón, esto es, la probabilidad de consumir de forma parecida a un patrón definido. Si un cliente es muy fiel a su patrón, los límites de consumo serán muy similares a su consumo medio, pero en el caso de que el cliente haga consumos poco parecidos entre sí dentro del conjunto de datos, los límites serán muy dispares del consumo medio, añadiendo incertidumbre al consumo.

Con este estudio se detectaron, por un lado, clientes que tenían un consumo muy estable, y, por otro lado, clientes cuyo consumo eléctrico era difícilmente predecible.

De forma paralela, se decidió estudiar el número de veces por día de la semana y por temperatura que cada cliente seguía un patrón de consumo. Así, se podría conocer mejor la forma de consumo de cada cliente en escenarios más específicos.

Este estudio reafirmó la conclusión extraída anteriormente de que, a pesar de que algunos clientes eran impredecibles, un gran número de clientes tienen un consumo muy similar a lo largo del año, y, especialmente, cuanto más específica es la situación, pudiendo filtrar dicha situación por día de la semana y por temperatura. A continuación, se va a mostrar un ejemplo de cliente muy fiel a su patrón de consumo y un ejemplo de un cliente con un patrón de consumo impredecible.

En la Figura 26, la Figura 27 y la Figura 28 se pueden encontrar, respectivamente, el consumo medio con los límites esperados de consumo de un cliente específico durante los lunes de Barcelona con temperatura media, cuántos de sus consumos se han clasificado como cada una de las neuronas por día de la semana y también por rango de temperaturas.




Figura 26. Consumo medio horario del cliente 5649 los lunes con temperatura media en Barcelona

Como se observa, este cliente es un consumidor nocturno, y entre media tarde y media mañana, tiene unos límites esperados muy similares a su consumo medio. Lo que quiere decir que durante esas horas su consumo es totalmente predecible. Durante el resto de las horas del día, cuando su consumo es menor, sus límites de consumo varían un poco más del consumo medio, aunque tampoco demasiado.




Figura 27. Clasificación por neurona para días de la semana de los consumos del cliente 5649




Figura 28. Clasificación por neurona para las distintas temperaturas de los consumos del cliente 5649

Tal y como se aprecia en la Figura 27 y en la Figura 28, los consumos eléctricos de este cliente siempre se clasifican como la misma neurona. Solamente cuando la temperatura es media y durante algunos miércoles, alguna vez su consumo eléctrico ha seguido el patrón definido en otra neurona.

En la Figura 29 se puede observar el consumo medio y los límites esperados de otro cliente, siendo el consumo de este cliente más impredecible que el del anterior.




Figura 29. Consumo medio horario del cliente 14408 los lunes con temperatura media en Barcelona

Este cliente tiene un pequeño pico de consumo a primera hora de la mañana, otro pico mayor a media tarde y luego su pico más alto durante las primeras horas de la noche. Sin embargo, tal y como muestran los límites esperados, es difícil predecir su consumo casi a cualquier hora, mostrando grandes distancias del consumo medio a los límites tanto superiores como inferiores a cualquier hora del día. En la Figura 30 y en la Figura 31 se muestran cuántos de sus consumos se han clasificado como cada una de las neuronas.




Figura 30. Clasificación por neurona para días de la semana de los consumos del cliente 14408




Figura 31. Clasificación por neurona para las distintas temperaturas de los consumos del cliente 14408

Como se puede observar en la Figura 30, la neurona predominante de este cliente para todos los días de la semana es la número veinticuatro, sin embargo, muchos consumos se han clasificado según el patrón marcado por otras neuronas, añadiendo incertidumbre a sus límites esperados de consumo. Siguiendo con la Figura 31, resalta que, en el modelo creado para la temperatura alta, el cliente casi siempre sigue el mismo patrón, mientras que cuando la temperatura es baja o media, el consumo no es nada fiel al marcado por un único patrón.

Capítulo 11. INTERFAZ GRÁFICO DE USUARIO

Con vistas a integrar todo el trabajo y unir toda la funcionalidad desarrollada en un mismo punto, se escogió desarrollar una interfaz gráfica de usuario sencilla y amigable que mostrara todo lo trabajado hasta esta fase.

11.1 CAPA DE PRESENTACIÓN

En la Figura 32 se encuentra la primera imagen de la interfaz gráfica de usuario. Como se aprecia, la interfaz está dividida en dos partes; en la parte superior y con la ayuda de botones, el usuario elige los datos por los que quiere filtrar y obtener la demanda eléctrica diaria agregada, y en la parte inferior se encuentra el gráfico donde mostrar el resultado.




Figura 32. Presentación de la interfaz gráfica de usuario

Además de los botones, se encuentran tres pestañas para indicar si la demanda agregada se quiere calcular para los datos de entrenamiento, para los datos de test, o para ambos en conjunto. En la Figura 33 se muestra el ejemplo de la demanda agregada municipio de Valencia durante los miércoles de temperatura media con los datos históricos de training. Además del gráfico que se muestra, también se representa en una nueva ventana que aparece, con lo cual, realizar una comparación entre distintos municipios es sencillo al tener una ventana nueva con cada una de las demandas de energía eléctrica agregadas que se calcule.




Figura 33. Ejemplo de la interfaz gráfica de usuario con datos de entrenamiento

Cuando la demanda agregada se calcula para los datos de test, se coge como muestra las últimas cuatro lecturas de consumo eléctrico. De esta manera, se pretende que la foto para el usuario sea la del último mes, y que así poder adaptar mejor el suministro de energía eléctrica a la realidad más cercana de cada cliente.

Además, para el caso de la demanda agregada calculada a partir de los datos de test, se muestra una frase debajo de la gráfica que sigue el siguiente formato: “X% de los clientes mantienen su patrón durante los miércoles de temperatura media. El Y% restante han cambiado su consumo en un Z%”. En la Figura 34 se encuentra un ejemplo de este caso.




Figura 34. Ejemplo de la interfaz gráfica de usuario con las últimas cuatro lecturas de los datos de test

Con motivo aclaratorio, cuando un usuario pulsa sobre el botón que contiene un signo de interrogación, nace una nueva ventana que explica el significado de que un cliente sea fiel a un patrón de consumo.

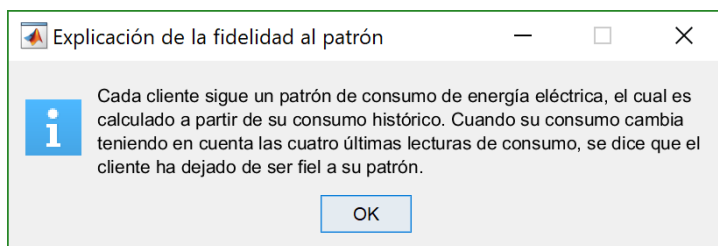


Figura 35. Pantalla explicativa de la fidelidad al patrón

Es importante interpretar la frase que nos indica el programa cuando calculamos la demanda agregada con los datos de test, pues si la cantidad de clientes que no están siendo fieles al patrón de consumo aumenta, significará que el modelo de clustering que hemos creado está desactualizado. Sería algo normal que los modelos que se han creado acaben obsoletos cuando se vayan recolectando más datos y los clientes adapten su consumo eléctrico a nuevas necesidades. En ese momento, sería necesario hacer una actualización de los modelos.

También existe la posibilidad de que la demanda de energía eléctrica agregada sea calculada para todos los datos. Para ello, el usuario deberá elegir la última pestaña, como se puede observar en la Figura 36.




Figura 36. Ejemplo de la interfaz gráfica de usuario con datos de entrenamiento y de test

11.2 CAPA DE CONSULTAS

Como se ha comprobado, dependiendo de la pestaña en la que se encuentre el usuario, la aplicación tendrá que llevar a cabo una funcionalidad u otra. En esta sección se van a explicar las distintas consultas que se llevan a cabo en función de las elecciones del usuario.

El algoritmo seguido para calcular las demandas agregadas de demanda eléctrica es muy similar al mostrado en el Fragmento de código 21, insertando unos datos u otros en función de la pestaña en la que el usuario está; para la pestaña de entrenamiento se utilizan los datos del conjunto de entrenamiento, para la pestaña de test se utilizan las lecturas del último mes de cada cliente, y para la pestaña de entrenamiento y test se utilizan todos los datos que se tienen. Una vez se tienen los consumos medios horarios y los límites esperados para cada cliente, simplemente se agregan.

Para comprobar que las formas de demanda obtenidas para cada municipio eran correctas, se ideó el Fragmento de código 22, donde se dibuja la forma de la demanda agregada real para cada uno de los días de los cuales se tiene datos.

```
load('Paso10/T_VALENCIA_MIERCOLES_SOM'); % Se carga la tabla deseada
tabla = T_VALENCIA_MIERCOLES_SOM;

fechas=[];
for i=1:size(tabla,1) % Mediante este algoritmo
    if find(tabla(i,25) == fechas) % se encuentran las distintas
    else % fechas con las que se cuenta
        fechas = [fechas,tabla(i,25)]; % en el conjunto de datos
    end
end
suma=zeros(length(fechas),24);
for j=1:length(fechas) % Para cada una de las tablas, se
    fecha=fechas(j); % calcula el consumo agregado
    for i=1:size(tabla,1) % de energía eléctrica
        if tabla(i,25) == fecha
            suma(j,:)=suma(j,:) + tabla(i,1:24);
        end
    end
end % Finalmente se dibujan los resultados obtenidos

figure;plot(suma);title('Valencia Distintos Miercoles');xlabel('Hora');
ylabel('Consumo eléctrico');xlim([1 24]);
[...]
```

Fragmento de código 22. Cálculo de la forma de la demanda para distintos días

La salida de este código se puede observar en la Figura 37, que si se mira con detalle, se observa que las demandas agregadas de los distintos días en los que se tienen valores son muy parecidas a las que vimos en las Figura 33 y en [dicha sección](#).




