



**Universidad
Zaragoza**

Trabajo Fin de Máster

Desarrollo de un método estadístico de previsión
de demandas domésticas.

Development of a statistical method of forecasting
domestic demands.

Autor/es

Mario Gutiérrez Martínez

Director/es

José Francisco Sanz Osorio

Escuela de Ingeniería y Arquitectura
2018



DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD

(Este documento debe acompañar al Trabajo Fin de Grado (TFG)/Trabajo Fin de Máster (TFM) cuando sea depositado para su evaluación).

D./D^a. Mario Gutiérrez Martínez,

con nº de DNI 32888996p en aplicación de lo dispuesto en el art.

14 (Derechos de autor) del Acuerdo de 11 de septiembre de 2014, del Consejo de Gobierno, por el que se aprueba el Reglamento de los TFG y TFM de la Universidad de Zaragoza,

Declaro que el presente Trabajo de Fin de (Grado/Máster) Máster, (Título del Trabajo)

Desarrollo de un método estadístico de previsión de demandas domésticas

es de mi autoría y es original, no habiéndose utilizado fuente sin ser citada debidamente.

Zaragoza, 12 de Julio de 2016

Fdo: 

Desarrollo de un método estadístico de previsión de demandas domésticas

Resumen

El objetivo de este Trabajo Fin de Máster es desarrollar el método estadístico que mejor combine precisión, sencillez, rapidez de ejecución, poca necesidad de información y robustez para la previsión de demandas domésticas a partir de los métodos existentes en la bibliografía. Es muy importante alcanzar una buena combinación de los factores mencionados ya que el método elegido se implementará en un demostrador real como se verá más adelante. Métodos muy precisos pero lentos o poco robustos no serían útiles para esta aplicación.

Ante la disyuntiva de que método estadístico es el más conveniente para la determinación de previsión de cargas, se realiza este estudio con el cual se plantea un método para la previsión, así como establecer lo positivo que es el conocimiento anticipado de la demanda energética. El primer beneficio proporcionado por la previsión de demandas gracias al concepto de Smart Grid consiste en la reducción de la energía a producir por parte de los sistemas de generación de cada país. Esto se debe a que se tendrá un mayor control sobre las necesidades energéticas. Dichas previsiones de demanda pueden ser gestionables, es decir, permiten ser ajustadas a los momentos más convenientes siendo ejemplo de ello dentro de una vivienda, cargas como la lavadora, lavavajillas o secadora. También pueden ser no gestionables, como son el caso de ciertas demandas donde la necesidad marca su momento de uso, aplicando el mismo ejemplo que en el caso anterior, para una vivienda sería el calefactor o microondas. Además, también pueden tratarse de previsiones de demanda individuales, como en el caso de un único “cliente”(demandante de previsión de cargas), o bien colectivas agrupando en ello por ejemplo a un bloque de edificio o una urbanización o pueblo, es decir, un conjunto de demandantes individuales agrupados de forma que sean vistos como una única carga.

No obstante, la variedad de “clientes” existentes, ya sean industrias, comercios, hogares, centros comerciales, etc. Hace que cada uno de ellos tenga que ser tratado de forma individual a excepción del caso de las viviendas donde su previsión de carga puede ser más general. En otros ejemplos como comercios o industrias se pueden gestionar en algunos de ellos mediante el arranque escalonado de sus equipos para evitar así picos de potencia excesivos pero no pudiendo ser gestionados a ciertos horarios como en el caso de las viviendas.

La orientación de este Trabajo Fin de Máster es tratar de atender la necesidad de determinar el método más adecuado para la previsión de demandas energéticas. Para lo cual, en la primera fase de este trabajo se ha realizado un estudio y análisis bibliográfico de la metodología empleada hasta el momento, aplicándola como punto de partida para la determinación del método más conveniente en la previsión de demandas principalmente en el sector doméstico.

Obteniéndose como resultado final tras el estudio realizado que con métodos sencillos pero precisos se hayan unos valores semejantes a los obtenidos con el empleo de métodos más complejos como son el de las redes neuronales, ya que los más simples no se ven influenciados por aspectos externos como el tiempo, la humedad o temperatura.

INDICE

1.	Introducción.....	8
1.1	Importancia del módulo de predicción de demanda.....	24
1.2	Metodología de trabajo.....	26
1.3	Métodos de previsión estudiados.....	28
1.3.1	Método de regresión lineal múltiple	28
1.3.2	Modelo de búsqueda de coeficientes	29
1.3.3	Métodos “top-down” y “bottom up”.....	30
1.3.4	Métodos basados en redes neuronales	31
1.3.5	Métodos de regresión.....	31
1.3.6	Modelos autorregresivos de media móvil.....	32
2.	Conclusión en la elección de metodologías.....	32
3.	Resultados.....	33
3.1	Modelo de búsqueda de coeficientes	33
3.2	Método del día similar	35
3.3	Método AR	38
3.4	Método ARMA	45
4.	Conclusiones.....	52
5.	Trabajos futuros.....	53
6.	Referencias	54
7.	Anexo I. Código de métodos de predicción	58
8.	Anexo II. Código del programa de cargas programables	77
9.	Anexo III. Metodologías para la recuperación de datos.....	81
10.	Anexo IV. Cálculo del error	84

INDICE FIGURAS

Figura 1: Evolución de la población mundial [1]	8
Figura 2: Perspectivas de crecimiento de la demanda mundial de energía primaria. [2].	9
Figura 3: Demanda eléctrica en España [3].....	9
Figura 4: Smart Grid[8]	12
Figura 5: Curva de potencia máxima 5,75 kW	16
Figura 6: Curva de potencia máxima 4,6 kW tras realización de gestión de cargas	17
Figura 7: Relación de ahorro económico con reducción de potencia[20]	17
Figura 8: Curva de precios PVPV del mercado diario del 06/09/2017	18
Figura 9: Curva de cargas en periodo tarde/noche conjunta a la de precios horarios	19
Figura 10: Curva de cargas en periodo intermedio con la de precios.....	20
Figura 11: Curva de cargas para la madrugada con la curva de precios	21
Figura 12: Gestión de cargas.[22].....	23
Figura 13: Esquema de la herramienta de optimización de consumo eléctrico.....	25
Figura 14: Planificación del día siguiente de almacenamiento y generación.....	26
Figura 15: Tabla Excel para introducir el patrón de consumo diario, potencia de cada elemento y desviaciones típicas de uso y hora de encendido	27
Figura 16: Predicciones en función de la semana empleada en el método de coeficientes	34
Figura 17: Errores generados en el método de coeficientes	34
Figura 18: Predicción con el método del día similar	35
Figura 19: Error generado con el método del día similar	36
Figura 20: Predicciones para los contadores individuales.....	37
Figura 21: Error generado para cada contador	37
Figura 22: Predicción estacional comparada con su demanda para el método AR.....	39
Figura 23: Error estacional par el método AR.....	39
Figura 24: Predicción estocástica comparada con su demanda para el método AR.....	40
Figura 25: Error estocástico para el método AR	40
Figura 26: Error global para el método AR.....	41

Figura 27: Demanda y predicción estacional para datos de contadores individuales	42
Figura 28: Error estacional generado para datos de contadores individuales.....	42
Figura 29: Demanda y predicción estocástica para los contadores individuales.....	43
Figura 30: Error estocástico generado para los contadores individuales.....	44
Figura 31: Error global para los contadores individuales.....	45
Figura 32: Predicción estacional para el método ARMA.....	46
Figura 33: Error estacional con el método ARMA	46
Figura 34: Predicción estocástica para el método ARMA	47
Figura 35: Error estocástico generado para el método ARMA	47
Figura 36: Error general obtenido para el método ARMA.....	48
Figura 37: Demanda y predicción estacional para los contadores individuales	49
Figura 38: Error estacional para los contadores individuales.....	49
Figura 39: Demanda y predicción estocástica para los contadores individuales.....	50
Figura 40: Error estocástica para los contadores individuales	51
Figura 41: Error total para los contadores individuales.....	52

INDICE TABLAS

Tabla 1: Gasto económico para el período tarde/noche	20
Tabla 2: Gasto económico para el período intermedio.....	21
Tabla 3: Gasto económico para el período de madrugada.....	22
Tabla 4: Error normalizado con el método de coeficientes	35
Tabla 5: Error normalizado con el método del día similar	36
Tabla 6: Error normalizado para cada contador	38
Tabla 7: Error normalizado estacional para método AR	39
Tabla 8: Error normalizado estocástico para el método AR.....	41
Tabla 9: Error normalizado total para el método AR	41
Tabla 10: Error normalizado estacional para los contadores individuales	43
Tabla 11: Error normalizado estocástico para los contadores individuales.....	44
Tabla 12: Error normalizado total para los contadores individuales	45
Tabla 13: Error normalizado estacional con el método ARMA	46
Tabla 14: Error normalizado estocástico para el método ARMA	48
Tabla 16: Error normalizado estacional para los contadores individuales	50
Tabla 17: Error normalizado estocástico para los contadores individuales.....	51
Tabla 18: Error normalizado total de los contadores individuales	52
Tabla 19: Conclusión de errores generados.....	53

1. Introducción

El actual crecimiento de la población (Figura 1) y la mayor dependencia de dispositivos que requieren energía eléctrica para su funcionamiento están provocando un aumento de la demanda energética por parte de los consumidores, lo que provoca a su vez la necesidad de una mayor generación eléctrica por parte de las centrales de generación (Figura 2). Ante este problema, la previsión de demanda se presenta como una solución adecuada para proveer las futuras necesidades energéticas y así poder modificar la generación de energía por parte de los sistemas de producción. De forma que se puedan satisfacer las necesidades con la menor inversión en generación posible.

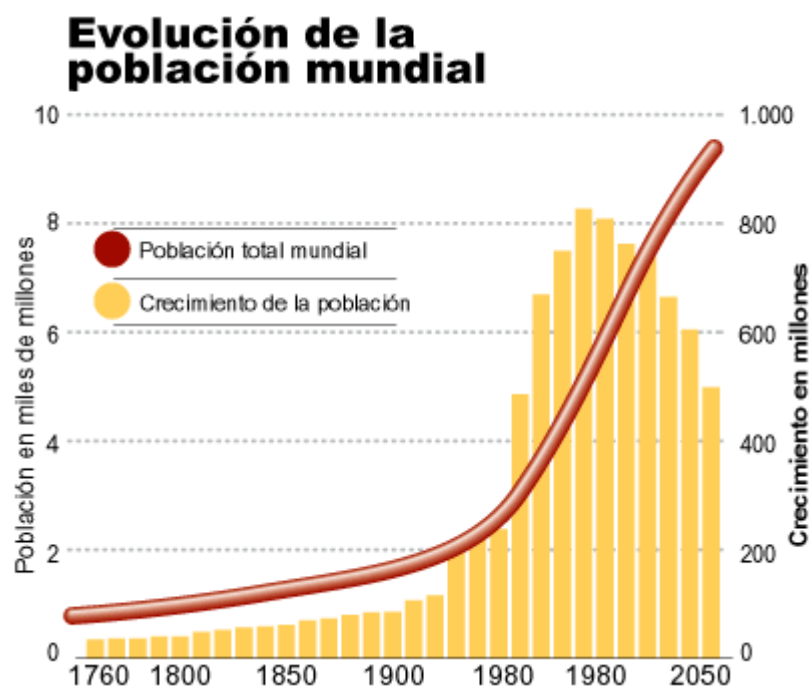


Figura 1: Evolución de la población mundial [1]




Figura 2: Perspectivas de crecimiento de la demanda mundial de energía primaria. [2]

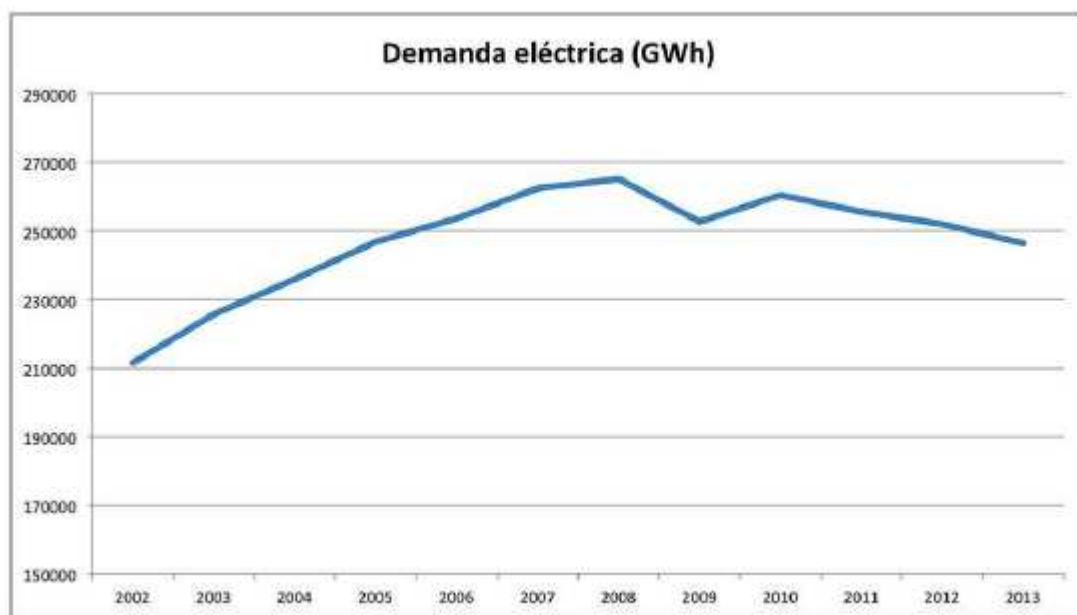


Figura 3: Demanda eléctrica en España [3]

La demanda eléctrica en España (ver Figura 3) se ha visto reducida debido en gran parte a las crisis económica, cortando así la trayectoria ascendente de consumo. No obstante, la demanda de energía eléctrica también está sujeta a otras influencias como son la estacionalidad y periodicidades. El consumo de electricidad variara por lo tanto con la estación del año y la hora del día. En referencia a la estación del año, se consume más

electricidad durante el invierno y el verano que en la primavera o el otoño, estaciones estas últimas en los que el clima es más moderado.

La relación entre el consumo de energía y la temperatura exterior ya ha sido expuesta con detalle en otros trabajos y entre ellas destacan:

- a) La tendencia, relacionada con factores socioeconómicos;
- b) Un fuerte componente estacional de período semanal;
- c) El efecto de las alteraciones en las condiciones de laboralidad, festivos, vacaciones, huelgas, etc., que distorsionan el patrón normal de comportamiento dentro de la semana.
- d) La contribución de las condiciones meteorológicas, entre las que destaca la temperatura.

Se observa también un componente estacional de período anual que no requiere modelización explícita, pues queda explicado por los períodos de fiestas y las variables meteorológicas.[4][5]

Los sistemas de energía eléctrica están pasando por una revolución debido a la creciente demanda de energía en todo el mundo. El desarrollo de la presión política y la conciencia de la población en la reducción de emisiones de carbono, incorporando la penetración de la energía renovable de forma mundial y la mezcla de tecnologías de información y comunicación con la forma de funcionamiento del sistema de energía han hecho que el concepto de Smart Grid entre a escena. Debido en parte a esta idea creada, ya que permite que se realice un seguimiento de la energía demandada gracias a la incorporación de la tecnología para así generar la energía necesaria, es decir, saber lo que se necesita para cubrir esa necesidad[6][7].El cambio de la redes actuales, las cuales se encuentran cada vez más al límite de su estabilidad, en redes inteligentes que garanticen la eficiente entrega de energía eléctrica evitando cortes energéticos requerirá una infraestructura de red de comunicaciones robusta y escalable que facilitará el flujo

bidireccional de electricidad, una administración avanzada de la carga, un mecanismo de protección auto-sanador y capacidades elevadas de monitoreo para hacer que el sistema de energía sea más eficiente y confiable[8]. Además, las Smart Grid favorece la innovación, el desarrollo de nuevos servicios o nuevas ideas permitiendo el crecimiento económico de la zona, en conclusión, ayudará a la evolución de las ciudades. Este concepto es aplicable desde un pequeño pueblo a una gran ciudad y a su vez tenerlos entre si comunicados para favorecer el intercambio de energía dentro del mismo pueblo o con la gran ciudad (Figura 4). Con el empleo de este sistema se dispondrá de una mejor gestión siendo esta más eficiente ya que se optimiza la producción y la distribución de ésta generación con el objetivo de mayor equilibrio entre la oferta y demanda de productores y compradores. Además, se podrá mejorar la eficiencia energética de la sociedad, conocer nuestro gasto en tiempo real, controlar la potencia en función de señales económicas o técnicas, contratar las tarifas que mejor encajen en cada vivienda y participar como productores en el mercado eléctrico.




Figura 4: Smart Grid[9]

Las principales características que engloban las Smart Grid son las siguientes[10]:

- Automatización.
- Inteligencia y control.
- Autoajuste.
- Participación del consumidor y generación distribuida.
- Resistente ante ataques.
- Gestión de la demanda.
- Calidad eléctrica.
- Vehículos eléctricos.
- Capacidad para todas las opciones de generación y almacenamiento.
- Optimización del transporte eléctrico.

- Preparación de mercados.
- Optimización de bienes y funcionamiento eficiente.
- Es flexible y adaptable a las necesidades cambiantes del sistema.

Las Smart Grid como ya se ha comentado suponen un cambio entre los clientes (consumidores y generadores) y los operadores de red en cuanto a la relación entre ellos. Es necesaria la incorporación masiva de las tecnologías de información y comunicación además de la automatización de la propia red y de los equipos productores y consumidores para que se produzca este cambio de relación.[11]

Las redes inteligentes o Smart Grid tienen la capacidad de ser más flexibles, seguras, robustas y fiables que las tradicionales. Además, permiten dar respuesta a la integración de las renovables, a la generación distribuida, a la integración del vehículo eléctrico y a la gestión de la demanda. Estas redes inteligentes permiten un conocimiento en mayor profundidad del estado del sistema eléctrico, ya que captan y procesan grandes cantidades de datos para tener un control del flujo eléctrico que circula en ambos sentidos.[12]

Para que el cliente tome un papel activo en cuanto a la gestión de su propia electricidad, se requiere establecer un sistema de suministro que de forma automática permita responder en tiempo real a las necesidades de operadores, suministradores y consumidores. En conclusión, se trata de redes más descentralizadas con la capacidad de integrar modelos nuevos en cuanto a generación energética y almacenamiento de energía.[13] Estos hogares inteligentes, tienen que ser percibidos por el usuario de forma claramente beneficiosa comparándolo con los riesgos que puedan tener para así fomentar la participación en este nuevo sistemas por parte del cliente, algunos de los riesgos que siente el cliente son su pérdida de autonomía, la pérdida de control en su propio hogar a favor de la tecnología o la no privacidad de sus datos. Todos estos factores pueden hacer a ciertos usuarios reacios a la idea de Smart Grid por lo que los encargados de la publicidad de este sistema deben resaltar la buena seguridad existente [14].

Este nuevo modelo eléctrico permite que se produzcan grupos de generación más cercanos a los consumidores y que estos sean también más pequeños con los que se logra en los flujos energéticos una mejoría importante. A diferencia del modelo tradicional, donde la generación de electricidad se produce muy alejada de los consumidores ya que esta se genera en los grandes centros de energía[13]. Además, otro elemento que entrará a escena con el nuevo modelo y que tendrá una suma importancia son las baterías que permitirán disponer de un almacenamiento de energía para cuando sea necesaria y a la vez evitará parar durante la generación de energía por parte de los grupos de generación distribuida cuando no sea necesaria más energía de la que se consume pudiendo así almacenarla para un futuro [7].

El demandante de energía no será consciente de todas las ventajas que supone el empleo de las Smart Grid ya que este, cuando tenga la necesidad de energía se le será suministrada sin saber si la energía que acaba de usar proviene de la generación de su vecino o de la generación de un bloque de oficinas en otra ciudad, así como si la energía requerida ha sido generada por una fuente renovable integrada en este sistema o generada a través de una central convencional. En cambio, el mayor beneficio del empleo de la Smart Grid será por parte de la red eléctrica puesto que esta se encontrará menos sobrecargada en los momentos pico del día. Con este nuevo sistema sí que existirá una participación más activa por parte del cliente que con el modelo tradicional, mediante la gestión de la demanda, que es la planificación e implementación de medidas destinadas a influir en el modo de consumir energía por los usuarios de manera que se produzcan los cambios deseados en la curva de demanda. El empleo de la gestión de la demanda tendrá un mayor impacto en lo referente a las centrales de generación de energía, ya que estas reducirán su capacidad de generación o se construirán de una menor dimensión y ello supondrá un ahorro en costes de generación así como una reducción de las emisiones de CO₂[15][16]. Alguno de los beneficios producidos por parte del empleo de la gestión de la demanda son la facilidad para la integración de cualquier fuente de generación eléctrica en el sistema, el cual, se beneficiara además porque se reducirán problemas relacionados con la tensión, se descongestionarán las subestaciones en momentos puntuales y se reducirán pérdidas producidas en la transporte de energía. Y a su vez, generará beneficios también en el mercado energético y sus clientes, ya que permitirá que el precio de la electricidad se reduzca y no se

produzcan tantas variaciones, un mejor control del mercado eléctrico y el mayor beneficio, el cual será entendido por los usuarios finales, la reducción en el precio eléctrico a pagar por los clientes [17].

Por lo que el usuario final si notará el efecto de la Smart Grid si a esta se le añade la gestión de cargas, básicamente de forma económica ya que ciertas actividades realizadas en el hogar serán desplazadas hacia unas horas de menor consumo en la red general. Además, otros beneficios que podrá ver reflejados el usuario final sin tener un conocimiento de las Smart Grid son la creación de nuevos puestos de trabajo específicos para este sistema, ahorro económico no solo por la gestión de cargas sino en el pago de menos impuestos eléctricos y como no los beneficios en salud ya que se reducirá la contaminación ambiental. [18] Múltiples son los estudios realizados sobre las Smart Grid relacionados con los análisis de costo-beneficio y las evaluaciones del impacto ambiental, los cuales son empleados para apoyar las políticas de despliegue de los sistemas y tecnologías Smart Grid. Sin embargo, las estimaciones contradictorias y muy variadas de costos, beneficios, reducción de emisiones de gases de efecto invernadero y ahorro de energía dejan con una pequeña duda sobre el despliegue de las Smart Grids. Por lo que identificar las causas de la amplia variación de las estimaciones es crucial para apoyarse en esos números que suponen una mejora respecto de las Smart Grid sobre el sistema convencional y así favorecer la implantación de este nuevo modelo de generación eléctrica [19].

Alguno de los objetivos fundamentales de la gestión de la demanda son:

- Reducción de la potencia contratada mediante el buen uso de la gestión de la demanda ya que un gran coste de la factura de la luz viene generado por la potencia que se tiene contratada [20]. Para poder ajustar la potencia a la requerida es necesario estimar la potencia de los equipos de los que se disponga, contratar potencias que se encuentren normalizadas y gestionar con la empresa suministradora la opción de potencia elegida.

Las principales potencias contratadas para los residentes suelen ser 4,6 kW o 5,75kW existiendo muchas otras. Un ejemplo de ajuste mediante la gestión de la

demanda sería el siguiente en el cual, se tendría que tener contratada una potencia de 5,75 kW para cubrir las necesidades (Figura 5) pero con el empleo de la gestión de la demanda, se trasladarán actividades domésticas de las horas de mayor consumo hacia otros horarios que tengan menor coincidencia de uso (Figura 6) para así poder disminuir la potencia contratada y con ello un menor gasto en la factura de la luz.

Un ejemplo como en el del caso anterior llevado a términos económicos, se refleja con los consiguientes ahorros en la reducción de la potencia de contratación como se puede ver en (Figura 7).




Figura 5: Curva de potencia máxima 5,75 kW




Figura 6: Curva de potencia máxima 4,6 kW tras realización de gestión de cargas

Potencia que quieres contratar en kW

		MONO FÁSICA	3,45	4,6	5,75	6,9
Potencia que tienes ahora en kW	3,3 / 3,45					
	4,4 / 4,6		-61 €			
	5,5 / 5,75		-123 €	-61 €		
	6,6 / 6,9		-184 €	-123 €	-61 €	
	7,7 / 8,05		-246 €	-184 €	-123 €	-61 €
	9,2		-307 €	-246 €	-184 €	-123 €

Figura 7: Relación de ahorro económico con reducción de potencia[21]

- Fomentar la penetración de las energías renovables y el autoconsumo de los usuarios mediante la generación de energía en sus propios edificios a través de medios como paneles fotovoltaicos y con el uso de baterías de almacenamiento de energía, para así obtener la energía necesaria de ellas y no de la red. Con la normativa actual, toda energía generada de forma no necesaria y vertida a la red, no obtendrá ningún beneficio económico por parte de la persona generadora de forma

que estará desperdiciando ese exceso de producción mientras que si ese exceso se almacena en baterías se estaría reservando el consumo de energía para un futuro o bien, ese exceso de generación se puede aprovechar gracias a la gestión de la demanda mediante la distribución que ciertas cargas de la vivienda hacia los horarios en los cuales se produzca una mayor generación. Con este segundo empleo de los excesos de consumo, en el cual se hace uso de la gestión de la demanda y se adapta esta demanda a los momentos de generación, no solo se evitará el vertido gratuito de energía a la red sino que también se reducen las necesidades de tamaño para el almacenamiento de energía para su uso de forma autónoma.

- Reducción de gastos eléctricos mediante la gestión de la demanda se podrá desplazar ciertos consumos de elementos a otros momentos horarios en que el precio eléctrico sea más barato y así reducir el coste de la factura eléctrica. Algunos ejemplos de curvas de precios se mostraran a continuación en las que se reflejarán las distintas situaciones en los costes de la energía para los mismos periodos del día.




Figura 8: Curva de precios PVPV del mercado diario del 06/09/2017

En la Figura 8, se puede observar la variación del precio del €/kWh a lo largo del día siendo en este caso durante la horas de la noche el precio más bajo, durante el día un precio intermedio y en el periodo tarde/noche se ve el precio más elevado.




Figura 9: Curva de cargas en periodo tarde/noche conjunta a la de precios horarios

En la Figura 9 se observa la curva de cargas para la tarde/noche a lo largo de un día habitual de forma conjunta con la curva de precios representada en la Figura 8. Observándose así la relación de las horas de mayor precio eléctrico con los consumos de cada electrodoméstico del hogar.