Figura 37. Demanda agregada para Valencia durante distintos miércoles

En paralelo, se llevó a cabo un estudio de cuáles eran aquellos clientes cuyo consumo durante los datos de test diferían en cierta proporción de los consumos durante los datos de training. Se realizó una primera versión de esta calculadora de clientes con cambios en su consumo, que se puede encontrar en el Fragmento de código 23.

```
load('Paso9bis/T_VALENCIA_SOM');
load('Paso9bisTest/T_VALENCIA_SOM_Test');
tabla_train = T_VALENCIA_SOM;
tabla_test = T_VALENCIA_SOM_Test;

identif = [];
cont = 0;
for i=1:length(tabla_train)
    [...] % Se calculan todos los identificadores de clientes de la tabla
end

consumo_train = zeros(length(identif),24);
consumo_test = zeros(length(identif),24);
col = 2:2:48;
for j=1:length(identif) % Se calculan los consumos de training y de
    cont_train = 0; % test por separado
    cont_test = 0;
    for i=1:length(tabla_train)
```

```

        if(tabla_train(i,52)==identif(j))
            consumo_train(j,:) = consumo_train(j,:) + tabla_train(i,col);
            cont_train = cont_train + 1;
        end
    end
    % Y se calcula el consumo medio
    consumo_train(j,:) = consumo_train(j,+)/cont_train;
    for i=1:length(tabla_test)
        if(tabla_test(i,52)==identif(j))
            consumo_test(j,:) = consumo_test(j,:) + tabla_test(i,col);
            cont_test = cont_test + 1;
        end
    end
    consumo_test(j,:) = consumo_test(j,+)/cont_test;

end
[...]
```

% Se calculan cuáles son
% aquellos clientes cuyo
% consumo de los datos de test
% difiere en unos límites del
% consume con datos de entrenam.

```

cont_error = zeros(length(consumo_train),1);
for i=1:length(consumo_train)
    for j=1:24
        if (consumo_test(i,j) > consumo_train(i,j)*1.5) || (consumo_test(i,j)
< consumo_train(i,j)*0.67)
            cont_error(i) = cont_error(i) + 1;
        end
    end
end
[...]
```

Fragmento de código 23. Primera versión del cálculo del cambio en el consumo de los clientes

Este código dibujaba el consumo real de cada cliente con los datos de training y con los datos de test, como se puede observar en la Figura 38 y en la Figura 39.




Figura 38. Consumos similares de un cliente con los datos de entrenamiento y de test

La gran diferencia entre estas dos figuras es que en la Figura 38 ambos consumos eran casi idénticos, mientras que en la Figura 39, el consumo medio con datos de test es muy dispar y atraviesa en múltiples ocasiones los límites establecidos a partir del consumo medio con los datos de training.




Figura 39. Consumos distintos de un cliente con los datos de entrenamiento y de test

Basado en esta idea, nació el Fragmento de código 24, integrado en la funcionalidad que se muestra en la interfaz gráfica de usuario.

```
cambioConsumo = zeros(2,length(identificadores));
for i=1:length(identificadores) % Se inicializan a 0 las variables que
    contHorasConsumoCambio = 0; % cuentan el cambio en el consumo
    cambioConsumoCiente = 0; % Se comprueba que el consumo de test
    for j=1:24 % no esté por encima ni debajo del de entren.
        if ((consumoCienteDefTest(i,j) > limiteSuperiorCienteDef(i,j)*1.5)
|| (consumoCienteDefTest(i,j) < limiteInferiorCienteDef(i,j)*0.67))
            contHorasConsumoCambio = contHorasConsumoCambio + 1;
            cambioConsumoCiente = cambioConsumoCiente +
abs(consumoCienteDefTest(i,j) - consumoCienteDef(i,j));
        end
    end
    cambioConsumo(1,i) = contHorasConsumoCambio; % Se corrigen posibles
    if sum(consumoCienteDef(i,:))*100 > 0 % errores numéricos
        if cambioConsumoCiente/sum(consumoCienteDef(i,:))*100 < 100
            cambioConsumo(2,i) =
cambioConsumoCiente/sum(consumoCienteDef(i,:))*100;
        else
            cambioConsumo(2,i) = 100;
        end
    end
end
```

```
else
    if cambioConsumoCliente/0.0001 < 100
        cambioConsumo(2,i) = cambioConsumoCliente/0.0001;
    else
        cambioConsumo(2,i) = 100;
    end
end
end
[...]
```

```
contCambio = 0;
casosCambio = zeros(1,length(cambioConsumo(1,:)));
for i=1:length(cambioConsumo(1,:))
    if(cambioConsumo(1,i)>9 && cambioConsumo(2,i)>10)
        contCambio = contCambio + 1;
        casosCambio(i)=1;
    end
end
end
```

% Y finalmente
% se cuenta el
% número de
% clientes con
% cambio en su
% consumo

Fragmento de código 24. Cálculo del cambio en el consumo para los distintos clientes

Una vez la interfaz gráfica recoge estos datos, es capaz de procesar tanto la gráfica que muestra como la frase que indica la fidelidad de los clientes a su patrón en la pestaña de test.

Capítulo 12. ANÁLISIS DE RESULTADOS

En el presente capítulo se pretende recopilar los distintos resultados que se han ido mostrando a lo largo de este trabajo, analizando la información que se pueda extraer tanto de forma individual como de manera conjunta.

Primeramente, se realizará un análisis para cada uno de los municipios en los que se ha realizado el estudio, dejando para el último lugar la comparativa y el análisis agrupado de todos ellos. Se recomienda ver el [anexo](#) donde se muestran todos los patrones de consumo eléctrico obtenidos para todos los modelos realizados para cada uno de los municipios, ya que a lo largo de esta sección se encontrarán datos de las figuras que allí se encuentran.

12.1 MADRID

En el municipio de Madrid se cuenta con datos de 689 clientes, la cifra más elevada dentro de los seis municipios sobre los que se centra el estudio. Como primera toma de contacto con la ciudad, observamos en la Figura 40 el consumo real durante un año dividido por días de la semana ordenado primero horizontalmente y luego verticalmente.




Figura 40. Consumo eléctrico agrupado por día de la semana en Madrid a lo largo de un año

Se observan consumos de energía eléctrica muy parecidos durante todos los días laborables, con dos picos a las doce del mediodía y a las siete de la tarde, con un valle a las cuatro de la tarde. El pico de la tarde es más pequeño el jueves, y sobre todo el viernes. En los sábados se detecta un pico a media mañana, aunque no es tan elevado como el que se descubría durante los días laborables. Finalmente, los domingos hay un consumo bastante bajo durante todo el día.

Para acometer la clasificación de los clientes en distintos patrones de consumo con ayuda de mapas autoorganizados de Kohonen, se utilizaron las configuraciones que se muestran en la Tabla 6.

<i>Municipio</i>	<i>Tabla</i>	<i>Mapa</i>
Madrid	Diario	5x5
	Sábado	5x5
	Domingo	4x4
	Temperatura	5x5

Tabla 6. Dimensiones utilizadas para los mapas autoorganizados en Madrid

Una vez el modelo para cada tabla de Madrid se entrenó, se calcularon las medidas de calidad de clustering, cuyos valores se pueden encontrar en la Tabla 7. La gran mayoría de los casos está alrededor del 80% de clientes cuya neurona predominante fue la misma en el conjunto de datos de training y también en el de test, obteniendo un mínimo en la tabla de temperaturas altas con un 75%, que sigue siendo un valor más que correcto.

<i>Municipio</i>	<i>L</i>	<i>M</i>	<i>X</i>	<i>J</i>	<i>V</i>	<i>S</i>	<i>D</i>	<i>T.Alta</i>	<i>T.Media</i>	<i>T.Baja</i>
Madrid	78%	79%	76%	79%	79%	83%	84%	75%	80%	78%

Tabla 7. Porcentaje de clientes cuya neurona predominante fue la misma en Madrid

Al ser estos porcentajes correctos, se puede decir que el modelo tuvo un buen entrenamiento. En la Figura 41 se muestra la demanda eléctrica agregada para los martes de temperatura media en Madrid realizados con las últimas medidas del conjunto de test. Como se observa, el modelo no ha quedado obsoleto, aunque ya se encuentra un buen

número de clientes que no mantiene su patrón de consumo. Dentro de estos clientes que han cambiado su patrón, han variado su consumo algo más de un 50%, lo que es un cambio bastante considerable.




Figura 41. Demanda eléctrica agregada estimada para Madrid

Madrid cuenta con un buen número de clientes industriales con un consumo muy constante a lo largo del día, sin embargo, la mayor parte del consumo eléctrico en Madrid viene de empresas industriales o, en su mayoría, del sector servicios, que tienen un consumo marcado por un pico de consumo al mediodía y otro pico más bajo a última hora de la tarde, con un valle a primeras horas de la tarde. Es por eso por lo que la demanda eléctrica agregada acaba teniendo esta forma tan característica que se puede observar en la Figura 41.

Tanto el primer grupo de clientes como el segundo podría reducir su demanda de energía eléctrica reduciendo la potencia contratada, cambiando toda su iluminación a bombillas leds, y, especialmente los clientes industriales, evitando pérdidas de tensión.

También se pueden ofrecer algunas medidas para tratar de desplazar la demanda eléctrica de los picos a los valles de consumo. Esto afectaría principalmente al grupo de clientes que no realizan un consumo constante. Para ello, se proponen tarifas con discriminación horaria, que incitan mediante un menor coste de la electricidad, a que el consumidor desplace sus horas de consumo, o al menos, desplace aquellos procesos que puede llevar a cabo en otras horas.

12.2 BARCELONA

En el municipio de Barcelona se cuenta con datos de 115 clientes, la segunda cifra más elevada después de la de Madrid dentro de los seis municipios sobre los que se centra el estudio. Como primera toma de contacto con la ciudad, observamos en la Figura 42 el consumo real durante un año dividido por días de la semana ordenado primero horizontalmente y luego verticalmente.




Figura 42. Consumo eléctrico agregado por día de la semana en Barcelona a lo largo de un año

Se observan consumos de energía eléctrica muy parecidos durante todos los días laborables, con dos picos a las doce del mediodía y a las siete de la tarde, con un valle a las cuatro de la tarde. El pico de la tarde es más pequeño el viernes. En los sábados se detecta un pico a media mañana, aunque no es tan elevado como el que se descubriría durante los días laborables. Finalmente, los domingos hay un consumo muy bajo y constante durante todo el día.

Para acometer la clasificación de los clientes en distintos patrones de consumo con ayuda de mapas autoorganizados de Kohonen, se utilizaron las configuraciones que se muestran en la Tabla 8.

<i>Municipio</i>	<i>Tabla</i>	<i>Mapa</i>
Barcelona	Diario	6x4
	Sábado	6x4
	Domingo	4x3
	Temperatura	6x4

Tabla 8. Dimensiones utilizadas para los mapas autoorganizados en Barcelona

Una vez el modelo para cada tabla de Barcelona se entrenó, se calcularon las medidas de calidad de clustering, cuyos valores se pueden encontrar en la Tabla 9. Con los datos de todas las tablas salvo una, son más del 80% de clientes cuya neurona predominante fue la misma en el conjunto de datos de training y también en el de test, existiendo casos muy cercanos al 90%.

<i>Municipio</i>	<i>L</i>	<i>M</i>	<i>X</i>	<i>J</i>	<i>V</i>	<i>S</i>	<i>D</i>	<i>T.Alta</i>	<i>T.Media</i>	<i>T.Baja</i>
Barcelona	83%	85%	79%	87%	83%	83%	88%	89%	90%	84%

Tabla 9. Porcentaje de clientes cuya neurona predominante fue la misma en Barcelona

Al ser estos porcentajes muy elevados, se puede decir que el modelo tuvo un entrenamiento muy bueno. En la Figura 43 se muestra la demanda eléctrica agregada para los miércoles de temperatura alta en Barcelona realizados con las últimas medidas del conjunto de test. Como se observa, el modelo está empezando a quedarse obsoleto, pues ya se encuentra un buen porcentaje de clientes que no mantiene su patrón de consumo, mayor al 15%. Dentro de estos clientes que han cambiado su patrón, han variado su consumo cerca del 50%, lo que es un cambio considerable.

Barcelona cuenta con un buen número de clientes industriales que tienen un consumo constante a lo largo de las horas del día, tanto durante la semana como durante la tarde, y también cuenta con ciertos clientes que tienen un consumo con los picos de demanda característicos durante medio día y a última hora de la tarde, aunque los clientes con mayor consumo eléctrico en Barcelona tienen un gran pico a medio día pero el pico de la tarde es mucho más pequeño que en otras ciudades, y es por eso que el pico de la tarde no es tan elevado como lo es, por ejemplo, en la ciudad de Madrid.




Figura 43. Demanda eléctrica agregada estimada para Barcelona

En el caso de Barcelona, tratar de desplazar la demanda eléctrica de los picos a los valles de consumo es especialmente difícil, debido a que el gran pico del mediodía parece que nace porque las empresas de servicios tienen necesidad a esa hora de consumir energía. Aun así, sería bueno contar con tarifas con discriminación horaria, para que aquellos que puedan realizar sus labores a otras horas, se vean beneficiados al realizarlas en momentos con menor demanda agregada de energía.

Sería interesante reducir su demanda de energía eléctrica que se demanda de forma continua. Esto sería posible con algunas medidas que tendrían que llevar a cabo las industrias y que tendrían una repercusión grande en la curva agregada de la demanda, y estas medidas son reducir la potencia contratada, cambiar toda la iluminación a bombillas leds y evitar en todo lo posible pérdidas de tensión.

12.3 CÁCERES

En el municipio de Cáceres se cuenta con datos de 81 clientes, un número inferior al 10% del total de los clientes, con lo cual, aunque tendrá cierto peso sobre el total, no será de los municipios más importantes. Como primera toma de contacto con la ciudad, observamos en la Figura 44 el consumo real durante un año dividido por días de la semana ordenado primero horizontalmente y luego verticalmente.




Figura 44. Consumo eléctrico agregado por día de la semana en Cáceres a lo largo de un año

Se observan consumos de energía eléctrica muy parecidos durante todos los días laborables, con dos picos a las doce del mediodía y a las siete de la tarde, con un valle a las cuatro de la tarde. El pico de la tarde es más pequeño el viernes. En los sábados se detecta un pico a media mañana, aunque no es tan elevado como el que se descubriría durante los días laborables. Finalmente, los domingos hay un consumo muy bajo y constante durante todo el día, aunque sorprende que durante este día el consumo más elevado un pequeño pico a primeras horas de la noche.

Para acometer la clasificación de los clientes en distintos patrones de consumo con ayuda de mapas autoorganizados de Kohonen, se utilizaron las configuraciones que se muestran en la Tabla 10.

<i>Municipio</i>	<i>Tabla</i>	<i>Mapa</i>
Cáceres	Diario	5x5
	Sábado	5x4
	Domingo	4x3
	Temperatura	6x4

Tabla 10. Dimensiones utilizadas para los mapas autoorganizados en Cáceres

Una vez el modelo para cada tabla de Cáceres se entrenó, se calcularon las medidas de calidad de clustering, cuyos valores se pueden encontrar en la Tabla 11. En la mayoría de los casos, solamente un porcentaje algo mayor al 70% de los clientes son aquellos cuya neurona predominante fue la misma en el conjunto de datos de training y en el de test, aunque hay algunos casos superiores al 80%.

Municipio	L	M	X	J	V	S	D	T.Alta	T.Media	T.Baja
Cáceres	75%	75%	72%	70%	71%	84%	91%	85%	77%	70%

Tabla 11. Porcentaje de clientes cuya neurona predominante fue la misma en Cáceres

Al ser estos porcentajes bastante bajos, se puede decir que el modelo no tuvo un entrenamiento demasiado bueno, quizás influido porque no se tenían tantos datos como en los casos de Madrid o Barcelona. En la Figura 45 se muestra la demanda eléctrica agregada para los jueves de temperatura baja en Cáceres realizados con las últimas medidas del conjunto de test. Como se observa, el modelo está empezando a quedarse obsoleto, pues ya se encuentra un buen porcentaje de clientes que no mantiene su patrón de consumo, mayor al 15%. Dentro de estos clientes que han cambiado su patrón, han variado su consumo más del 50%, lo que es un cambio bastante grande.




Figura 45. Demanda eléctrica agregada estimada para Cáceres

En Cáceres se encuentra un patrón de consumo de energía propio de un gran consumidor industrial, pues tiene un consumo muy elevado durante todas las horas del día y de la

noche. Sin embargo, son pocos los clientes que siguen este patrón, y tampoco se encuentran otros patrones de consumo industrial, y son muchos los que siguen un patrón con dos picos y un valle, y es por ello por lo que, a pesar de contar con un perfil de consumo industrial muy elevado, al final la forma de la demanda agregada muestra dos picos y un valle muy marcados.

Es importante en Cáceres tratar de desplazar la demanda eléctrica hacia los valles de consumo, pues es la ciudad que tiene una mayor diferencia relativa entre sus picos y sus valles de consumo. Es por ello por lo que es de gran importancia introducir tarifas con discriminación horaria, para que aquellos clientes que puedan mover sus consumos más elevados a las horas valle se vean recompensados con un coste menor de la electricidad, promoviendo así a que la demanda agregada sea más constante.

También podría tratarse de reducir la demanda de energía eléctrica por parte de las industrias reduciendo la potencia contratada, cambiando toda su iluminación a bombillas leds, y, especialmente los clientes industriales, evitando pérdidas de tensión.

12.4 LA CORUÑA




Figura 46. Consumo eléctrico agregado por día de la semana en La Coruña a lo largo de un año

En el municipio de La Coruña se cuenta con datos de 42 clientes, la cifra más baja dentro de los seis municipios sobre los que se centra el estudio. Como primera toma de contacto con la ciudad, observamos en la Figura 46 el consumo real durante un año dividido por días de la semana ordenado primero horizontalmente y luego verticalmente.

Aunque se percibe una forma de consumo muy similar durante los siete días de la semana, con la aparición de dos picos, uno a primeras horas de la tarde y otro a primeras horas de la mañana, hay demasiados consumos a distintos niveles, ensuciando la visibilidad. Por ello, se decidió dibujar la Figura 47, mostrando solo el consumo de los últimos tres meses.




Figura 47. Consumo eléctrico agregado por día de la semana en La Coruña a lo largo de tres meses

Ahora se observa mejor la forma, aunque parece que los últimos meses se han realizado consumos más bajos que durante el resto del año. Durante los días de la semana el consumo tiende a ser más constante durante la tarde, apareciendo en los fines de semana un valle a últimas horas de la tarde.

Para acometer la clasificación de los clientes en distintos patrones de consumo con ayuda de mapas autoorganizados de Kohonen, se utilizaron las configuraciones que se muestran en la Tabla 12.

<i>Municipio</i>	<i>Tabla</i>	<i>Mapa</i>
La Coruña	Diario	4x6
	Sábado	4x6
	Domingo	4x6
	Temperatura	5x5

Tabla 12. Dimensiones utilizadas para los mapas autoorganizados en La Coruña

Una vez el modelo para cada tabla de La Coruña se entrenó, se calcularon las medidas de calidad de clustering, cuyos valores se pueden encontrar en la Tabla 13. En todos los casos, alrededor del 80% de los clientes son aquellos cuya neurona predominante fue la misma en el conjunto de datos de training y en el de test, aunque varía bastante entre unas tablas y otras, llegando a valer cerca del 75% en algunas ocasiones y cerca del 90% en otras.

<i>Municipio</i>	<i>L</i>	<i>M</i>	<i>X</i>	<i>J</i>	<i>V</i>	<i>S</i>	<i>D</i>	<i>T.Alta</i>	<i>T.Media</i>	<i>T.Baja</i>
La Coruña	83%	76%	74%	88%	83%	90%	79%	76%	88%	86%

Tabla 13. Porcentaje de clientes cuya neurona predominante fue la misma en La Coruña

Al ser estos porcentajes bastante elevados, se puede decir que el modelo tuvo un buen entrenamiento. En la Figura 48 se muestra la demanda eléctrica agregada para los lunes de temperatura baja en La Coruña realizados con las últimas medidas del conjunto de test. Como se observa, el modelo está totalmente actualizado, pues solamente se encuentra un porcentaje muy bajo de clientes que no mantiene su patrón de consumo. Dentro de estos clientes que han cambiado su patrón, han variado su consumo cerca del 50%, lo que es un cambio considerable.

En La Coruña, los tres patrones de consumo que muestran un consumo total más elevado son consumidores nocturnos, mostrando una mayor demanda de energía eléctrica durante las horas de la noche que durante las horas de día, de hecho, el primer patrón muestra un característico pico durante las primeras horas de la noche. Hay que llegar hasta el cuarto perfil con mayor demanda total de energía para encontrar un patrón con dos horas punta y un valle. Por eso la demanda agregada total tiene la forma que se presenta.




Figura 48. Demanda eléctrica agregada estimada para La Coruña

La primera propuesta con vistas a la optimización de la gestión activa de la demanda pasaría por tratar de reducir la demanda de energía eléctrica continua, mediante la contratación de una potencia más reducida, el cambio de la iluminación a bombillas led y tratando de evitar pérdidas de tensión en los procesos de las industrias.

También sería interesante conseguir desplazar un poco la demanda eléctrica hacia más entrada la noche o incluso la madrugada. Si se ofrecieran tarifas con discriminación horaria, quizás el pico que ocurre a primeras horas de la noche podría moverse un par de horas más tarde y no coincidiría con los picos de demanda de energía eléctrica que suceden en otras ciudades.

12.5 MÁLAGA

En el municipio de Málaga se cuenta con datos de 93 clientes, la tercera cifra más elevada después de las de Madrid y Barcelona dentro de los seis municipios sobre los que se centra el estudio. Como primera toma de contacto con la ciudad, observamos en la Figura 49 el consumo real durante un año dividido por días de la semana ordenado primero horizontalmente y luego verticalmente.




Figura 49. Consumo eléctrico agregado por día de la semana en Málaga a lo largo de un año

Se observan consumos de energía eléctrica muy parecidos durante todos los días laborables, siendo máximo y constante durante toda la noche, desde primera hora de la noche a primera hora de la mañana. Se observa también el crecimiento de consumo entre media mañana y primeras horas de la tarde, apareciendo dos valles, uno a primera hora de la mañana y otro a últimas horas de la tarde. Durante los fines de semana, el crecimiento de consumo durante la tarde no existe, siendo además los domingos muy bajo el crecimiento de consumo durante media mañana.