PVPC	CONSUMO	GASTO
0,1067	2571	2,74 €
0,10127	2502	2,53 €
0,09443	2503	2,36 €
0,09518	2504	2,38 €
0,09822	2505	2,46 €
0,09913	3506	3,48 €
0,10524	4127	4,34 €
0,10401	5628	5,85 €
0,10895	2809	3,06 €
0,10766	2510	2,70 €
0,10566	2511	2,65 €
0,10598	2512	2,66 €
0,10828	2813	3,05 €
0,1086	3884	4,22 €
0,10924	2585	2,82 €
0,10492	2516	2,64 €
0,102	2517	2,57 €
0,10225	2888	2,95 €
0,10323	5839	6,03 €

0,10833	5590	6,06 €
0,11501	6071	6,98 €
0,12516	7842	9,82 €
0,12543	5643	7,08 €
0,12038	2594	3,12 €
		94,56 €

Tabla 1: Gasto económico para el período tarde/noche




Figura 10: Curva de cargas en periodo intermedio con la de precios

En la Figura 10 se observa la curva de cargas para el periodo intermedio en un día habitual de forma conjunta con la curva de precios representada en la Figura 8.

PVPC	CONSUMO	GASTO
0,1067	2571	2,74 €
0,10127	2502	2,53 €
0,09443	2503	2,36 €
0,09518	2504	2,38 €
0,09822	2505	2,46 €
0,09913	3506	3,48 €
0,10524	4127	4,34 €
0,10401	5628	5,85 €
0,10895	2809	3,06 €
0,10766	2510	2,70 €
0,10566	2511	2,65 €

0,10598	4762	5,05 €
0,10828	5063	5,48 €
0,1086	6134	6,66 €
0,10924	4835	5,28 €
0,10492	4766	5,00 €
0,102	2517	2,57 €
0,10225	2888	2,95 €
0,10323	3839	3,96 €
0,10833	3590	3,89 €
0,11501	4071	4,68 €
0,12516	4542	5,68 €
0,12543	2843	3,57 €
0,12038	2594	3,12 €
		92,47 €

Tabla 2: Gasto económico para el período intermedio




Figura 11: Curva de cargas para la madrugada con la curva de precios

En la Figura 11 se observa la curva de cargas para el periodo de precios más barato en un día habitual de forma conjunta con la curva de precios representada en la Figura 8.

PVPC	CONSUMO	GASTO
0,10670007	2571	2,74 €
0,10127037	4502	4,56 €
0,09443252	4503	4,25 €
0,09518409	4504	4,29 €
0,09821862	4505	4,42 €
0,09912565	5506	5,46 €
0,10523554	3877	4,08 €
0,10400987	5378	5,59 €
0,10894941	2809	3,06 €
0,10766159	2510	2,70 €
0,10566323	2511	2,65 €
0,10597512	2582	2,74 €
0,10828138	2883	3,12 €
0,10860318	3884	4,22 €
0,10923642	2585	2,82 €
0,10492446	2586	2,71 €
0,10200115	2517	2,57 €
0,10225297	2888	2,95 €
0,10322868	3589	3,70 €
0,10833406	3340	3,62 €
0,11501326	4071	4,68 €
0,12516356	3642	4,56 €
0,12543267	2843	3,57 €
0,12037789	2594	3,12 €
		88,20 €

Tabla 3: Gasto económico para el periodo de madrugada

- Conseguir un aplanamiento de la curva de la demanda de electricidad mediante un desplazamiento de consumos desde los periodos punta a los periodos valle. Para conseguir este objetivo se tiene que buscar modificar los patrones de consumo de energía eléctrica, para así obtener una curva más plana que tenga una mayor influencia en la eficiencia del conjunto del sistema. El tipo de mecanismos de gestión de la demanda que inciden en este objetivo se denominan mecanismos de “modulación”. El cual es una de las medidas empleadas actualmente mediante el uso de las discriminaciones horarias.[22]

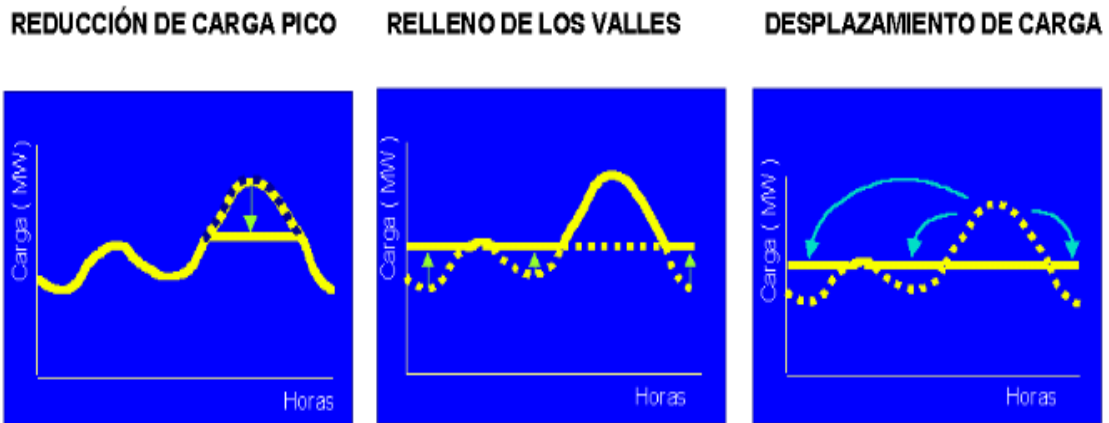


Figura 12: Gestión de cargas.[23]

Un ejemplo del buen funcionamiento y beneficios aportados por las Smart Grids se ve reflejado en el caso de la Smart Grid en Málaga. Este proyecto no construye nuevas redes sino que trabaja sobre las actuales incorporando elementos y dispositivos a lo ya existente con el objetivo de mejorar la optimización y gestión actual de las infraestructuras. El lugar de este desarrollo engloba tanto clientes domésticos, como servicios o industriales pero mayoritariamente clientes domésticos con lo que ello implica en la curva de consumo correspondiente, es decir, muy poco consumo durante la noche y dos picos de consumo durante el día. La generación por parte de las renovables en este proyecto se encuentra a un nivel muy bueno comparando con la demanda generada en la zona, lo cual permite aplanar la curva reduciendo los picos de consumo. En esta zona que se está realizando el proyecto tiene una ventaja sobre otras y es que sin la realización de ningún tipo de obra disponen de la capacidad para seguir creciendo en un futuro proporcionando energía a más futuros clientes o satisfaciendo nuevos servicios como puede ser la integración del vehículo eléctrico.[24] En otros países como Estados Unidos, el gobierno ha formalizado una ley a favor de la iniciativa de integración de las Smart Grid y se ha comprometido a proporcionar dinero para este tipo de proyectos. Los mayores avances relacionados con este nuevo sistema en Estados Unidos han sido disponer de infraestructura avanzada para la medición para los servicios públicos, medidores inteligentes para los clientes, integración de la tecnología en dispositivos de campo en sistemas de distribución, sensores avanzados, redes de comunicación de alta velocidad y una sumamente importante para este sistema como son las medidas de seguridad cibernéticas [25]. Otro ejemplo [26] de estudio realizado

sobre la gestión de la demanda es el realizado en los Países Bajos, a partir de datos reales se plantean distintas estrategias de demanda y de respuesta para moldear las cargas futuras. Las estrategias se basan en la red o en el mercado de energía o en el mercado de energía con capacidades limitadas, siendo este último el que mayor beneficio produce para el sistema.

1.1 Importancia del módulo de predicción de demanda

Como se ha mencionado, los métodos de predicción de demanda desarrollados en este proyecto formarán parte del algoritmo de gestión / optimización del consumo en viviendas a desarrollar, implantar y probar en escenarios reales en un proyecto Europeo del marco de H2020.

El principal objetivo del proyecto Europeo es demostrar y acelerar la implantación de nuevos servicios en la red de distribución y en los mercados de comercialización de energía eléctrica a la vez que se crea un mercado Europeo de energía eléctrica estandarizado y abierto para todo tipo de actores, desde productores hasta consumidores y prosumidores (consumidores y productores de energía eléctrica). Para ello se desarrollará un entorno virtual que facilite el intercambio de información entre todos los agentes implicados, lo que permitirá un uso de la energía más eficiente y racional.

Una de las consecuencias de este proyecto es desarrollar una herramienta que permita optimizar, minimizar, el coste energético de los consumidores de energía eléctrica. Para lograr esto es necesario desarrollar herramientas de optimización y de previsión de precios, producción eléctrica de origen renovable y consumo, punto en el que entran en acción los métodos estudiados y desarrollados en este TFM.

Entre otras tareas, la Fundación CIRCE participa en el desarrollo de una herramienta que permita la optimización en tiempo real del consumo eléctrico de viviendas en

distintos escenarios energéticos. De ahí la importancia de desarrollar algoritmos precisos pero que también serán sencillos, de rápida ejecución, que requieran de poca información para trabajar y sobre todo sean robustos. Esta herramienta, alojada en un servidor “en la nube”, estará compuesta por los módulos mostrados en la Figura 13, entre los que se incluye un módulo de predicción de consumos y otro de generación de datos perdidos.




Figura 13: Esquema de la herramienta de optimización de consumo eléctrico

El resultado de este proceso de optimización/planificación es el plan de consumo y de funcionamiento de los sistemas de generación y almacenamiento de energía eléctrica de las próximas 24 horas que minimiza los costes eléctricos del consumidor. Es importante destacar que los resultados (previsiones y optimización/planificación) se actualizan cada 15 minutos para adaptarse a la evolución del sistema, tal y como ilustra la Figura 12.




Figura 14: Planificación del día siguiente de almacenamiento y generación

1.2 Metodología de trabajo

El trabajo desarrollado en este TFM parte del análisis de artículos científicos centrados en la búsqueda del mejor método para determinar las futuras demandas. Se centra en métodos estadísticos porque tras la consulta de diversos documentos de carácter científico que comparan los métodos estadísticos con el empleo de redes neuronales llegando a la conclusión que con el uso de los métodos estadísticos para la previsión de carga siendo estos lo suficientemente precisos y trabajados se llegan a obtener resultados sumamente parecidos o mejores a los que se pueden hallar empleando las redes neuronales. Pero obviamente con una cantidad de información previa mucho menor, lo cual supone una menor complejidad en la elaboración de su programa y en la determinación de la previsión de carga. [27][28][27][29][30]

Una vez que se ha centrado el caso a estudiar en el TFM, se realiza la posterior búsqueda y análisis dentro de los métodos estadísticos los más interesantes como pueden ser el método de coeficientes, el método ARIMA, el método AR, el método de regresión múltiple, métodos “top-down” y “bottom up” o métodos de regresión entre otros. Con estos métodos estudiados en distintos artículos científicos se trabaja para

seleccionar cual de todos ellos tiene menor error para la determinación de la previsión de cargas.[31]

Para poder aplicar todos los métodos mencionados antes se necesita previamente disponer de la cantidad de datos suficientes para poder trabajar con estos métodos. En función del método aplicado, será necesario una mínima cantidad de datos distinta pero cuanta mayor sea la cantidad de datos de los que se disponga, mayor será la exactitud en los resultados obtenidos.

Para el desarrollo de este trabajo Fin de Máster se emplean como datos los obtenidos de contadores individuales a lo largo de un par de años, determinando el valor medio de consumo de cada día y a partir de esos datos de partida se genera la previsión de demanda para un futuro.

Además, se han generado unas curvas de demanda a partir de datos de consumo habituales en una vivienda, como se puede observar en la Figura 9 dichos datos. Partiendo de estos para la obtención de nuevas curvas de demanda y permitiendo ajustarlas según la gestión de cargas que se realice. Siendo de la siguiente forma:

Elementos	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	Potencia	Sigma uso	Sigma hora	
Tostadora	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	400	1	1	
Horno	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	0	0	0	1300	2	2
Microondas	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	800	1	1
Aspiradora	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	750	2	2
Cafetera	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	900	1	1
Plancha	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1000	2	2
Ordenador	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	300	1	1
Calefactor	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	1	1	1	0	0	0	2000	3	3
Iluminacion	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0	250	1	1
Nevera	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	2500	0	0
Television	1	0	0	0	0	0	1	1	0	0	0	0	0	1	1	0	0	1	1	1	0	1	1	1	0	70	1	1

Figura 15: Tabla Excel para introducir el patrón de consumo diario, potencia de cada elemento y desviaciones típicas de uso y hora de encendido

A partir de la Figura 15 donde se introducen las horas de demanda de energía en una vivienda para cada dispositivo de consumo, se obtiene la relación de potencias horarias con las que contaría la hipotética vivienda. De acuerdo con esta relación de consumos, mediante la realización de una configuración de trabajo se puede obtener la curva de carga resultante de dicha tabla y en ella realizar la gestión de demandas de consumo energético por parte de ciertos dispositivos domésticos de forma que se modifique la

curva de carga hacia una que tenga un mayor interés. Dicho programa se encuentra en anexo a este documento.

1.3 Métodos de previsión estudiados

En este punto se analizarán todos los métodos estudiados para la previsión de cargas de forma individual explicando en qué consiste cada uno de ellos para su posterior aplicación y determinando así cual o cuales de todos ellos tendrán un menor error en la previsión de cargas. Esta última parte, será detallada más en profundidad en el apartado de resultados del estudio realizado.