Para acometer la clasificación de los clientes en distintos patrones de consumo con ayuda de mapas autoorganizados de Kohonen, se utilizaron las configuraciones que se muestran en la Tabla 14.

<i>Municipio</i>	<i>Tabla</i>	<i>Mapa</i>
Málaga	Diario	5x5
	Sábado	5x4
	Domingo	5x4
	Temperatura	5x5

Tabla 14. Dimensiones utilizadas para los mapas autoorganizados en Málaga

Una vez el modelo para cada tabla de Málaga se entrenó, se calcularon las medidas de calidad de clustering, cuyos valores se pueden encontrar en la Tabla 15. En todos los casos, un porcentaje mayor al 80% de los clientes son aquellos cuya neurona predominante fue la misma en el conjunto de datos de training y en el de test, y de hecho hay algunos casos superiores al 90%.

Municipio	L	M	X	J	V	S	D	T.Alta	T.Media	T.Baja
Málaga	86%	86%	89%	84%	88%	84%	82%	91%	92%	86%

Tabla 15. Porcentaje de clientes cuya neurona predominante fue la misma en Málaga

Al ser estos porcentajes elevados en todos los casos, se puede decir que el modelo tuvo un entrenamiento muy bueno. En la Figura 50 se muestra la demanda eléctrica agregada para los miércoles de temperatura baja en Málaga realizados con las últimas medidas del conjunto de test. Como se observa, el modelo está en cierto modo actualizado, aunque ya se encuentra cierto número de clientes que no mantiene su patrón de consumo. Dentro de estos clientes que han cambiado su patrón, han variado su consumo algo más de un 60%, lo que es un cambio bastante alto.




Figura 50. Demanda eléctrica agregada estimada para Málaga

En el municipio de Málaga se encuentra una mezcla de dos tipos de consumidores. Por un lado, hay gran cantidad de consumidores totalmente nocturnos; clientes que durante el día hacen un consumo de energía eléctrica que podría considerarse nulo, y que durante la

noche y la madrugada hacen uso de una gran cantidad de electricidad. Por otro lado, aunque son menores en número y en consumo total, se encuentran patrones de consumo con picos de consumo al mediodía y a últimas horas de la tarde, con un valle durante la tarde. Así, al agregar todas las demandas, se encuentra una curva como la vista en la Figura 50.

Tanto el primer grupo de clientes, el de los consumidores meramente nocturnos, como el segundo, el que presenta dos picos y un valle en la curva de su demanda, podría reducir su demanda de energía eléctrica reduciendo la potencia contratada, cambiando toda su iluminación a bombillas leds, y, especialmente los clientes industriales, evitando pérdidas de tensión.

También se pueden ofrecer algunas medidas para tratar de desplazar la demanda eléctrica de los picos a los valles de consumo. Esto afectaría principalmente al grupo de clientes que realizan la mayor parte de su consumo durante los picos de demanda. Para ello, se proponen tarifas con discriminación horaria, que incitan mediante un menor coste de la electricidad, a que el consumidor desplace sus horas de consumo, o al menos, desplace aquellos procesos que puede llevar a cabo en otras horas.

12.6 VALENCIA




Figura 51. Consumo eléctrico agregado por día de la semana en Valencia a lo largo de un año

En el municipio de Valencia se cuenta con datos de 85 clientes, un número inferior al 10% del total de los clientes, con lo cual, aunque tendrá cierto peso sobre el total, no será de los municipios más importantes. Como primera toma de contacto con la ciudad, observamos en la Figura 51 el consumo real durante un año dividido por días de la semana ordenado primero horizontalmente y luego verticalmente.

Se observan consumos de energía eléctrica muy parecidos durante todos los días laborables, con dos picos a las doce del mediodía y a las siete de la tarde, con un valle a las cuatro de la tarde. El pico de la tarde es más pequeño el viernes. En los sábados se detecta un pico a media mañana, aunque no es tan elevado como el que se descubriría durante los días laborables. Finalmente, los domingos hay un consumo muy bajo y constante durante todo el día.

Para acometer la clasificación de los clientes en distintos patrones de consumo con ayuda de mapas autoorganizados de Kohonen, se utilizaron las configuraciones que se muestran en la Tabla 16.

<i>Municipio</i>	<i>Tabla</i>	<i>Mapa</i>
Valencia	Diario	6x4
	Sábado	6x4
	Domingo	3x4
	Temperatura	6x4

Tabla 16. Dimensiones utilizadas para los mapas autoorganizados en Valencia

Una vez el modelo para cada tabla de Valencia se entrenó, se calcularon las medidas de calidad de clustering, cuyos valores se pueden encontrar en la Tabla 17. En la mayoría de los casos, un porcentaje algo mayor al 80% de los clientes son aquellos cuya neurona predominante fue la misma en el conjunto de datos de training y en el de test, aunque hay algunos casos cercanos al 75%.

<i>Municipio</i>	<i>L</i>	<i>M</i>	<i>X</i>	<i>J</i>	<i>V</i>	<i>S</i>	<i>D</i>	<i>T.Alta</i>	<i>T.Media</i>	<i>T.Baja</i>
Valencia	80%	84%	84%	72%	78%	81%	91%	80%	79%	75%

Tabla 17. Porcentaje de clientes cuya neurona predominante fue la misma en Valencia

Al ser estos porcentajes muy elevados salvo en alguna ocasión, se puede decir que el modelo tuvo un entrenamiento muy bueno en la mayoría de los casos. En la Figura 52 se muestra la demanda eléctrica agregada para los miércoles de temperatura media en Valencia realizados con las últimas medidas del conjunto de test. Como se observa, el modelo se encuentra bastante actualizado, y se encuentra un porcentaje bajo de clientes que no mantiene su patrón de consumo, inferior al 10%. Dentro de estos clientes que han cambiado su patrón, han variado su consumo inferior al 50%, lo que es un cambio elevado, aunque no demasiado grande.




Figura 52. Demanda eléctrica agregada estimada para Valencia

En Valencia se encuentra un patrón de consumo de energía propio de un gran consumidor industrial, con un consumo muy elevado durante todas las horas del día y de la noche. Este patrón es el que tiene un consumo total de energía eléctrica más elevado, sin embargo, apenas se encuentran otros patrones de consumo industrial, y son muchos los que siguen un patrón con dos picos y un valle, y es por ello por lo que, a pesar de contar con un perfil de consumo industrial muy elevado, al final la forma de la demanda agregada muestra dos picos y un valle muy marcados.

Tratar de desplazar la demanda eléctrica hacia los valles de consumo es la máxima prioridad en Valencia a la hora de aplanar la curva de la demanda de energía eléctrica. Es por ello por lo que es de gran importancia introducir tarifas con discriminación horaria, para que aquellos clientes que puedan mover sus consumos más elevados a las horas valle se vean recompensados con un coste menor de la electricidad, promoviendo así a que la demanda agregada sea más constante.

También podría tratarse de reducir la demanda de energía eléctrica por parte de las industrias reduciendo la potencia contratada, cambiando toda su iluminación a bombillas leds, y, especialmente los clientes industriales, evitando pérdidas de tensión.

12.7 COMPARATIVA

Se han realizado por último modelos para la demanda agregada de los diferentes municipios estudiados con anterioridad para tratar de obtener modelos a nivel nacional. En la Tabla 18, se observa cómo Madrid aporta una mayor cantidad de datos de estudio, y, por tanto, los patrones que se encuentren a nivel nacional serán más parecidos a los encontrados para Madrid. Esto no quiere decir que el patrón de Madrid sea el más importante, simplemente que, al estar los datos tan desbalanceados, tomarán mayor protagonismo en este estudio.

Provincia	Madrid	Barcelona	Cáceres	La Coruña	Málaga	Valencia	Total
Clientes	61,8%	10,6%	7,4%	3,9%	8,5%	7,8%	1105

Tabla 18. Clientes por provincia en porcentaje

La Figura 53 muestra el consumo real durante un año dividido por días de la semana ordenado primero horizontalmente y luego verticalmente para el conjunto de datos formado por la unión de los seis municipios, de los cuales se ha visto la proporción de participación en la Tabla 18.




Figura 53. Consumo eléctrico agregado por día de la semana con todos los datos a lo largo de un año

Como la imagen obtenida no nos permite visualizar correctamente la curva de la demanda, se ha procedido a seleccionar los datos de las fechas más próximas a la fecha de estudio y se observan en la Figura 54, donde los datos están ordenados de izquierda a derecha y desde arriba hacia abajo para los diferentes días de la semana.




Figura 54. Consumo eléctrico agregado por día de la semana con todos los datos durante tres meses

En la Figura 54 se observa cómo de lunes a jueves la curva de la demanda muestra dos picos pronunciados, a medio día y durante las últimas horas del día, y un valle durante la tarde, mientras que, en los viernes, el segundo pico es mucho más reducido, llegando a ser inexistente los sábados. Durante los domingos, se encuentra un consumo muy constante durante las horas diurnas y las nocturnas, teniendo un pequeño pico a primera hora de la noche.

En la Tabla 19 se muestran las distribuciones seguidas para los mapas autoorganizados de Kohonen, observándose cómo la cantidad de neuronas para las tablas de días de diario y para las tablas de distintas temperaturas es mayor que la cantidad de neuronas para días de fin de semana, debido a que hay una mayor variedad de patrones durante los días de diario y una mayor estabilidad en los patrones de consumo durante los fines de semana.

Municipio	Tabla	Mapa
Todos	Diario	6x4
	Sábado	4x5
	Domingo	4x3
	Temperatura	6x4

Tabla 19. Dimensiones utilizadas para los mapas autoorganizados para todos los datos juntos

Se ha considerado evaluar la bondad del ajuste del modelo a través de la creación de una medida de calidad de clustering, mediante la cual se puede valorar si el entrenamiento llevado a cabo del modelo ha sido el adecuado. Esta medida de calidad de clustering es la proporción de clientes cuyo patrón de consumo con los datos de entrenamiento y con los datos de test ha sido el mismo.

Municipio	L	M	X	J	V	S	D	T.Alta	T.Media	T.Baja
Todos	77%	80%	78%	79%	79%	83%	85%	78%	83%	79%

Tabla 20. Porcentaje de clientes cuya neurona predominante fue la misma para todos los datos juntos

Como se observa en la Tabla 20, la medida de calidad de clustering en todos los casos ronda el 80%, aunque cabe destacar que en el caso del domingo tiene un valor del 85%. Este dato nos indica que el modelo de clustering creado ha sido bien ajustado.




Figura 55. Demanda eléctrica estimada para el caso de los datos de todos los municipios unidos

En la Figura 55 se muestra la demanda eléctrica agregada para los jueves de temperatura baja realizados con las últimas medidas del conjunto de test de los seis municipios agregados. Como se observa, el modelo está en cierto modo desactualizado, aunque ya se encuentra un elevado número de clientes que no mantiene su patrón de consumo. Dentro de estos clientes que han cambiado su patrón, han variado su consumo algo más de un 60%, lo que es un cambio bastante alto.

Dentro de los tres perfiles más característicos para este modelo, aquellos perfiles que han tenido un mayor consumo total de energía eléctrica, se encuentran dos perfiles que muestran un mayor consumo desde media mañana hasta última hora de la tarde, con unos picos poco pronunciados a las horas características, y un tercer perfil con un consumo muy continuo a lo largo de todas las horas diurnas y nocturnas. Después, aparecen muchos perfiles con picos de demanda eléctrica más pronunciados a medio día y a última hora de la tarde, consiguiendo que la demanda agregada total obtenga dicha forma.

Así, aunque se hayan ofrecido acciones con vistas a la optimización de la gestión activa de la demanda para las distintas ciudades, se presentan a continuación las dos acciones más características.

Resulta interesante desplazar la demanda eléctrica de los picos a los valles de consumo, para lo cual se necesitaría contar con tarifas con discriminación horaria, para que aquellos clientes que puedan realizar sus labores a otras horas, se vean beneficiados al realizarlas en momentos con menor demanda agregada de energía.

También gana importancia la reducción de demanda de energía eléctrica continua. Esto sería posible con algunas medidas que tendrían que llevar a cabo las industrias y que tendrían una repercusión grande en la curva agregada de la demanda, y estas medidas son reducir la potencia contratada, cambiar toda la iluminación a bombillas leds y evitar en todo lo posible pérdidas de tensión.

Capítulo 13. CONCLUSIONES Y TRABAJOS FUTUROS

Gracias al perfilado de los distintos clientes en función de su geografía y características de calendario y atmosféricas, se conoce mejor el consumo del sector no residencial, así como los patrones de consumo más recurrentes y los más característicos.

El presente trabajo ha sido llevado a cabo con una muestra de consumo eléctrico de clientes del sector no residencial en España, con la idea de ser un estudio piloto para un posible trabajo a futuro a mayor escala, capaz de realizar la monitorización a tiempo real del consumo eléctrico de los distintos clientes.

Por un lado, los clientes recibirían mensajes informativos, así como alarmas cuando su consumo sobrepase unos límites o la demanda agregada haga lo propio, haciendo que la tarifa flexible de energía eléctrica afecte a los clientes. De esta forma, el cliente tendría la posibilidad de gestionar mejor su demanda de energía eléctrica, con un mayor conocimiento tanto de su consumo como del agregado.

Por otro lado, los suministradores de energía conocerían mejor las necesidades de sus clientes en todo momento, pudiendo planear de manera óptima la activación de generadores de energía en función de la demanda agregada de energía de sus clientes, y controlando aquellos consumos que muestren un comportamiento extraño al contar con más información.

Las conclusiones extraíbles de esta prueba realizada con la muestra de datos es que la demanda y el patrón de consumo de los clientes cambia en función del día de la semana, incluso lo hace también en función de la temperatura que haga ese día.

Se han propuesto acciones con vistas a la optimización de la gestión activa de la demanda, que, con la ayuda de la implementación de la arquitectura de comunicaciones propuesta, serán capaces de comunicarse de forma instantánea a los consumidores no residenciales objetivos.

Así, se deja abierto como un posible trabajo futuro la integración de este estudio, u otro con el mismo objetivo, con un sistema de recopilación de datos en tiempo real, pudiendo así implementar alarmas y mensajes instantáneos que puedan servir de ayuda para la optimización de la gestión activa de la demanda, tanto para los consumidores como para los productores de energía.

Otro trabajo futuro que se deja abierto es el estudio de la energía reactiva, que no ha sido llevado a cabo en el presente trabajo porque han preferido centrarse los esfuerzos en realizar un estudio a fondo de los patrones de la energía activa, aunque perfectamente se podría llevar a cabo también con esta otra.

La implementación de algoritmos de series temporales a estos mismos datos también puede ser un interesante trabajo futuro, pudiendo llegar a predecir series temporales así como la posible evolución de la curva de la demanda que en este trabajo se ha calculado.

Capítulo 14. BIBLIOGRAFÍA

- [1] "Series estadísticas nacionales", Red Eléctrica de España, 2018. [Online]. Available: <http://www.ree.es/es/estadisticas-del-sistema-electrico-espanol/series-estadisticas/series-estadisticas-nacionales>. [Accessed: 20- Feb- 2018].
- [2] "La gestión de la demanda en el sector eléctrico español", Borja Domínguez Mouriz, 2012. [Online]. Available: <https://www.iit.comillas.edu/pfc/resumenes/4fc6c15ba5d0a.pdf>. [Accessed: 5- Mar- 2018].
- [3] "Análisis de perfiles de consumo de energía eléctrica en una muestra de clientes del sector residencial", Jorge García-Morales Merino, 2017. [Online]. Available: <https://www.iit.comillas.edu/pfc/resumenes/59a736fc79965.pdf>. [Accessed: 7- Jun- 2018].
- [4] "Guía de consumo inteligente", Red Eléctrica de España, 2013. [Online]. Available: http://www.ree.es/sites/default/files/downloadable/guia_consumo_v2.pdf. [Accessed: 5- Mar- 2018].
- [5] "Centro de descargas", Agencia Estatal de Meteorología, 2018. [Online]. Available: <https://opendata.aemet.es/centrodedescargas/productosAEMET>. [Accessed: 3- Mar- 2018].
- [6] "1.1 Descripción de MATLAB", Nereida.deioc.ull.es, 2018. [Online]. Available: <http://nereida.deioc.ull.es/~pcgull/ihiu01/cdrom/matlab/contenido/node2.html>. [Accessed: 10- Feb- 2018].
- [7] "Redes neuronales", Mathworks.com, 2017. [Online]. Available: <https://es.mathworks.com/discovery/redes-neuronales.html>. [Accessed: 11- Feb- 2018].
- [8] "Unsupervised learning", Machine learning for humans, 2017. [Online]. Available: <https://medium.com/machine-learning-for-humans/unsupervised-learning-f45587588294>. [Accessed: 11- Feb- 2018].
- [9] "Los mapas auto-organizados de Kohonen (SOM) ", UC3M, 2014. [Online]. Available: <http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/DM/tema5dm.pdf>. [Accessed: 13- Feb- 2018].
- [10] "Métodos jerárquicos de análisis cluster", UGR, 2015. [Online]. Available: <http://www.ugr.es/~gallardo/pdf/cluster-3.pdf>. [Accessed: 15- Feb- 2018].


- [11] "Introduction to K-means clustering", Learn Data Science, 2017. [Online]. Available: <https://www.datascience.com/blog/k-means-clustering>. [Accessed: 15- Feb- 2018].
- [12] "Centro de control eléctrico", Red eléctrica de España, 2017. [Online]. Available: <http://www.ree.es/es/actividades/operacion-del-sistema-electrico/centro-de-control-electrico>. [Accessed: 15- Mar- 2018].
- [13] "El consume de energía eléctrica en la industria española", Cómo ahorrar luz, 2017. [Online]. Available: <https://www.aura-energia.com/consumo-energia-electrica-industria-espanola/>. [Accessed: 11- Mar- 2018].
- [14] "Informe sintético de indicadores de eficiencia energética", IDAE, 2015. [Online]. Available: http://www.idae.es/sites/default/files/estudios_informes_y_estadisticas/informe_indicadores_ee_2015_27072017.pdf. [Accessed: 13- Mar- 2018].
- [15] "Sistema universitario español", Universidad Pontificia Comillas, 2011. [Online]. Available: <http://www.comillas.edu/es/sistema-universitario-espanol>. [Accessed: 15- Mar- 2018].
- [16] "Sensor de insolación", MeteoGlosario Visual, 2014. [Online]. Available: <https://meteoglosario.aemet.es/?pag=termino&ter=929>. [Accessed: 18- Mar- 2018].
- [17] "Introduction to Data Analysis using Machine Learning", NoSimpler Analytics, 2017. [Online]. Available: <http://www.nosimpler.me/machine-learning/>. [Accessed: 4- Apr- 2018].
- [18] "Conceptos y Técnicas: Preprocesamiento", Simon Fraser University, 2015. [Online]. Available: http://cs.uns.edu.ar/~cic/dm2007/downloads/transparencias/06_Sobre_Preprocesamiento_datos.pdf. [Accessed: 7- Apr- 2018].
- [19] "Convert JSON to CSV", Data Design Group, Inc, 2018. [Online]. Available: <http://www.convertcsv.com/json-to-csv.htm> [Accessed: 6- Mar- 2018].
- [20] "Aplicación de Metodologías Machine Learning en la Gestión de Riesgo de Crédito", David Trujillo Fernández, 2017. [Online]. Available: http://oa.upm.es/47087/1/TFG_DAVID_TRUJILLO_FERNANDEZ.pdf. [Accessed: 23- Apr- 2018].
- [21] "Qué es overfitting y underfitting y cómo solucionarlo", Aprende Machine Learning, 2017. [Online]. Available: <http://www.aprendemachinelearning.com/que-es-overfitting-y-underfitting-y-como-solucionarlo/>. [Accessed: 8- Apr- 2018].



- [22] "Técnicas de clusterización", Juan de Dios Lara Albín, 2014. [Online]. Available:
<http://bibing.us.es/proyectos/abreproy/5453/fichero/PFC+tecnicas+clusterizacion.pdf>.
[Accessed: 18- Apr- 2018].



ANEXO A – ERROR DE CUANTIFICACIÓN



En este anexo se muestran los errores de cuantificación obtenidos con kmeans para los distintos números de clusters para todos los días de la semana de los seis municipios. Para una mayor comprensión de los resultados, se recomienda leer el [capítulo](#) donde todo esto se explica.

Barcelona
















Madrid
















Cáceres
















La Coruña
















Málaga
















Valencia









ANEXO B – ERROR DE CLUSTERING

En este anexo se muestran los errores de clustering cometidos para los distintos mapas autoorganizados de Kohonen y sus respectivas dimensiones. Se muestra el error obtenido para cada una de las tablas. Se muestra resaltado en negrita los dígitos más significativos para comparar los resultados de una forma más rápida, y subrayadas en amarillo aquellas dimensiones que finalmente se eligieron. Para una explicación más profunda, se recomienda leer el [capítulo](#) donde se trata este tema.