1.3.1 Método de regresión lineal múltiple

El método de regresión lineal múltiple considera los factores que influyen en la variación de la demanda como pueden ser temperatura, crecimiento demográfico, humedad, etc. Mediante el empleo de la ecuación de “Steadman” se puede obtener el valor real de consumo a partir de analizar el consumo de electricidad de muchos consumidores y extraer los componentes necesarios. Con los datos de consumo por hora, la temperatura y humedad relativa se obtiene la electricidad destinada para confort humano y la diferencia de esta con la electricidad consumida total es la electricidad real consumida para procesos productivos y servicios.

El valor obtenido se interpola con un polinomio cúbico determinando así la nueva curva de consumo real de energía. Este valor es la energía de la componente relacionada con el clima más adverso, existen otras como la relacionada con la iluminación. Para la obtención de este valor se necesita conocer los valores de iluminación exterior para aplicar el polinomio y con el determinar el consumo de la iluminación. Para obtener la energía real consumida con respecto a tiempo e iluminación de manera conjunta se emplea el Matlab para la elaboración de una superficie de consumo la cual es convexa debido a que durante el día la necesidad de iluminación es menor, descendiendo la

gráfica hasta que el valor mínimo sea cero y restando la obtenida con el valor inicial, tenemos la energía que requerimos. Para la iluminación de la calle se aplica el mismo método que para la iluminación particular.

Para obtener la nueva curva de demanda real de energía en procesos productivos, se debe interpolar su valor en un polinomio cúbico. Aplicando este polinomio nuevamente, se puede determinar el consumo en iluminación a partir de los valores de iluminación exterior. Si se quiere conocer la energía real consumida en iluminación con respecto al tiempo, se emplea el Matlab para la elaboración de una gráfica de superficie la cual es convexa debido a que durante el día la necesidad de iluminación disminuye. Si la gráfica obtenida se desplaza hasta que el valor mínimo sea cero y se realiza la diferencia entre las dos gráficas se obtiene el consumo real en iluminación. De idéntica forma se puede hallar el consumo en iluminación destinada a la calle.[29]

1.3.2 Modelo de búsqueda de coeficientes

El modelo predictivo de búsqueda de coeficientes consiste en primer lugar en escoger el mes previo al mes donde se encuentra la semana que se desea estimar. Con este mes se extraen unos coeficientes $C(s-1)$, $C(s-2)$, $C(A-1(s))$, $C(A-1(s-1))$, como resultado de la minimización de un sistema lineal formado por el producto de los mismos por la suma de los consumos correspondientes a $A(s-1)$, $A(s-2)$, $A-1(s)$, $A-1(s-1)$ de las semanas del mes escogido y el consumo real. Siendo los valores correspondientes a estos parámetros: $A(s-1)$ el valor de consumo de la energía correspondiente a la semana previa de estimación del mismo año; $A-1(s)$ el valor de consumo de energía correspondiente a la semana que se pretende estimar pero del año anterior; $A-1(s-1)$ el valor correspondiente al consumo de energía de la semana previa a la que se pretende estimar pero del año anterior y así con el resto de consumos. Para los coeficientes como el $C(s-1)$ se obtienen a partir de una ecuación como en este caso sería la división entre el valor de consumo de la semana previa a la estimada del mismo año y el valor de la semana previa del año anterior. Estos datos más la suma de los consumos correspondientes a la semana n se recogen en una tabla dinámica. El sistema se resuelve mediante la utilización de una herramienta de Excel llamada Solver. Una vez se tengan

los coeficientes para cada día de la semana, serán introducidos en el algoritmo de la estimación para poder obtener así la curva de consumo estimada.[32]

1.3.3 Métodos “top-down” y “bottom up”

El primero es un método que parte de los datos históricos agregados a la demanda y el segundo de ellos, parte de datos históricos de la demanda desagregada por procesos productivos, de manera que la demanda total es la suma de todas las agregaciones de consumos. El bottom-up, ofrece varias ventajas como la flexibilidad de los datos requeridos o la inclusión de muchos datos históricos necesarios para muchos países. Este método generalmente se utiliza para estimar el ahorro de energía debido a la ejecución de programas o la intervención de la eficiencia energética de las máquinas, equipos o materiales tales como programas estándar y etiquetado de los aparatos residenciales. En cambio, el método top-down que permite calcular el ahorro de energía, como resultado de la aplicación de programas de eficiencia energética, a partir de los datos de nivel nacional, tales como el consumo nacional de energía, la intensidad energética, crecimiento de la población, y de algunos datos económicos como el PIB nacional, la tasa de urbanización. Para este trabajo se optó por el bottom-up, dicho modelo requiere datos de entrada relacionados con los equipos utilizados, el patrón de construcción, la operación del equipo y su uso. El primer conjunto de entradas se refieren a los tipos de equipos adquiridos o instalados como son ordenadores, pantallas, impresoras, copiadoras y restauración. Se proporcionan cantidades de energía consumida la cual se puede producir según el modo de funcionamiento: "off", "bajo" y "on". La off es el consumo de energía más bajo, mientras que el equipo está conectado a la red eléctrica. El bajo se define como un modo de baja potencia que el equipo es capaz de entrar automáticamente después de un período de inactividad. Y el on que abarca todos los modos de funcionamiento. Además, asigna a cada trabajador un perfil en función del tiempo que pase en la oficina y necesita saber las horas de llegada, salida, la cantidad de equipos que se apagan al acabar el día, la ocupación durante la hora del almuerzo, etc. El modelo calcula la potencia demandada mediante la multiplicación de las potencias en los distintos modos por los perfiles de uso que tenga cada equipo, obteniendo así la demanda en kW, si se quiere el consumo en la semana pues se

multiplicaría por los cinco días laborables. A la potencia calculada se le aplica un factor de diversidad que es la relación entre la suma de las demandas máximas en las distintas partes de un sistema eléctrico y la demanda máxima de todo el sistema, este es del 75% en los días de semana y baja a un 15% el fin de semana en las empresas que tengan trabajadores en esos días.[33][34]

1.3.4 Métodos basados en redes neuronales

Para emplear estos métodos se necesitan diversos grupos de datos de entrada como son la temperatura, viento, el calendario y la carga eléctrica, es decir, el consumo. Este método es muy complejo y para cada proyecto se realiza uno específico aunque existen programas más genéricos para su aplicación como en este caso que se usa el Matlab. Se realiza un entrenamiento con una cantidad de valores elevada lo que dificulta el trabajo con el objetivo de obtener un valor óptimo. Si estos valores hallados son buenos significa que podremos empezar a realizar la predicción de demanda eléctrica. Con los datos introducidos de calendarios, temperaturas y demás, este método permite obtener una predicción realmente buena pero siendo muy dificultosa la determinación de la demanda por la complejidad del método.

Es un método complejo, el cual requiere conocer diversos grupos de datos de entrada como son la temperatura, viento, el calendario y consumo eléctrico. Además, se realiza un método específico para cada proyecto, no obstante, existen programas genéricos como es el caso de Matlab. Consiste en el entrenamiento con muchos valores para obtener un valor óptimo. Con la introducción de los datos de calendarios, temperaturas y otros, hacen que este método sea muy preciso pero a la vez muy dificultosa la obtención de la previsión de la demanda. [27]

1.3.5 Métodos de regresión

Los métodos de regresión tienen por objetivo la regresión múltiple para aprender más sobre la relación entre varias variables independientes y una dependiente. Está basado

en los mínimos cuadráticos, el modelo se ajusta de tal manera que la suma de los cuadrados de las diferencias de valores observados y pronosticados se reduce al mínimo. Se emplean factores como el tiempo, el tipo de día y clase de consumidores. Este modelo expresa la carga como una función lineal.[30]

1.3.6 Modelos autorregresivos de media móvil

El promedio móvil es un modelo en el que la serie de tiempo se considera como una media móvil de una serie de choque aleatorio. Hay una dualidad entre el proceso de media móvil y el proceso autorregresivo que es que el modelo de media móvil puede ser reescrito en una forma autorregresiva. Sin embargo, esto solo puede ser hecho si los parámetros de media móvil cumplen con ciertas condiciones lo que supondría que el modelo es invertible. Las series no serán estacionarias.[30]

2. Conclusión en la elección de metodologías

La conclusión tomada para la elección del mejor método para la obtención de la predicción de la demanda por la cual se descarta la de red neuronal artificial viene dada por un artículo que compara tres métodos distintos para la obtención de la demanda energética y realiza una conclusión final de cuál de los métodos resulta más eficaz. Los métodos utilizados en este artículo son el de redes neuronales artificiales, modelo oculto de Markov y el método de máquina restringida de Boltzmann. El primero de estos ya ha sido explicado en otros artículos así que solo se comentará los otros dos restantes. El modelo oculto de Markov es investigar con el fin de extender los modelos de regresión de series de tiempo mediante la adición de una variable de estado oculto discreta, las cuales son la representación de una combinación específica de hora y día. Mientras que el método de máquina restringida de Boltzmann se utiliza para modelar los datos de series de tiempo y las actividades humanas. Estos modelos son probabilísticos, con nodos estocásticos y capas. Además, posee una excelente capacidad de generalización. Las conclusiones extraídas de la aplicación de los tres métodos son que el análisis realizado con el método de Boltzmann superó los otros métodos. Aunque todos los

métodos presentados mostraron tiempos de entrenamiento rápido y por lo tanto son adecuados.[28]

Otro trabajo consultado que permite la eliminación del método de redes neuronales artificiales para nuestra elección es la tesis realizada sobre la comparativa entre las redes neuronales artificiales y los métodos estadísticos. Los modelos estadísticos empleados son el método K vecinos más cercanos y el modelo de regresión kernel. Estos modelos fueron aplicados sobre un total de 22 matrices de datos diferentes. Aunque los resultados de este estudio indican que no existe un método claramente superior en todos los conjuntos de datos analizados, las redes neuronales siempre aparecen dentro del grupo de mejores predictores en función del porcentaje de clasificaciones correctas. Pero existen algunos inconvenientes relacionados con las redes neuronales como el excesivo tiempo que tardan algunas redes en obtener los pesos, las exigencias que imponen al usuario como determinar el número de neuronas ocultas, el valor de los parámetros, la finalización del entrenamiento, etc., y la dificultad en comprender la representación interna aprendida por la red. Por lo cual, su complejidad durante el trabajo no la hace ideal para su uso.[35]

3. Resultados

En este apartado, se verán reflejados los resultados de predicción de distintos métodos hallados todos ellos con la herramienta informática Matlab. En cada uno de ellos, será mostrado la predicción realizada y el error generado entre la diferencia del valor real de demanda y el predicho. Para lo cual, se trabajara a partir de datos energéticos proporcionados por red eléctrica española (REE) para más de un año y con datos de contadores individuales de domicilios particulares o industrias o cualquier tipo de establecimiento.

3.1 Modelo de búsqueda de coeficientes

Como se ha explicado en el apartado de modelos de predicción para este tipo de método, se obtendrán tres predicciones distintas con sus correspondientes errores en función de la semana empleada para la predicción. Se calcula a partir de la semana 56 para tener un margen de datos reales empleados para la predicción.

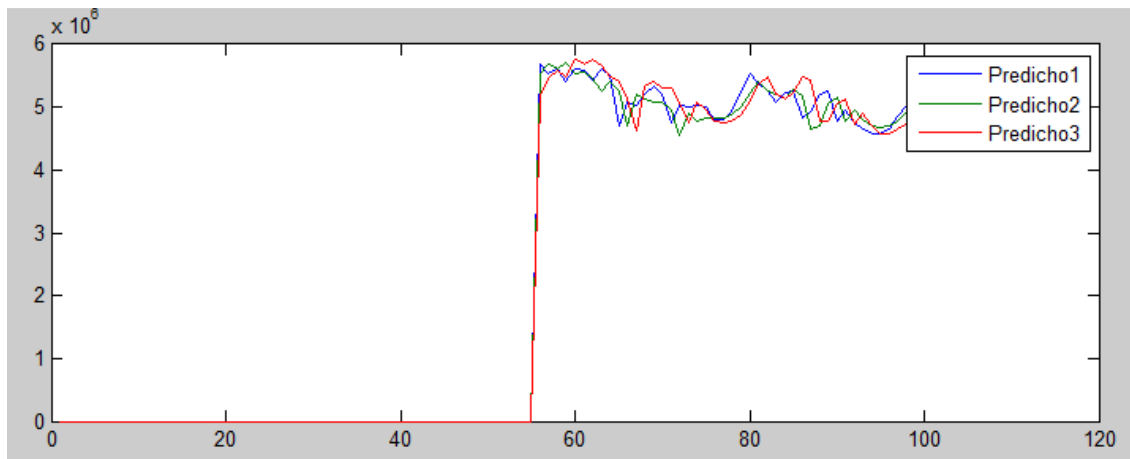


Figura 16: Predicciones en función de la semana empleada en el método de coeficientes




Figura 17: Errores generados en el método de coeficientes

	NRMSE
Predicción 1	0.05926
Predicción 2	0.05507
Predicción 3	0.0780

Tabla 4: Error normalizado con el método de coeficientes

Cabe destacar en este método que los datos de partida para poder desarrollar dicho método en este caso solo se le puede aplicar los proporcionados por red eléctrica española ya que en esta metodología se requiere de una cantidad de datos muy extensa para poder trabajarla y solo con estos datos de partida se puede desarrollar este método.