Barcelona

Lunes

3x4 -> **4.829**493718695877e+03
4x3 -> **4.633**003513955231e+03
4x4 -> **4.265**792343788211e+03
4x5 -> **4.098**637248295538e+03
5x4 -> **3.976**648261052898e+03
4x6 -> **3.913**461663572019e+03
6x4 -> 3.859042365976233e+03
5x5 -> **3.858**186987550105e+03

Martes

3x4 -> **5.014**495937951638e+03
4x3 -> **4.800**230832875631e+03
4x4 -> **4.441**263615887297e+03
4x5 -> **4.284**045942055855e+03
5x4 -> **4.269**693834959477e+03
4x6 -> **4.133**79761189351e+03
6x4 -> 4.011599121661855e+03
5x5 -> **4.111**219411310342e+03

Miércoles

3x4 -> **4.996**985548847808e+03
4x3 -> **4.773**897101155180e+03
4x4 -> **4.427**912766739355e+03
4x5 -> **4.301**654437147892e+03
5x4 -> **4.132**839871484911e+03
4x6 -> **4.119**443259946014e+03
6x4 -> 4.054121801206437e+03
5x5 -> **4.064**486101649298e+03

Jueves

3x4 -> **4.875**759219380350e+03
4x3 -> **4.577**744123518358e+03
4x4 -> **4.304**830363756257e+03
4x5 -> **4.144**207983010391e+03
5x4 -> **4.067**887375365587e+03
4x6 -> **3.991**508683670683e+03
6x4 -> 3.858833829812984e+03
5x5 -> **3.861**848146199114e+03

ANEXO B – ERROR DE CLUSTERING

Viernes

3x4 -> **4.716617600989645e+03**
 4x3 -> **4.506293620498287e+03**
 4x4 -> **4.224087611379608e+03**
 4x5 -> **4.000403110645626e+03**
 5x4 -> **3.978333400932821e+03**
 4x6 -> **3.871172938900239e+03**
6x4 -> 3.782962706615834e+03
 5x5 -> **3.837843856083117e+03**

Sábado

3x4 -> **3.655654192975681e+03**
 4x3 -> **3.700226604360436e+03**
 4x4 -> **3.302287249020710e+03**
 4x5 -> **3.158835099433746e+03**
 5x4 -> **2.984945447197731e+03**
 4x6 -> **3.045141594063400e+03**
6x4 -> 2.897370501229362e+03
 5x5 -> **2.854467721609558e+03**

Domingo

3x4 -> **2.526428312819275e+03**
4x3 -> 2.644000460930148e+03
 4x4 -> **2.427889937707692e+03**
 4x5 -> **2.279943580042075e+03**
 5x4 -> **2.233495128376459e+03**
 4x6 -> **2.252131932599698e+03**
 6x4 -> **2.200454955131736e+03**
 5x5 -> **2.143932438652845e+03**

Media sin Sábado ni Domingo

3x4 -> **4.886670405173063e+03**
 4x3 -> **4.658233838400537e+03**
 4x4 -> **4.332777340310146e+03**
 4x5 -> **4.165789744231060e+03**
 5x4 -> **4.085080548759139e+03**
 4x6 -> **4.005793261455661e+03**
6x4 -> 3.913311965054669e+03
 5x5 -> **3.946716900558395e+03**

Temperatura Baja

3x4 -> **4.991332107458287e+03**
4x3 -> **4.699261951384900e+03**
4x4 -> **4.430545669534807e+03**
4x5 -> **4.223967401294429e+03**
5x4 -> **4.168866573510381e+03**
4x6 -> **4.156703878713380e+03**
6x4 -> **4.010598833224723e+03**
5x5 -> **4.092926785012020e+03**

Temperatura Media

3x4 -> **4.150993788678666e+03**
4x3 -> **3.896651379533843e+03**
4x4 -> **3.754336934491218e+03**
4x5 -> **3.538080988185030e+03**
5x4 -> **3.535317908432072e+03**
4x6 -> **3.388120170838284e+03**
6x4 -> **3.355756028773342e+03**
5x5 -> **3.327568957672668e+03**

Temperatura Alta

3x4 -> **4.436027580183694e+03**
4x3 -> **4.245482403618736e+03**
4x4 -> **3.904115257552783e+03**
4x5 -> **3.820878643842303e+03**
5x4 -> **3.698828923959476e+03**
4x6 -> **3.614250957996957e+03**
6x4 -> **3.409696422187486e+03**
5x5 -> **3.574665146069205e+03**

Madrid

Lunes

3x4 -> **9.724826181942328e+03**
 4x3 -> **9.860840422442772e+03**
 4x4 -> **9.322900488804480e+03**
 4x5 -> **8.502898733324433e+03**
 5x4 -> **8.578394782530030e+03**
 4x6 -> **8.175368420461815e+03**
 6x4 -> **8.595135141622997e+03**
 5x5 -> **8.102647713503640e+03**

Martes

3x4 -> **9.831826583046495e+03**
 4x3 -> **9.881564769180726e+03**
 4x4 -> **9.802220097479607e+03**
 4x5 -> **8.593293120717672e+03**
 5x4 -> **8.742673337185837e+03**
 4x6 -> **8.611612243074518e+03**
 6x4 -> **8.849175305842960e+03**
 5x5 -> **8.544045665330140e+03**

Miércoles

3x4 -> **9.979891041683830e+03**
 4x3 -> **1.012420685466417e+04**
 4x4 -> **9.420689529035395e+03**
 4x5 -> **9.532059000345173e+03**
 5x4 -> **8.794139837121533e+03**
 4x6 -> **8.947069582896950e+03**
 6x4 -> **8.711022981885095e+03**
 5x5 -> **8.321583358498025e+03**

Jueves

3x4 -> **9.579172966358480e+03**
 4x3 -> **9.827513501278265e+03**
 4x4 -> **9.318927654316101e+03**
 4x5 -> **8.317407853251750e+03**
 5x4 -> **8.449743249434700e+03**
 4x6 -> **8.040649735399114e+03**
 6x4 -> **8.061327660665746e+03**
 5x5 -> **8.377762176072330e+03**

Viernes

3x4 -> **9.702439247323631e+03**
 4x3 -> **9.764506171297451e+03**
 4x4 -> **9.138184864495353e+03**
 4x5 -> **8.459093704345474e+03**
 5x4 -> **8.575494683290426e+03**
 4x6 -> **8.422551166600082e+03**
 6x4 -> **8.336511687366400e+03**
 5x5 -> **8.058875396428692e+03**

Sábado

3x4 -> **8.173442584763535e+03**
 4x3 -> **7.822211268368069e+03**
 4x4 -> **7.102220488485755e+03**
 4x5 -> **7.006365573954663e+03**
 5x4 -> **6.768135383296103e+03**
 4x6 -> **6.745023043259067e+03**
 6x4 -> **6.651422587995548e+03**
 5x5 -> **6.509679198076236e+03**

Domingo

3x4 -> **5.727609086982000e+03**

4x3 -> **5.605270213788392e+03**

4x4 -> **5.277585269449575e+03**

4x5 -> **5.053613068470053e+03**

5x4 -> **4.892999503773640e+03**

4x6 -> **4.901373167434194e+03**

6x4 -> **4.794702236068283e+03**

5x5 -> **4.791625335426150e+03**

Media sin Sábado ni Domingo

3x4 -> **9.763625335426150e+03**

4x3 -> **9.891799503773640e+03**

4x4 -> **9.400627021378839e+03**

4x5 -> **8.681035383296103e+03**

5x4 -> **8.628609086982001e+03**

4x6 -> **8.439564769180725e+03**

6x4 -> **8.510659000345173e+03**

5x5 -> **8.281083358498025e+03**

Temperatura Baja

3x4 -> **1.065546353574516e+04**

4x3 -> **1.085230991409436e+04**

4x4 -> **1.039259667177480e+04**

4x5 -> **9.755517584544260e+03**

5x4 -> **9.564170205790280e+03**

4x6 -> **9.558748000532040e+03**

6x4 -> **8.997998355172622e+03**

5x5 -> **9.229961937518923e+03**

Temperatura Media

3x4 -> **8.235343168526351e+03**

4x3 -> **8.118104901824546e+03**

4x4 -> **7.677023934138075e+03**

4x5 -> **7.154649048677768e+03**

5x4 -> **7.210806292871504e+03**

4x6 -> **6.915607378431820e+03**

6x4 -> **6.693799368052507e+03**

5x5 -> **6.601353457417287e+03**

Temperatura Alta

3x4 -> **8.884281692590013e+03**

4x3 -> **9.078135241641356e+03**

4x4 -> **8.436538157397605e+03**

4x5 -> **7.890088804547307e+03**

5x4 -> **7.832938516328387e+03**

4x6 -> **7.668270399546991e+03**

6x4 -> **7.389530704979631e+03**

5x5 -> **7.281616250547945e+03**

Cáceres

Lunes

3x4 -> **9.724561171688698e+03**
 4x3 -> **9.658596915347480e+03**
 4x4 -> **9.555185832442787e+03**
 4x5 -> **8.971926175621235e+03**
 5x4 -> **8.761027494169313e+03**
 4x6 -> **8.591609323928476e+03**
 6x4 -> **8.381150502241286e+03**
 5x5 -> **8.352040987692073e+03**

Martes

3x4 -> **9.769760666532024e+03**
 4x3 -> **9.805566018527104e+03**
 4x4 -> **9.259252742283616e+03**
 4x5 -> **8.878237023957480e+03**
 5x4 -> **8.776694759925418e+03**
 4x6 -> **8.641133309304680e+03**
 6x4 -> **8.299515577343070e+03**
 5x5 -> **8.273210174953088e+03**

Miércoles

3x4 -> **1.028330318057439e+04**
 4x3 -> **9.756004357019165e+03**
 4x4 -> **9.332144753831079e+03**
 4x5 -> **8.737354534818203e+03**
 5x4 -> **8.837928082914488e+03**
 4x6 -> **8.675822025427558e+03**
 6x4 -> **8.342166571848058e+03**
 5x5 -> **8.183071576648601e+03**

Jueves

3x4 -> **9.769339531419693e+03**
 4x3 -> **9.326377740278440e+03**
 4x4 -> **8.825971865251317e+03**
 4x5 -> **8.421550720381489e+03**
 5x4 -> **8.414703870227193e+03**
 4x6 -> **8.163747682768004e+03**
 6x4 -> **7.748077241576783e+03**
 5x5 -> **7.894244879796509e+03**

Viernes

3x4 -> **1.025269208685254e+04**
 4x3 -> **9.833594222904128e+03**
 4x4 -> **9.290629514814907e+03**
 4x5 -> **8.893162000458078e+03**
 5x4 -> **9.019748364937997e+03**
 4x6 -> **8.417515748157926e+03**
 6x4 -> **8.313523871301204e+03**
 5x5 -> **8.356875216117025e+03**

Sábado

3x4 -> **6.834060003945449e+03**
 4x3 -> **6.721752529116880e+03**
 4x4 -> **6.172829690087797e+03**
 4x5 -> **5.575005460084682e+03**
 5x4 -> **5.563636504865420e+03**
 4x6 -> **5.467791090874531e+03**
 6x4 -> **5.390050311278964e+03**
 5x5 -> **4.943391616653466e+03**