3.2 Método del día similar

En este caso se trabaja con datos del día anterior, semana previa al dato a predecir y el día anterior a la semana previa. A partir de estos datos, se realiza la predicción.




Figura 18: Predicción con el método del día similar




Figura 19: Error generado con el método del día similar

NRMSE	
Predicción 1	0.0141

Tabla 5: Error normalizado con el método del día similar

Estos resultados obtenidos son a partir de los datos proporcionados por red eléctrica española para más de un año. A continuación, se realizara el mismo proceso pero esta vez utilizando los datos individuales de los contadores. En primer lugar se obtendrán las predicciones para las siguientes 24 horas y después se calculara su error.




Figura 20: Predicciones para los contadores individuales

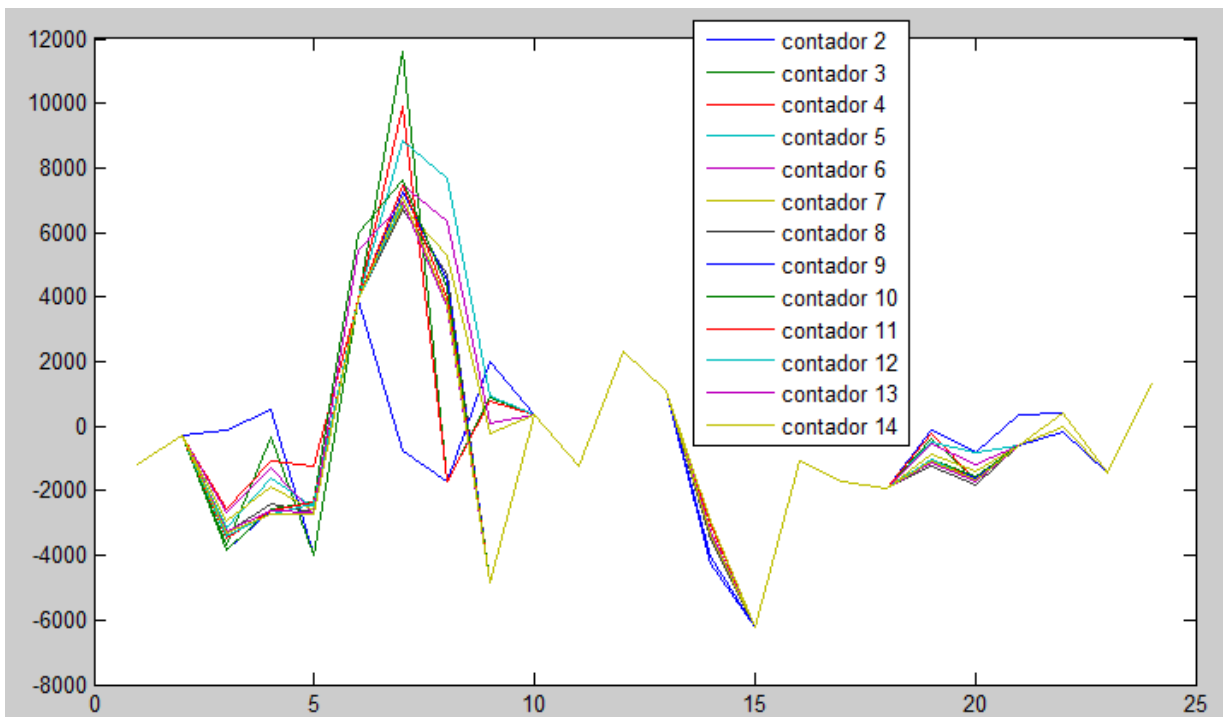


Figura 21: Error generado para cada contador

	NRMSE
Contador 2	0,0535
Contador 3	0,0786
Contador 4	0,0695
Contador 5	0,077
Contador 6	0,0698
Contador 7	0,0663
Contador 8	0,071
Contador 9	0,0733
Contador 10	0,0758
Contador 11	0,0714
Contador 12	0,0698
Contador 13	0,0722
Contador 14	0,0704

Tabla 6: Error normalizado para cada contador

3.3 Método AR

Este método trabaja con datos horarios y para su empleo se define el número de horas que se pretende predecir. En este método empleado, se divide la predicción en dos, la parte estocástica y la parte estacional para las cuales se calculará el error de cada una y el error global.




Figura 22: Predicción estacional comparada con su demanda para el método AR




Figura 23: Error estacional par el método AR

Error normalizado estacional

0.103

Tabla 7: Error normalizado estacional para método AR

En cuanto a la parte estocástica, se realiza lo mismo que para la parte estacional.




Figura 24: Predicción estocástica comparada con su demanda para el método AR




Figura 25: Error estocástico para el método AR

Error normalizado estocástico

1.0967

Tabla 8: Error normalizado estocástico para el método AR

Una vez que tenemos las dos partes calculadas se obtiene el error global y el error normalizado global.




Figura 26: Error global para el método AR

Error normalizado total

0.0715

Tabla 9: Error normalizado total para el método AR

Estos resultados obtenidos son a partir de los datos proporcionados por red eléctrica española para más de un año. A continuación, se realizara el mismo proceso pero esta vez utilizando los datos individuales de los contadores sumándolos todos como si fuera uno solo para facilitar el trabajo y que la variación del tipo de función del espacio para el que se encuentra asignado cada contador no inflencie mucho. Se divide la predicción en dos, la parte estocástica y la parte estacional para las cuales se calculará el error de cada una y el error global.

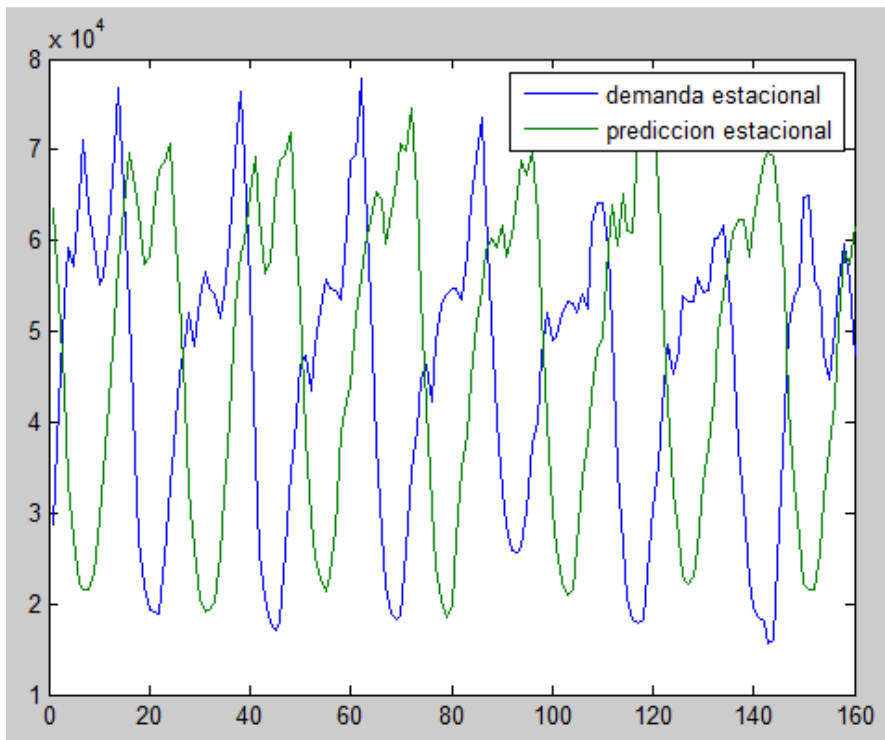


Figura 27: Demanda y predicción estacional para datos de contadores individuales




Figura 28: Error estacional generado para datos de contadores individuales

Error normalizado estacional

0.1753

Tabla 10: Error normalizado estacional para los contadores individuales

En cuanto a la parte estocástica, se realiza lo mismo que para la parte estacional.

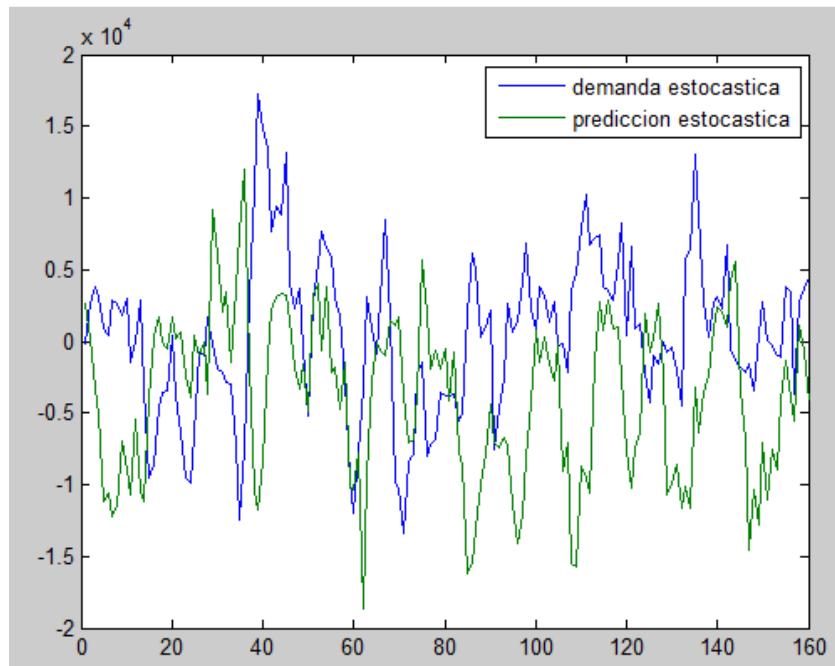


Figura 29: Demanda y predicción estocástica para los contadores individuales




Figura 30: Error estocástico generado para los contadores individuales

Error normalizado estocástico

5.6117

Tabla 11: Error normalizado estocástico para los contadores individuales

Una vez que tenemos las dos partes calculadas se obtiene el error global y el error normalizado global.




Figura 31: Error global para los contadores individuales

Error normalizado total
0.4454

Tabla 12: Error normalizado total para los contadores individuales

3.4 Método ARMA

Se trata de un método muy similar al anterior en el cual se divide en dos partes la demanda, la parte estocástica y la parte estacional. Se obtiene para cada una de ellas su previsión de demanda y se determina su error individual. Ya por último se halla el error global generado con esta forma de previsión de cargas.




Figura 32: Predicción estacional para el método ARMA




Figura 33: Error estacional con el método ARMA

Error normalizado estacional

0.1311

Tabla 13: Error normalizado estacional con el método ARMA

Una vez que se tiene una de las dos partes, en este caso la estacional se obtiene lo mismo para la parte estocástica.

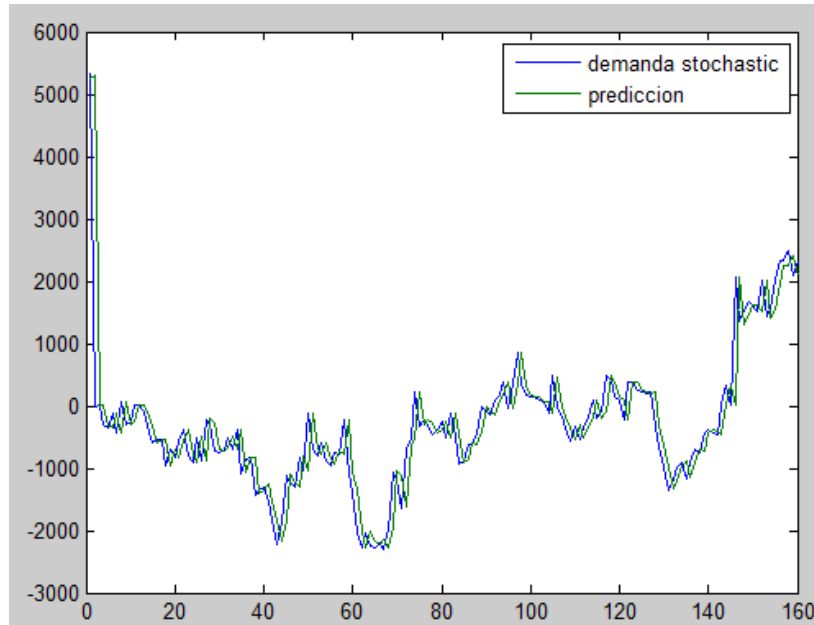


Figura 34: Predicción estocástica para el método ARMA




Figura 35: Error estocástico generado para el método ARMA

Error normalizado estocástico

7.4520

Tabla 14: Error normalizado estocástico para el método ARMA

Ahora que se tienen las dos partes de la predicción, se halla el error general obtenido empleado este método.




Figura 36: Error general obtenido para el método ARMA

Estos resultados obtenidos son a partir de los datos proporcionados por red eléctrica española para más de un año. A continuación, se realizara el mismo proceso pero esta vez utilizando los datos individuales de los contadores sumándolos todos como si fuera uno solo para facilitar el trabajo y que la variación del tipo de función del espacio para el que se encuentra asignado cada contador no inflencie mucho. Se divide la predicción en dos, la parte estocástica y la parte estacional para las cuales se calculará el error de cada una y el error global.




Figura 37: Demanda y prediccion estacional para los contadores individuales




Figura 38: Error estacional para los contadores individuales

Error normalizado estacional

0.4616

Tabla 15: Error normalizado estacional para los contadores individuales

Una vez que se tiene una de las dos partes, en este caso la estacional se obtiene lo mismo para la parte estocástica.




Figura 39: Demanda y predicción estocástica para los contadores individuales




Figura 40: Error estocástica para los contadores individuales

Error normalizado estocástico

11.8369

Tabla 16: Error normalizado estocástico para los contadores individuales

Ahora que se tienen las dos partes de la predicción, se halla el error general obtenido empleado este método.




Figura 41: Error total para los contadores individuales

Error normalizado total
0.7395

Tabla 17: Error normalizado total de los contadores individuales


4. Conclusiones

A partir del trabajo práctico realizado con los métodos estadísticos, los cuales eran tan buenos o mejores que métodos más complejos si se trabaja de forma precisa con ellos según diversos artículos científicos. Se ha trabajado con los métodos anteriormente vistos por ser los métodos que pueden tener mejor resultado, es decir, menor error en el cálculo de la predicción. Estas metodologías empleadas, pueden ser trabajadas a partir de datos ya conocidos los cuales pueden ser datos de consumo mensuales, como los expuestos en el apartado anterior o bien con datos horarios de consumos cuyo resultado será mucho más preciso y por lo tanto tendrá un menor error.

Errores generales	
Modelo de búsqueda de coeficientes	0.05926 // 0.05507 // 0.078
Método del día similar	0.0141
Método AR	0.0715
Método ARMA	0.1604

Tabla 18: Conclusión de errores generados

Los errores obtenidos con estos métodos son muy pequeños pero cabe destacar lo anteriormente mencionado que dependiendo de qué tipo sean los datos de partida si horarios o mensuales los errores generados variarán, como puede ser el caso en esta situación para el método ARMA, cuyo trabajo reflejado en este caso es con datos mensuales y con datos horarios tiene un error mucho menor semejante al generado por el método AR. Todo este trabajo realizado con los diversos métodos está orientado hacia búsqueda del mejor método para la previsión de cargas en viviendas.



5. Trabajos futuros

Como es lógico, este estudio no es definitivo ya que el paso del tiempo crea la necesidad de seguir investigando en estos temas para seguir así progresando y siendo lo más precisos posibles para la previsión de cargas de forma que tras un tiempo de 1 o 2 años de funcionamiento sería interesante volver a evaluar los métodos estudiados con los datos reales de los demo-sites y cuando se dispongan de más datos reales sería interesante evaluar otros tipos de métodos más complejos (redes neuronales, lógica fuzzy, etc...) tomando como referencia los resultados de los desarrollados en este TFM. No obstante, la obtención de datos de consumos debe ser continuada para así disponer con una mayor cantidad de datos con los que poder trabajar facilitando así en un futuro los estudios a realizar.

6. Referencias

- [1] Enerlis, E. and Young, and F. and M. Network, *Libro Blanco Smart Cities*. 2012.
- [2] Agencia Internacional de la Energía, “Perspectivas de crecimiento de la demanda mundial de energía primaria.pdf.” .
- [3] T. Iàk, “Relacion demanda y precio de la luz,” p. 0.
- [4] E. Gutiérrez Moya and M. T. Arévalo Quijada, “La demanda residencial de energía eléctrica en la Comunidad Autónoma de Andalucía: Un análisis cuantitativo,” pp. 1–448, 2003.
- [5] J. R. Cancelo and A. Espasa, “Modelizaci{ó}n del efecto temperatura en el consumo de electricidad: un ejercicio de b{ú}squeda de especificaci{ó}n en relaciones din{á}micas no lineales,” *Estadística Espa{ñ}ola*, vol. 37, no. 139, pp. 183–200, 1995.
- [6] J. O. Dada, “Towards understanding the benefits and challenges of Smart/Micro-Grid for electricity supply system in Nigeria,” *Renew. Sustain. Energy Rev.*, vol. 38, pp. 1003–1014, 2014.
- [7] Y. Yoldaş, A. Önen, S. M. Mueeen, A. V. Vasilakos, and İ. Alan, “Enhancing smart grid with microgrids: Challenges and opportunities,” *Renew. Sustain. Energy Rev.*, vol. 72, no. October 2016, pp. 205–214, 2017.
- [8] N. S. Nafi, K. Ahmed, M. A. Gregory, and M. Datta, “A survey of smart grid

- architectures, applications, benefits and standardization,” *J. Netw. Comput. Appl.*, vol. 76, no. August, pp. 23–36, 2016.
- [9] E. E. Portal, “SMART GRID – A real-time dynamic network of electrical demand, supply and control.pdf.” .
- [10] S. Bahrami, S. Member, A. Sheikhi, S. Member, and ... Vácha, “From Demand Response in Smart Grid Toward Integrated Demand Response in Smart Energy Hub,” *IEEE Lat. Am. Trans.*, vol. 13, no. 3, pp. 1–6, 2016.
- [11] Madridmasd, “Smart Grids_ Redes Eléctricas ya ‘listas’.pdf.” .
- [12] Futured, “Redes Eléctricas ya ‘lista’.pdf.” .
- [13] Innovaspain, “‘Smart grids’, llega la distribución inteligente de energía a nuestro país.pdf.” .
- [14] C. Wilson, T. Hargreaves, and R. Hauxwell-Baldwin, “Benefits and risks of smart home technologies,” *Energy Policy*, vol. 103, no. January, pp. 72–83, 2017.
- [15] M. Qardan, M. Cheng, J. Wu, and N. Jenkins, “Benefits of demand-side response in combined gas and electricity networks,” *Appl. Energy*, vol. 192, p. -, 2016.
- [16] A. Conchado, P. Linares, O. Lago, and A. Santamaría, “An estimation of the economic and environmental benefits of a demand-response electricity program for Spain,” *Sustain. Prod. Consum.*, vol. 8, no. October, pp. 108–119, 2016.
- [17] N. G. Paterakis, O. Erdinç, and J. P. S. Catalão, “An overview of Demand Response: Key-elements and international experience,” *Renew. Sustain. Energy Rev.*, vol. 69, no. November 2016, pp. 871–891, 2017.
- [18] E. Velasco-Ramírez, C. Ángeles-Camacho, and M. García-Martínez, “Redes de transmisión inteligente. Beneficios y riesgos,” *Ing. Investig. y Tecnol.*, vol. 14, no. 1, pp. 81–88, 2013.
- [19] M. Moretti, S. N. Djomo, H. Azadi, K. May, K. De Vos, S. Van Passel, and N. Witters, “A systematic review of environmental and economic impacts of smart grids,” *Renew. Sustain. Energy Rev.*, vol. 68, pp. 888–898, 2016.
- [20] J. María, Y. Loyola, and I. Industrial, “La factura eléctrica,” 2016.
- [21] “Preciación de tarifas electricas.”
- [22] A. C. Santos, D. B. Díaz, E. C. Fernández, and M. A. C. Gil, “Generación distribuida, autoconsumo y redes inteligentes.” p. 871, 2015.

- [23] Enercol, “Gestion de cargas eléctricas.pdf.” .
- [24] Endesa, “Smart Grid Málaga.”
- [25] A. H. I. Lee, H. H. Chen, and J. Chen, “Building smart grid to power the next century in Taiwan,” *Renew. Sustain. Energy Rev.*, vol. 68, no. October 2016, pp. 126–135, 2017.
- [26] E. A. M. Klaassen, R. J. F. van Gerwen, J. Frunt, and J. G. Slootweg, “A methodology to assess demand response benefits from a system perspective: A Dutch case study,” *Util. Policy*, vol. 44, pp. 25–37, 2016.
- [27] I. Delmar, J. García, I. Alexander, and C. Milanes, “Predicción de la demanda eléctrica de corto plazo mediante Redes Neuronales Artificiales.,” *Potencia*, no. 1, pp. 2–5, 2003.
- [28] W. Hämmäläinen and M. Vinni, “Comparison of machine learning methods for estimating Energy Consumption in Buildings,” *Intell. Tutoring Syst.*, pp. 525–534, 2006.
- [29] J. D. Hobby and G. H. Tucci, “Analysis of the residential, commercial and industrial electricity consumption,” *2011 IEEE PES Innov. Smart Grid Technol.*, pp. 1–7, 2011.
- [30] R. Weron, *Modeling and forecasting electricity loads and prices: A statistical approach*. 2013.
- [31] L. Pedersen, *Load Modelling of Buildings in Mixed Energy Distribution Systems*, no. February. 2007.
- [32] C. S. D. E. Ingenier, “CONSUMO ELÉCTRICO A,” 2014.
- [33] A. C. Menezes, A. Cripps, R. A. Buswell, J. Wright, and D. Bouchlaghem, “Estimating the energy consumption and power demand of small power equipment in office buildings,” *Energy Build.*, vol. 75, pp. 199–209, 2014.
- [34] C. R. D. E. Colaboración, “EV-OPTI MANAGER EV Charging Manager optimization demand,” 2015.
- [35] J. J. Montaña, “Redes Neuronales Artificiales aplicadas al Análisis de Datos,” *Network*, p. 275, 2002.
- [36] J. P. Albaladejo, “Métodos de inferencia estadística con d tos faltantes . Estudio de simulación sobre los efectos en las estimaciones,” vol. 48, pp. 241–270, 2006.

7. Anexo I. Código de métodos de predicción

Método AR

```
% Cargamos las variables

clearvariables

data1=load('C_REE_1h_2007');
data2=load('C_REE_1h_2008');

n1=data1.Ct(2:end,5);
n2=data2.Ct(2:end,5);
demanda=cat(1, n1, n2);      %Cargamos todos los datos de demanda en un
vector

num_horas=size(demanda);    %Calculamos cuantas horas de datos hay
num_dias=num_horas(1,1)/(24); %Calculamos cuantos días de datos hay
num_sem=num_horas(1,1)/(24*7); %Calculamos cuantas semana de datos
hay

%*****
%*****
%% definición de periodos de predicción y de aprendizaje
%*****
%*****

n_horas=num_horas(1,1);
n_aux=1440;    % >1680 %momento de inicio de las predicciones dentro de
todo el vector de datos de demandas
n_pred=160;    %horas a predecir
n_h = (n_aux+1):(n_aux+n_pred);          % rango de horas a predecir

%*****
%*****
% Hacemos una predicción Naïve para otros métodos de comparación de
precisiones
```

```

%*****
*****

for d=60:(num_dias)
for h=((d*24)+1):((d*24)+24)
    naive_24(h,1)=demanda(h-24);
end
end

%*****
*****

%%Ahora descomponemos en componente estocástico y estacional
%*****
*****

L=demanda;
end_i=num_horas(1,1);
N=10; %semanas para la calibración
beg_i=(N+2)*168;
datal = end_i-beg_i+1;
stochc = zeros(datal,1);
perc = zeros(datal,1);
start = beg_i-1;
fori=1:datal
% seasonal (deterministic, periodic) component
demanda_seasonal(i,1) = mean(demanda(start+i-168:-168:start+i-N*168))
+ mean(demanda(start+i-24:-24:start+i-(24*7))) - mean(demanda(start+i-
168-24:-24:start+i-(N+1)*168));
% stochastic component
demanda_stochastic(i,1) = demanda(start+i)-demanda_seasonal(i);
end;

hh=0;

%*****
*****

%%Ahora calculamos el componente seasonal como combinación de los
anteriores

```

```

%*****
*****

n_horas=num_horas(1,1);

f1 = demanda_seasonal(n_h-48); %día anterior
for h=n_h
f2(h-1440,1) = mean(demanda_seasonal(h-48:-24:h-192)); %promediosemana
anterior
end
f3 = demanda_seasonal(n_h-192); %día tipo anterior
f4 = demanda_seasonal(n_h-24);

f0 = [f1 f2 f3];

fprintf(1,'Optimizando...') %Iniciamos la optimización

for h=n_h-1440

    f(:,1) = abs(f0(h,:) - f4(h)); %Función objetivo

Aeq=[1,1,1]; %Condiciones de contorno
beq=1;
lb=[0;0;0];
ub=[1;1;1];

options=optimset('display','off');

c=linprog(f, [], [], Aeq, beq, lb, ub, [], options); %optimizamos

c1=c(1,1); %generamos el vector de coeficientes
c2=c(2,1);
c3=c(3,1);
coeficientes(:,h)=c;

```

```

%*****
*****
%%Calculamos la componente seasonal de cada hora
%*****
*****

    prediccion_seasonal(h,1)=c1*demanda_seasonal(h+1440-
24)+c2*mean(demanda_seasonal(h+1440-24:-24:h+1440-
168))+c3*demanda_seasonal(h+1440-168); %calculamos la predicción
estacional

%*****
*****
%%calculamos la predicción estocastica con el método AR
%*****
*****

hh=hh+1;
    y=iddata(demanda_stochastic((h-(336*4):h-1)+1440,1)); %dos semanas
de aprendizaje para hacer el polinomio AR!

    na=4; %orden del polinomio del método AR
    n=1;

    m=ar(y,na);
coeff(hh,:) = polydata(m);
    Y_0(:,1) = demanda_stochastic((h-n:h-1)+1440,1);
prediccion_stochastic(h,1)=(-1)*sum(Y_0'.*coeff(hh,2:end));

end

fprintf(1,'Listo!\n')

%*****
*****
%%cálculo de la predicción total
%*****
*****