Domingo

3x4 -> **4.953926613804701e+03**

4x3 -> **4.604721971298921e+03**

4x4 -> **4.611247171862387e+03**

4x5 -> **4.033353769137555e+03**

5x4 -> **4.007894574149779e+03**

4x6 -> **3.766167787751316e+03**

6x4 -> **3.511945488627505e+03**

5x5 -> **3.588778282838457e+03**

Media sin Sábado ni Domingo

3x4 -> **9.959931327413467e+03**

4x3 -> **9.676027850815264e+03**

4x4 -> **9.252636941724740e+03**

4x5 -> **8.780446091047295e+03**

5x4 -> **8.762020514434882e+03**

4x6 -> **8.497965617917329e+03**

6x4 -> **8.216886752862081e+03**

5x5 -> **8.211888567041458e+03**

Temperatura Baja

3x4 -> **1.021928140042173e+04**

4x3 -> **9.820168572607532e+03**

4x4 -> **9.177213051109642e+03**

4x5 -> **8.838028884743357e+03**

5x4 -> **8.922529505404170e+03**

4x6 -> **8.483884535766163e+03**

6x4 -> 8.241123023601001e+03

5x5 -> **8.329576190174403e+03**

Temperatura Media

3x4 -> **8.226197289774704e+03**

4x3 -> **7.915283343912413e+03**

4x4 -> **7.427517448068847e+03**

4x5 -> **6.971408881241243e+03**

5x4 -> **6.903838316090001e+03**

4x6 -> **6.713344454122671e+03**

6x4 -> 6.591621404768838e+03

5x5 -> **6.580457737593499e+03**

Temperatura Alta

3x4 -> **9.041406915562397e+03**

4x3 -> **8.619915794644256e+03**

4x4 -> **8.229010943710031e+03**

4x5 -> **7.873442731354700e+03**

5x4 -> **7.791646548009290e+03**

4x6 -> **7.619945363600817e+03**

6x4 -> 7.277990311618373e+03

5x5 -> **7.343572396862155e+03**

La Coruña

Lunes

3x4 -> **4.914080948357944e+03**
 4x3 -> **4.764606619082509e+03**
 4x4 -> **4.231290282093966e+03**
 4x5 -> **4.051977374889778e+03**
 5x4 -> **3.873528023061836e+03**
 4x6 -> **3.696490069957523e+03**
 6x4 -> **3.597635958007724e+03**
 5x5 -> **3.728761122285756e+03**

Martes

3x4 -> **4.735473899678338e+03**
 4x3 -> **4.635301507114021e+03**
 4x4 -> **4.395751855626823e+03**
 4x5 -> **3.976658333230247e+03**
 5x4 -> **3.828684415330841e+03**
 4x6 -> **3.619384715536943e+03**
 6x4 -> **3.756579220378912e+03**
 5x5 -> **3.634071315834824e+03**

Miércoles

3x4 -> **4.726715926536805e+03**
 4x3 -> **4.614776695296318e+03**
 4x4 -> **4.194007212979140e+03**
 4x5 -> **3.949090792902385e+03**
 5x4 -> **3.813352830261980e+03**
 4x6 -> **3.534030277158483e+03**
 6x4 -> **3.543079229658450e+03**
 5x5 -> **3.649131315198215e+03**

Jueves

3x4 -> **4.747978559091564e+03**
 4x3 -> **4.703732910874086e+03**
 4x4 -> **4.368873631817633e+03**
 4x5 -> **4.013441307873669e+03**
 5x4 -> **3.902118384318103e+03**
 4x6 -> **3.742009672861294e+03**
 6x4 -> **3.727015016141812e+03**
 5x5 -> **3.625132108253179e+03**

Viernes

3x4 -> **4.874037991704348e+03**
 4x3 -> **4.654759941309612e+03**
 4x4 -> **4.420616873579878e+03**
 4x5 -> **3.998465191605068e+03**
 5x4 -> **3.963778770114020e+03**
 4x6 -> **3.635077818230877e+03**
 6x4 -> **3.709039669226951e+03**
 5x5 -> **3.638217962196981e+03**

Sábado

3x4 -> **4.624758642691568e+03**
 4x3 -> **4.381062744381654e+03**
 4x4 -> **4.086594196976444e+03**
 4x5 -> **3.701748123365910e+03**
 5x4 -> **3.667826196353395e+03**
 4x6 -> **3.511215673188351e+03**
 6x4 -> **3.437689602394550e+03**
 5x5 -> **3.412292204261261e+03**

Domingo

3x4 -> **4.193**701353474547e+03

4x3 -> **4.037**864855372105e+03

4x4 -> **3.674**610011421107e+03

4x5 -> **3.352**283485812975e+03

5x4 -> **3.400**223678786591e+03

4x6 -> **3.001**598420708447e+03

6x4 -> **3.209**432332749320e+03

5x5 -> **2.930**995639644731e+03

Media sin Sábado ni Domingo

3x4 -> **4.799**657465073799e+03

4x3 -> **4.674**635534735309e+03

4x4 -> **4.322**107971219489e+03

4x5 -> **3.997**926600100230e+03

5x4 -> **3.876**292484617356e+03

4x6 -> **3.645**398510749024e+03

6x4 -> **3.666**669818682770e+03

5x5 -> **3.655**062764753790e+03

Temperatura Baja

3x4 -> **3.933896599812788e+03**

4x3 -> **3.901929495154568e+03**

4x4 -> **3.866266641054895e+03**

4x5 -> **3.372502724247865e+03**

5x4 -> **3.341072656053487e+03**

4x6 -> **3.080012530115977e+03**

6x4 -> **3.155234853935991e+03**

5x5 -> **3.145097920685000e+03**

Temperatura Media

3x4 -> **4.963786507307881e+03**

4x3 -> **4.790198084481281e+03**

4x4 -> **4.541146526139300e+03**

4x5 -> **4.139692770449170e+03**

5x4 -> **3.986246088978309e+03**

4x6 -> **3.797194958556644e+03**

6x4 -> **3.831586475285978e+03**

5x5 -> **3.780027375743217e+03**

Temperatura Alta

3x4 -> **4.292759518825590e+03**

4x3 -> **4.251740148370227e+03**

4x4 -> **3.613993713051073e+03**

4x5 -> **3.216843516644051e+03**

5x4 -> **3.488251923961087e+03**

4x6 -> **2.736626787857095e+03**

6x4 -> **2.754901911455223e+03**

5x5 -> **2.578737287313691e+03**

Málaga

Lunes

3x4 -> **5.524**521011723195e+03
 4x3 -> **5.201**217228369970e+03
 4x4 -> **4.866**141833883205e+03
 4x5 -> **4.540**322466223280e+03
 5x4 -> **4.554**528714487124e+03
 4x6 -> **4.269**134139251882e+03
 6x4 -> **4.279**577520241125e+03
 5x5 -> **4.175**374161012090e+03

Martes

3x4 -> **5.535**025291006755e+03
 4x3 -> **5.069**259871947652e+03
 4x4 -> **4.747**742109749902e+03
 4x5 -> **4.408**747943377586e+03
 5x4 -> **4.427**070585850726e+03
 4x6 -> **4.069**248157085502e+03
 6x4 -> **4.162**530387839165e+03
 5x5 -> **4.003**061893499543e+03

Miércoles

3x4 -> **5.643**561494075328e+03
 4x3 -> **5.229**615519048980e+03
 4x4 -> **4.865**507851846583e+03
 4x5 -> **4.555**607080198147e+03
 5x4 -> **4.577**234929362830e+03
 4x6 -> **4.253**391841631706e+03
 6x4 -> **4.297**160436229004e+03
 5x5 -> **4.268**123433011673e+03

Jueves

3x4 -> **5.538**066697540658e+03
 4x3 -> **5.458**696471126856e+03
 4x4 -> **4.776**123682011895e+03
 4x5 -> **4.603**106049410191e+03
 5x4 -> **4.519**634823949688e+03
 4x6 -> **4.219**046354545361e+03
 6x4 -> **4.318**995913420230e+03
 5x5 -> **4.142**208529501984e+03

Viernes

3x4 -> **5.447**888808836856e+03
 4x3 -> **5.146**599915504107e+03
 4x4 -> **4.795**063184405721e+03
 4x5 -> **4.481**207052416255e+03
 5x4 -> **4.434**137706315875e+03
 4x6 -> **4.088**144949770826e+03
 6x4 -> **4.266**973020147402e+03
 5x5 -> **4.071**642327825715e+03

Sábado

3x4 -> **4.213**169609713436e+03
 4x3 -> **3.990**589981932264e+03
 4x4 -> **3.699**393950510186e+03
 4x5 -> **3.590**171130139954e+03
 5x4 -> **3.474**721000463603e+03
 4x6 -> **3.374**545294771540e+03
 6x4 -> **3.342**990836332714e+03
 5x5 -> **3.202**493648514676e+03

Domingo

3x4 -> **3.545416511272303e+03**

4x3 -> **3.391468461755308e+03**

4x4 -> **3.205635960171035e+03**

4x5 -> **2.984735726827927e+03**

5x4 -> **2.974948607114318e+03**

4x6 -> **2.823387695382776e+03**

6x4 -> **2.863506155436739e+03**

5x5 -> **2.827737194131387e+03**

Media sin Sábado ni Domingo

3x4 -> **5.537812660636558e+03**

4x3 -> **5.221077801199513e+03**

4x4 -> **4.810115732379461e+03**

4x5 -> **4.517798118325092e+03**

5x4 -> **4.502521351993249e+03**

4x6 -> **4.179793088457055e+03**

6x4 -> **4.265047455575384e+03**

5x5 -> **4.132082068970201e+03**

Temperatura Baja

3x4 -> **4.969**434826508484e+03

4x3 -> **4.796**751681134590e+03

4x4 -> **4.527**837036578209e+03

4x5 -> **4.253**639009254556e+03

5x4 -> **4.205**457024446203e+03

4x6 -> **3.958**101410601847e+03

6x4 -> **4.081**889545263754e+03

5x5 -> **3.959**452092696470e+03

Temperatura Media

3x4 -> **4.753**727957752034e+03

4x3 -> **4.611**905029512198e+03

4x4 -> **4.384**425612061255e+03

4x5 -> **4.086**940362259149e+03

5x4 -> **4.124**398001577235e+03

4x6 -> **3.791**427969404494e+03

6x4 -> **3.736**331449142726e+03

5x5 -> **3.744**732765505333e+03

Temperatura Alta

3x4 -> **5.083**741866422674e+03

4x3 -> **4.777**162016350359e+03

4x4 -> **4.302**818972291048e+03

4x5 -> **4.006**367680552943e+03

5x4 -> **4.034**716489732113e+03

4x6 -> **3.758**273668078131e+03

6x4 -> **3.866**601690239259e+03

5x5 -> **3.798**590433294115e+03

Valencia

Lunes

3x4 -> **1.124588908878093e+04**
 4x3 -> **1.133787275410266e+04**
 4x4 -> **1.009462214535110e+04**
 4x5 -> **9.561350037632596e+03**
 5x4 -> **9.264964259482322e+03**
 4x6 -> **8.965146198926688e+03**
 6x4 -> **8.554616083400050e+03**
 5x5 -> **8.669650348939707e+03**