```

```

prediccion(h,1)=prediccion_seasonal(h,1) +
prediccion_stochastic(h,1);    %calculamos la predicci3n total

%*****
%*****
%%c3lculo del error total
%*****
%*****

error= prediccion(h,1)' - demanda(n_h);
rmse(1) = sqrt(nanmean(error(h,1).^2));

m = nanmean(demanda(n_h,1));
m(m==0) = 1;
nrmse(1) = rmse(1)./m;

%*****
%*****
%%c3lculo del error seasoal
%*****
%*****

error_seasonal= prediccion_seasonal(h,1)' - demanda_seasonal(n_h);
rmse_seasonal(1) = sqrt(nanmean(error_seasonal(h,1).^2));

m = nanmean(demanda_seasonal(n_h,1));
m(m==0) = 1;
nrmse_seasonal(1) = rmse_seasonal(1)./m;

%*****
%*****
%%c3lculo del error aleatorio
%*****
%*****

error_stochastic= prediccion_stochastic(h,1)' -
demanda_stochastic(n_h);
rmse_stochastic(1) = sqrt(nanmean(error_stochastic(h,1).^2));

```

```

m = abs(nanmean(demanda_stochastic(n_h,1)));
m(m==0) = 1;
nrmse_stochastic(1) = rmse_stochastic(1)./m;

```

Modelo de búsqueda de coeficientes

```

clearvariables
data1=load('C_REE_1h_2007');
data2=load('C_REE_1h_2008');

n1=data1.Ct(2:end,5);
n2=data2.Ct(2:end,5);
demanda=cat(1, n1, n2);

num_horas=size(demanda);
num_dias=num_horas(1,1)/(24);

d0=demanda;

% Metodo de coeficientes a lo largo de una semana

num_sem=num_horas(1,1)/(24*7);

for i=(1:num_sem);
    if i<2;
        dem_semanal(i,1)=sum(demanda(i:i*168));
    else
        dem_semanal(i,1)=sum(demanda((i-1)*168+1:i*168));
    end
end

prediccion1(1:55,1)=dem_semanal(1:55,1);
prediccion2(1:55,1)=dem_semanal(1:55,1);
prediccion3(1:55,1)=dem_semanal(1:55,1);

```



```

for i=(56:(num_sem-3));
    if i<57;
        q_01=dem_semanal(i-52,1);
        q_10=dem_semanal(i-1,1);
        q_11=dem_semanal(i-53,1);
        q_20=dem_semanal(i-2,1);
        q_21=dem_semanal(i-54,1);
        q_30=dem_semanal(i-3,1);
        q_31=dem_semanal(i-55,1);

        C_1=(q_10)/(q_11);
        C_2=(q_20)/(q_21);
        C_3=(q_30)/(q_31);
        C_123=(C_1+C_2+C_3)/3;

        Pred_1=C_123*(q_10);
        Pred_2=C_123*(q_20);
        Pred_3=C_123*(q_30);

        prediccion1(i,1)=Pred_1;
        prediccion2(i,1)=Pred_2;
        prediccion3(i,1)=Pred_3;

        Predicho1(i,1)=Pred_1;
        Predicho2(i,1)=Pred_2;
        Predicho3(i,1)=Pred_3;

    else
        %%Para la prediccion 1

        q_011=prediccion1(i-52,1);
        q_101=dem_semanal(i-1,1);
        q_111=dem_semanal(i-53,1);
        q_201=dem_semanal(i-2,1);
        q_211=dem_semanal(i-54,1);
        q_301=dem_semanal(i-3,1);
        q_311=dem_semanal(i-55,1);

```

```
C_11=(q_101)/(q_111);  
C_21=(q_201)/(q_211);  
C_31=(q_301)/(q_311);  
C_123_1=(C_11+C_21+C_31)/3;
```

```
Pred_1=C_123_1*(q_101);
```

```
prediccion1(i,1)=Pred_1;
```

```
Predicho1(i,1)=Pred_1;
```

```
%%Para la prediccion 2
```

```
q_012=prediccion2(i-52,1);  
q_102=dem_semanal(i-1,1);  
q_112=dem_semanal(i-53,1);  
q_202=dem_semanal(i-2,1);  
q_212=dem_semanal(i-54,1);  
q_302=dem_semanal(i-3,1);  
q_312=dem_semanal(i-55,1);
```

```
C_12=(q_102)/(q_112);  
C_22=(q_202)/(q_212);  
C_32=(q_302)/(q_312);  
C_123_2=(C_1+C_2+C_3)/3;
```

```
Pred_2=C_123_2*(q_202);
```

```
prediccion2(i,1)=Pred_2;
```

```
Predicho2(i,1)=Pred_2;
```

```
%% Para la prediccion 3
```

```
q_013=prediccion3(i-52,1);
q_103=dem_semanal(i-1,1);
q_113=dem_semanal(i-53,1);
q_203=dem_semanal(i-2,1);
q_213=dem_semanal(i-54,1);
q_303=dem_semanal(i-3,1);
q_313=dem_semanal(i-55,1);
```

```
C_13=(q_103)/(q_113);
C_23=(q_203)/(q_213);
C_33=(q_303)/(q_313);
C_123_3=(C_13+C_23+C_33)/3;
```

```
Pred_3=C_123_3*(q_303);
```

```
prediccion3(i,1)=Pred_3;
```

```
Predicho3(i,1)=Pred_3;
```

```
end
```

```
end
```

```
% Calculo del error para las tres predicciones
```

```
error_1 = Predicho1(56:101)-dem_semanal(56:101);
rmse_1 = sqrt(nanmean(error_1.^2));
m = nanmean(dem_semanal(56:101));
m(m==0) = 1;
nrmse_1 = rmse_1./m;
```

```
error_2 = Predicho2(56:101)-dem_semanal(56:101);
rmse_2 = sqrt(nanmean(error_2.^2));
m = nanmean(dem_semanal(56:101));
```

```

m(m==0) = 1;
nrmse_2 = rmse_2./m;

error_3 = Predicho3(56:101)-dem_semanal(56:101);
rmse_3 = sqrt(nanmean(error_3.^2));
m = nanmean(dem_semanal(56:101));
m(m==0) = 1;
nrmse_3 = rmse_3./m;

```

Método ARMA

```

clearvariables

data1=load('C_REE_1h_2007');
data2=load('C_REE_1h_2008');

n1=data1.Ct(2:end,5);
n2=data2.Ct(2:end,5);
demanda=cat(1, n1, n2);      %Cargamos todos los datos de demanda en un
vector

num_horas=size(demanda);    %Calculamos cuantas horas de datos hay
num_dias=num_horas(1,1)/(24); %Calculamos cuantos días de datos hay
num_sem=num_horas(1,1)/(24*7); %Calculamos cuantas semana de datos
hay

%Predicción Naïve
for d=60:(num_dias)
for h=((d*24)+1):((d*24)+24)
naive_24(h,1)=demanda(h-24);
end
end

```

```

%*****
*
%Ahora descomponemos en componente estocástico y estacional
%*****

L=demanda;
end_i=num_horas(1,1);
N=10; %semanas para la calibración
beg_i=(N+2)*168;
datal = end_i-beg_i+1;
stochc = zeros(datal,1);
perc = zeros(datal,1);
start = beg_i-1;
fori=1:datal
% seasonal (deterministic, periodic) component
demanda_seasonal(i,1) = mean(demanda(start+i-168:-168:start+i-N*168))
+ mean(demanda(start+i-24:-24:start+i-(24*7))) -
mean(demanda(start+i-168-24:-24:start+i-(N+1)*168));
% stochastic component
demanda_stochastic(i,1) = demanda(start+i)-demanda_seasonal(i);
end;

hh=0;

%Ahora calculamos el componente seasonal como combinación de los
%anteriores
n_horas=num_horas(1,1);

n_h = 1441:1600; %horas a predecir

f1 = demanda_seasonal(n_h-48); %día anterior
for h=n_h
f2(h-1440,1) = mean(demanda_seasonal(h-48:-24:h-192)); %promediosemana
anterior
end
f3 = demanda_seasonal(n_h-192); %día tipo anterior

```

```

f4 = demanda_seasonal(n_h-24);

f0 = [f1 f2 f3];

fprintf(1, 'Optimizando...')      %Iniciamos la optimización

for h=n_h-1440

    f(:,1) = abs(f0(h,:) - f4(h));      %Función objetivo

    Aeq=[1,1,1];      %Condiciones de contorno
    beq=1;
    lb=[0;0;0];
    ub=[1;1;1];

    options=optimset('display','off');

    c=linprog(f, [], [], Aeq, beq, lb, ub, [], options);      %optimizamos

    c1=c(1,1);      %generamos el vector de coeficientes
    c2=c(2,1);
    c3=c(3,1);
    coeficientes(:,h)=c;

    %Calculamos la componente seasonal de cada hora
    prediccion_seasonal(h)=c1*demanda_seasonal(h+1440-
24)+c2*mean(demanda_seasonal(h+1440-24:-24:h+1440-
168))+c3*demanda_seasonal(h+1440-168); %calculamos la predicción
estacional

    %calculamos la predicción estocastica con el método AR

    hh=hh+1;

```

```

%ordenes del polinomio del método ARMA
na=5;
nc=5;
orders= [nanc];
n=1;

y=iddata(demanda_stochastic((h-(336*4):h-1)+1440,1)); %dos semanas de
aprendizaje para hacer el polinomio ARMA!

m=armax(y,orders);
coeff(hh,:) = polydata(m);
Y_0(:,1) = demanda_stochastic((h-n:h-1)+1440,1);
prediccion_stochastic(h)=sum(Y_0'.*coeff(hh,2:end));

end

fprintf(1,'Listo!\n')

%cálculo de la predicción total
prediccion=prediccion_seasonal + prediccion_stochastic; %calculamos
la predicción total

%cálculo del error total
error= prediccion' - demanda(1441:1600);
rmse(1) = sqrt(nanmean(error(:).^2));

m = nanmean(demanda(n_h,1));
m(m==0) = 1;
nrmse(1) = rmse(1) ./m;

%cálculo del error seasoal
error_seasonal= prediccion_seasonal' - demanda_seasonal(1441:1600);
rmse_seasonal(1) = sqrt(nanmean(error_seasonal(:).^2));

m = nanmean(demanda_seasonal(1441:1600,1));
m(m==0) = 1;

```

```

nrmse_seasonal(1) = rmse_seasonal(1)./m;

%cálculo del error aleatorio
error_stochastic= prediccion_stochastic' -
demanda_stochastic(1441:1600);
rmse_stochastic(1) = sqrt(nanmean(error_stochastic(:).^2));

m = abs(nanmean(demanda_stochastic(1441:1600,1)));
m(m==0) = 1;
nrmse_stochastic(1) = rmse_stochastic(1)./m;

```

Método del día similar

```

Cargamos los datos para hacer pruebas
data1=load('C_REE_1h_2007'); %Cargamos el archivo
data2=load('C_REE_1h_2008'); %Cargamos el archivo

n1=data1.Ct(2:end,5); %Cogemos la fila de datos que nos
interesa
n2=data2.Ct(2:end,5); %Cogemos la fila de datos que nos
interesa
demanda=cat(1, n1, n2); %Cargamos todos los datos de demanda en un
vector

num_horas=size(demanda); %Calculamos cuantas horas de datos hay
num_dias=num_horas(1,1)/(24); %Calculamos cuantos días de datos hay
num_sem=num_horas(1,1)/(24*7); %Calculamos cuantas semanas de datos
hay

%*****
%*****
% definición de periodos de predicción y de aprendizaje
%*****
%*****

n_horas=num_horas(1,1);

```



```

n_aux=1500;    %momento de inicio de las predicciones dentro de todo el
vector de datos de demandas
n_aux_learning=1;    %siempre<= n_aux!!!(periodo de aprendizaje)
n_h = 10;    %número de horas a predecir
i_h = (1:n_h)+n_aux;    %indices de horas

%*****
%*****
% Hacemos una predicción Naïve para otros métodos de comparación de
precisiones
%*****
%*****

for d=60:(num_dias)
for h=((d*24)+1):((d*24)+24)
        naive_24(h,1)=demanda(h-24);
end
end

%*****
%*****
%% En la predicción de "similar day" no usaremos método alguno para
separar
%entre componente aleatorio y estacional: sólo hay un componente de la
%demanda
%*****
%*****

% Datos para la estimación de los coeficientes
f1 = demanda(i_h-48);    %día anterior
for h=i_h
f2(h-n_aux,1) = mean(demanda(h-48:-24:h-192)); %promediosemana
anterior
end
f3 = demanda(i_h-192);    %día tipo anterior
f4 = demanda(i_h-24);