Martes

3x4 -> **1.356159775917795e+04**
 4x3 -> **1.141792482120738e+04**
 4x4 -> **1.045528398238579e+04**
 4x5 -> **9.748638599961785e+03**
 5x4 -> **9.433004347476510e+03**
 4x6 -> **9.152865109661561e+03**
 6x4 -> **8.763117832077158e+03**
 5x5 -> **8.909214385175892e+03**

Miércoles

3x4 -> **1.369975383016989e+04**
 4x3 -> **1.182964779931570e+04**
 4x4 -> **1.054247383969093e+04**
 4x5 -> **9.728530928490052e+03**
 5x4 -> **9.670909210757936e+03**
 4x6 -> **9.380370269163363e+03**
 6x4 -> **8.941475396813461e+03**
 5x5 -> **9.023928268361633e+03**

Jueves

3x4 -> **1.174042902771763e+04**
 4x3 -> **1.091247065509644e+04**
 4x4 -> **1.001989757742373e+04**
 4x5 -> **9.176185392297777e+03**
 5x4 -> **9.130872472453884e+03**
 4x6 -> **8.697047449379734e+03**
 6x4 -> **8.381387959428643e+03**
 5x5 -> **8.471832049896300e+03**

Viernes

3x4 -> **1.266610528392691e+04**
 4x3 -> **1.210616821953981e+04**
 4x4 -> **1.070904076526979e+04**
 4x5 -> **9.705994866879028e+03**
 5x4 -> **9.805390046764916e+03**
 4x6 -> **9.233429941318704e+03**
 6x4 -> **8.860250631561485e+03**
 5x5 -> **8.990522202987533e+03**

Sábado

3x4 -> **1.012413192034024e+04**
 4x3 -> **9.388201841260401e+03**
 4x4 -> **8.462260224081589e+03**
 4x5 -> **7.368130319205242e+03**
 5x4 -> **7.051840045001850e+03**
 4x6 -> **6.794131936220682e+03**
 6x4 -> **6.505363811958630e+03**
 5x5 -> **6.659698242170551e+03**

Domingo

3x4 -> **5.476625138450908e+03**

4x3 -> **5.656176083871415e+03**

4x4 -> **4.739600073206098e+03**

4x5 -> **4.120797463124982e+03**

5x4 -> **3.929029244766426e+03**

4x6 -> **3.946842565661581e+03**

6x4 -> **3.644541558721911e+03**

5x5 -> **4.015178900293608e+03**

Media sin Sábado ni Domingo

3x4 -> **1.258275499795466e+04**

4x3 -> **1.152081684985240e+04**

4x4 -> **1.036426366202427e+04**

4x5 -> **9.584139965052247e+03**

5x4 -> **9.461028067387113e+03**

4x6 -> **9.085771793690010e+03**

6x4 -> **8.700169580656158e+03**

5x5 -> **8.813029451072212e+03**

Temperatura Baja

3x4 -> **1.106446871880986e+04**
4x3 -> **1.064092281856412e+04**
4x4 -> **9.572878312101393e+03**
4x5 -> **8.832101166697887e+03**
5x4 -> **8.456460206016998e+03**
4x6 -> **8.278611828295168e+03**
6x4 -> **8.241233433177884e+03**
5x5 -> **8.039793362476732e+03**

Temperatura Media

3x4 -> **1.075778775682307e+04**
4x3 -> **9.765498904645076e+03**
4x4 -> **9.018758039577217e+03**
4x5 -> **8.319757226458238e+03**
5x4 -> **7.777134751324266e+03**
4x6 -> **7.460325734335520e+03**
6x4 -> **7.393418413525582e+03**
5x5 -> **7.238269698512740e+03**

Temperatura Alta

3x4 -> **1.279064133723075e+04**
4x3 -> **1.130859149462622e+04**
4x4 -> **1.041483890141654e+04**
4x5 -> **1.001898623740558e+04**
5x4 -> **9.283028232888608e+03**
4x6 -> **8.710656372934258e+03**
6x4 -> **8.548684841702341e+03**
5x5 -> **8.520843152252753e+03**

Todos

Lunes

3x4 -> **9.296**138086016260e+03
 4x3 -> **9.386**811150546030e+03
 4x4 -> **9.032**982281130384e+03
 4x5 -> **8.586**418487543808e+03
 5x4 -> **8.200**034672598880e+03
 4x6 -> **8.344**56808721305e+03
 6x4 -> **8.134**261310879334e+03
 5x5 -> **7.726**381599303186e+03

Martes

3x4 -> **9.786**916253795085e+03
 4x3 -> **9.696**677748652759e+03
 4x4 -> **9.135**672185104917e+03
 4x5 -> **8.297**009821191918e+03
 5x4 -> **8.325**683720615365e+03
 4x6 -> **8.199**049190268346e+03
 6x4 -> **7.892**719694648139e+03
 5x5 -> **8.163**019598972956e+03

Miércoles

3x4 -> **9.504**486106458560e+03
 4x3 -> **9.597**813157604905e+03
 4x4 -> **8.897**874883437230e+03
 4x5 -> **8.751**443914968808e+03
 5x4 -> **8.571**744601125072e+03
 4x6 -> **8.525**941888593621e+03
 6x4 -> **8.018**897820972216e+03
 5x5 -> **7.988**083252664335e+03

Jueves

3x4 -> **9.077**159180725260e+03
 4x3 -> **9.174**401054483396e+03
 4x4 -> **8.925**309106624405e+03
 4x5 -> **8.633**211305823233e+03
 5x4 -> **8.071**375578589383e+03
 4x6 -> **8.020**466002039570e+03
 6x4 -> **7.905**027370163794e+03
 5x5 -> **7.732**645925180274e+03

Viernes

3x4 -> **9.723**404637112644e+03
 4x3 -> **9.529**263396841532e+03
 4x4 -> **8.652**116105855901e+03
 4x5 -> **8.526**023672578962e+03
 5x4 -> **8.316**770386557420e+03
 4x6 -> **8.261**815197652077e+03
 6x4 -> **7.830**844124156092e+03
 5x5 -> **7.980**222251662245e+03

Sábado

3x4 -> **7.735**531132374900e+03
 4x3 -> **7.501**880804504120e+03
 4x4 -> **6.672**971965207022e+03
 4x5 -> **6.316**617001736277e+03
 5x4 -> **6.463**342998052296e+03
 4x6 -> **6.458**539313345878e+03
 6x4 -> **6.244**643161494376e+03
 5x5 -> **5.967**675393261532e+03

Domingo

3x4 -> **5.510379971552567e+03**

4x3 -> **5.435708133590130e+03**

4x4 -> **5.020645604845957e+03**

4x5 -> **4.949810601077893e+03**

5x4 -> **4.712085201025911e+03**

4x6 -> **4.651872043886009e+03**

6x4 -> **4.497317370463514e+03**

5x5 -> **4.484477738969164e+03**

Media sin Sábado ni Domingo

3x4 -> **9.477620852821561e+03**

4x3 -> **9.476993301625724e+03**

4x4 -> **8.928790912430568e+03**

4x5 -> **8.558821440421345e+03**

5x4 -> **8.297121791897223e+03**

4x6 -> **8.270345817454983e+03**

6x4 -> **7.956350064163916e+03**

5x5 -> **7.918070525556599e+03**

Temperatura Baja

3x4 -> **9.643384315475600e+03**
4x3 -> **9.787521210547848e+03**
4x4 -> **9.054008812963700e+03**
4x5 -> **8.776032186778868e+03**
5x4 -> **8.578677965087798e+03**
4x6 -> **8.611952708799060e+03**
6x4 -> **8.094857020350086e+03**
5x5 -> **8.798382917844841e+03**

Temperatura Media

3x4 -> **7.707060469389981e+03**
4x3 -> **7.828060402938444e+03**
4x4 -> **7.386377042013276e+03**
4x5 -> **7.182943277677666e+03**
5x4 -> **6.958899382605697e+03**
4x6 -> **6.964313492032159e+03**
6x4 -> **6.580081766514536e+03**
5x5 -> **6.663348593585287e+03**

Temperatura Alta

3x4 -> **9.448092558343502e+03**
4x3 -> **9.004091121223728e+03**
4x4 -> **8.500366946425260e+03**
4x5 -> **7.585622559575121e+03**
5x4 -> **7.961350381277186e+03**
4x6 -> **7.844991299844633e+03**
6x4 -> **7.484179190673222e+03**
5x5 -> **7.147063241914696e+03**


ANEXO C – PATRONES DE CONSUMO ELÉCTRICO

En este anexo se muestran los resultados del entrenamiento de los modelos propios de cada una de las tablas. Para entender de donde vienen, se recomienda la lectura del [capítulo](#) que lo explica, y para observar las información extraída de estos resultados, se recomienda la lectura del [capítulo](#) donde se analizan.



Barcelona

Lunes


som_patterns



ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Martes


som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Miércoles



som_patterns



Hits





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO





Jueves

som_patterns





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO





Viernes

som_patterns




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Sábado



SOM_patterns



Hits





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Domingo

SOM_patterns




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura alta



som_patterns



Hits





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO





Temperatura media

SOM_patterns




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura baja



som_patterns



Hits





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Madrid

Lunes

som_patterns





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO





Martes

som_patterns




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Miércoles


som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Jueves



som_patterns



Hits





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO





Viernes

som_patterns





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Sábado

SOM_patterns




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Domingo



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura alta



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura media



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura baja


som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Cáceres

Lunes


som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Martes



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Miércoles


som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Jueves

SOM_patterns




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO


som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Viernes



som_patterns



Hits





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Sábado

SOM_patterns





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Domingo

SOM_patterns





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO





Temperatura alta

SOM_patterns




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura media



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura baja



som_patterns



Hits





ANEXO C – PATRONES DE CONSUMO ELÉCTRICO





La Coruña

Lunes

SOM_patterns




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Martes


SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Miércoles


SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Jueves


SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Viernes


SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Sábado


SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Domingo


SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura alta



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura media



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura baja



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Málaga

Lunes



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Martes



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Miércoles



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Jueves



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Viernes



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Sábado



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Domingo



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura alta


som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura media



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura baja


som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Valencia

Lunes



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Martes



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Miércoles



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Jueves



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Viernes



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Sábado



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Domingo



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura alta



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura media



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura baja



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Todos

Lunes



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Martes



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Miércoles



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Jueves



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Viernes



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Sábado



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Domingo



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura alta



som_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura media



SOM_patterns



Hits




ANEXO C – PATRONES DE CONSUMO ELÉCTRICO




Temperatura baja

SOM_patterns



Hits



ANEXO C – PATRONES DE CONSUMO ELÉCTRICO