```

```

f0 = [f1 f2 f3];

fprintf(1, 'Optimizando...')      %Para saber cuando empieza a optimizar

for h=i_h-n_aux

    f(:,1) = abs(f0(h,:)-f4(h));    %Función a optimizar

Aeq=[1,1,1];    %Condiciones de contorno
beq=1;
    lb=[0;0;0];
ub=[1;1;1];

options=optimset('display','off');    %Condiciones adicionales apra
optimizar. Esn este caso no se avisa de cada final de optimización

    c=linprog(f, [], [], Aeq, beq, lb, ub, [], options);    %OPTIMIZACIÓN

    c1=c(1,1);    %Cargamos los coeficientes resultado de la
optimización
    c2=c(2,1);
    c3=c(3,1);

    prediccion(h,1)=c1*demanda(h+n_aux-24)+c2*mean(demanda(h+n_aux-
24:-24:h+1440-168))+c3*demanda(h+n_aux-168); %calculamos la predicción
total aplicando el método de optimización de coeficientes en base al
día anterior

    coeficientes(:,h)=c;    %Acumulamos los coeficientes en la
matriz de coeficientes

end

fprintf(1, 'Listo!\n')    %Para saber cuando termina de optimizar

```

```
%cálculo del error de la predicción total optimizando coeficientes en
base al día anterior
```

```
error(:,1)= prediccion(:,1) - demanda(i_h,1);
rmse(1,1) = sqrt(nanmean(error(:,1).^2));
m = nanmean(demanda(i_h,1));
m(m==0) = 1;
nrmse(1,1) = rmse(1,1) ./m;
```

```
%*****
*****
```

```
% Ahora aplicamos el método de aprendizaje, usar el promedio de los
%coeficientes para un periodo posterior.
```

```
%*****
*****
```

```
hora_optimizada=0;
```

```
for z=i_h-n_aux
```

```
n_horas=num_horas(1,1);
```

```
n_h_learning = (n_aux-n_aux_learning+1):n_aux; %definición de periodo
de aprendizaje
```

```
%Aplicamos algo similar al método básico
```

```
% Datos para la estimación de los coeficientes
```

```
f1 = demanda(n_h_learning+z-48); %día anterior
```

```
for ii = 1:n_aux_learning
```

```
i=n_h_learning(ii)+z;
```

```
f2_aux(ii,1) = mean(demanda(i-48:-24:i-192)); %promedio semana
anterior
```

```
end
```

```
    f3 = demanda(n_h_learning+z-192); %díatipo anterior
```

```
    f4 = demanda(n_h_learning+z-24);
```

```
    f0_learning = [f1 f2_aux f3];
```

```

%datos para hacer la predicción (+24h)
    f11 = demanda(i_h(z)-24); %día anterior
    f22 = mean(demanda(i_h(z)-24:-24:i_h(z)-168)); %promedio semana
anterior
    f33 = demanda(i_h(z)-168); %día tipo anterior
    f00 = [f11 f22 f33];

fprintf(1, 'Optimizando segunda...') %Para saber cuando empieza a
optimizar

%f(:,1) = abs(f0_learning(:,1)-f4(:,1)); %Función a optimizar

for h=1:n_aux_learning

f(:,1) = abs(f0_learning(h,:) - f4(h,1)); %Función a optimizar

Aeq=[1,1,1]; %Condiciones de contorno
beq=1;
lb=[0;0;0];
ub=[1;1;1];

options=optimset('display','off'); %Condiciones adicionales para
optimizar. En este caso no se avisa de cada final de optimización

    c=linprog(f, [], [], Aeq, beq, lb, ub, [],
options); %OPTIMIZACIÓN

    c1=c(1,1); %Cargamos los coeficientes resultado de la
optimización
    c2=c(2,1);
    c3=c(3,1);

coeficientes_learning(:,h)=c; %Acumulamos los coeficientes en
la matriz de coeficientes

end

```

```

hora_optimizada=hora_optimizada+1
fprintf(1,'Listo segunda!\n')           %Para saber cuando termina de
optimizar

%cálculo de la predicción total método del período de aprendizaje

    peso0 = sum(coeficientes_learning,2);
    peso = peso0/sum(peso0);           %Cálculo del peso de cada coeficiente
pred(z,1) = f00*peso;                 %Calculo de la predicción
%pred(z,1) = peso(1,1)*demanda(h+n_aux-
24)+peso(2,1)*mean(demanda(h+n_aux-24:-24:h+1440-
168))+peso(3,1)*demanda(h+n_aux-168); %Calculo de la predicción

end

error_hb(:,1) = pred(:,1) - demanda(i_h,1);
rmse_hb(1,1) = sqrt(nanmean(error_hb(:,1).^2));
m = nanmean(demanda(i_h,1));
m(m==0) = 1;
nrmse_hb(1,1) = rmse_hb(1,1)./m;

```

8. Anexo II. Código del programa de cargas programables

El código del programa sigue los siguientes pasos:

- Lectura y adquisición de los datos de la hoja Excel.
- Detección del momento de encendido y el tiempo de uso de cada elemento.
- Añadir aleatoriedad al momento de encendido y tiempo de uso en función de las desviaciones introducidas.
- Construcción de una nueva matriz de consumos a partir de los datos obtenidos en el paso □.

```
clear all
clc
```

PASO 1: Lectura y adquisición de los datos de la hoja Excel.

```
%% Lectura de los datos de la hoja excel
```

```
sigma_hora=[xlsread('Curva consumo.xlsx', 'AB2:AB12')]
sigma_uso=[xlsread('Curva consumo.xlsx', 'AA2:AA12')]
potencia=[xlsread('Curva consumo.xlsx', 'Z2:Z12')]
datos=[xlsread('Curva consumo.xlsx', 'B2:Y12')]
```

```
%% Definir límites de tiempo
```

```
%Horas, 24*60 si son minutos
t_max = 24;
% Tiempo máximo de probabilidad de uso o hora de encendido
x=[0 t_max];
%Dimensión de la matriz de consumo
[elementos pasos_t]=size(datos);
%Paso de tiempo
dt = t_max/pasos_t;
%Eje de t, inicios: hora 1 empieza en t=0;
t = 0:dt:t_max-dt;
```

PASO 2: Detección del momento de encendido y el tiempo de uso de cada elemento, según se ha fijado en la tabla de equipos de dónde el programa lee los datos. Se obtiene como resultado del paso 2 dos matrices de datos, de cara a obtener cargas aleatorias.

Con ambas matrices, se tiene la media de encendido y duración respectivamente para cada elemento. Con estas medias y las desviaciones definidas según usuario final se podrá realizar la aleatoriedad de ambos tiempos. Dicha aleatoriedad se calcula en el paso 3.

%% Detector de la hora y la duración de encendido

```

%Recorre los elementos (filas) de la matriz de datos
for i_elemento=1:elementos
% Inicialización variables
dato_anterior=0;
n_encendidos(i_elemento)=0;
duracion=0;
%Recorre las horas/minutos (columnas) de la matriz de datos
for i_hora=1:pasos_t
%Búsqueda de elemento encendido
if datos(i_elemento, i_hora)==1
%Búsqueda de hora de encendido
if dato_anterior==0
%Incremento numero de encendidos
    n_encendidos(i_elemento)=n_encendidos(i_elemento)+1;
% Escribir las horas/minutos de encendido de cada elemento en la matriz hora_encendido
    hora_encendido(i_elemento,n_encendidos(i_elemento))=t(i_hora);
% Inicialización variable
    duracion =0;
end
% Detectado el encendido se aumenta en uno la horas/minutos de uso
    duracion=duracion+1;
% Detectado el encendido se marca esta variable por si se usa más de un paso de tiempo
(horas/minutos)
    dato_anterior=1;
% Última columna
if i_hora==pasos_t
% Escribir las horas/minutos de uso de cada elemento en la matriz duraciones
    duraciones(i_elemento,n_encendidos(i_elemento))=duracion;
end
% Detectado el encendido y si se ha encendido más de una vez
elseif (dato_anterior==1)&&(n_encendidos(i_elemento)>0)
% Escribir las horas/minutos de uso de cada elemento en la matriz duraciones
    duraciones(i_elemento,n_encendidos(i_elemento))=duracion;
% Reseteo variable
    dato_anterior=0;
end
end
%Duraciones en horas o minutos (depende dt)
dur_t = duraciones*dt;

```

PASO 3: Se añade aleatoriedad al momento de encendido y tiempo de uso en función de las desviaciones introducidas, es decir, de las posibles fluctuaciones en cuanto a los horarios de encendido de los distintos equipos de consumo de la vivienda

%% Aleatoriedad tiempo de uso

```

% Recorre cada columna de la matriz de encendidos
for encendido=1:n_encendidos(i_elemento)
% Para una desviación nula (particularmente uso del elemento durante todo el día)
if sigma_uso((i_elemento))==0
% No variación del tiempo de uso
    t_uso=dur_t(i_elemento,encendido);
else
% Definición de probabilidad de uso acotada por x (x10000 para suavizar curva)
    P_uso=10000*normcdf(x, dur_t(i_elemento,encendido), sigma_uso(i_elemento));
% Límite inferior de la probabilidad > 0%
    P0_uso = ceil(P_uso(1));
% Límite superior de la probabilidad < 100%
    P24_uso= floor(P_uso(2));
% Probabilidad aleatoria rescalada para los límites de tiempo establecidos
    P_uso = (P0_uso+ unidrnd(P24_uso-P0_uso))/10000;
% Obtención del nuevo tiempo de uso para la probabilidad aleatoria
    t_uso = norminv(P_uso,dur_t(i_elemento,encendido), sigma_uso(i_elemento));
end

```

%% Aleatoriedad hora de encendido

```

% Para una desviación nula (particularmente uso del elemento durante todo el día)
if sigma_hora((i_elemento))==0
% No variación de la hora/minutos de encendido
    t_hora=hora_encendido(i_elemento,encendido);
else
% Definición de probabilidad de uso acotada por x (x10000 para suavizar curva)
    P_hora=10000*normcdf(x, hora_encendido(i_elemento,encendido), sigma_hora(i_elemento));%
%límite inferior de la probabilidad > 0%
    P0_hora = ceil(P_hora(1));
%límite superior de la probabilidad < 100
    P24_hora= floor(P_hora(2));

% Obtención del nuevo tiempo de uso para la probabilidad aleatoria
    P_hora = (P0_hora+ unidrnd(P24_hora-P0_hora))/10000

% Probabilidad aleatoria rescalada para los límites de tiempo establecidos
    t_hora = norminv(P_hora,hora_encendido(i_elemento,encendido), sigma_hora(i_elemento));%
end

```

%% Tiempo de uso resultante a una hora dada

```

% Si con los nuevos tiempos se pasa de las horas/minutos del día
if (t_hora+t_uso) > t_max
%Escribir la nueva hora de encendido + tiempo de uso máximos en la matriz hora_uso
    hora_uso(i_elemento,encendido)= t_max;
else

```



```

% Escribir la nueva hora de encendido + el nuevo tiempo de uso en la matriz hora_uso. [(/dt)*dt]
evita que con el redondeo no salgan múltiplos del paso de tiempo
    hora_uso(i_elemento,encendido)=round((t_hora+t_uso)/dt)*dt;
end
% Escribir de la nueva hora de encendido en la matriz hora
    hora(i_elemento,encendido)=round(t_hora/dt)*dt;
% Escribir el nuevo tiempo de uso en la matriz uso
    uso(i_elemento,encendido)=round(t_uso/dt)*dt;
end
end

```

Como resultado, se obtiene una matriz nueva de horarios y tiempos de uso que da una nueva matriz de consumos a partir de los resultados de las nuevas matrices de horarios y tiempos, siendo esta la distribución de consumos deseada y más acorde para la reducción de consumos excesivos en horarios poco interesantes.

%% Reconstrucción de la nueva matriz de consumo

```

% Matriz de ceros de elementos x pasos_t
datos_nuevos=zeros(elementos,pasos_t);
% Recorre los elementos de la matriz hora
for i_elemento=1:elementos
% Para cada columna de la matriz se detecta si cuando se ha encendido un elemento
if n_encendidos(i_elemento)>0
for i_encendido=1:n_encendidos(i_elemento)
% Para cada nuevo encendido se mira cuanto ha estado encendido
for dur=1:uso(i_elemento,i_encendido)
% nueva definición del índice i_hora para reescribir la matriz
    i_hora = find(hora(i_elemento,i_encendido)==t);
% Reconstrucción de la nueva matriz
if i_hora + dur > t_max
consumo(i_elemento,i_hora:t_max)=potencia(i_elemento);
else
    consumo(i_elemento,i_hora:i_hora+dur)=potencia(i_elemento);
end
end
end
end
end

```

9. Anexo III. Metodologías para la recuperación de datos

Cuando se pretende trabajar con datos de cualquier tipo de tema, ya sea energético, estadísticos, laboral, etc. es necesario hacerlo con la mayor cantidad de datos posibles y con datos sin errores. Esto no siempre es posible debido a errores de medición, ocasionados por los equipos de medida o el personal encargado de estas tareas, o a la existencia de periodos son datos. Por esta razón es necesario el uso de técnicas para la recuperación de datos y obtener mejores resultados. En el caso de predicciones, es importante disponer de datos suficientes y representativos del fenómeno a representar para así tener una mejor estimación, de forma que las variaciones que se produzcan serán reflejadas en el futuro de manera correcta ajustándose más a la realidad.

En los siguientes apartados se comentan diversos métodos que empleados con una breve explicación.

Método de media consecutiva: Es un método más robusto que la media móvil ya que usa los valores próximos para el cálculo de la media, es simple y fácil de realizar. Sin embargo, este proceso no es óptimo cuando faltan muchos datos consecutivos ya que trabaja con los valores próximos para la realización de la media. Se puede utilizar la siguiente fórmula:

$$B_t = L_t^{\text{med}} \pm 3 * SD (L_t - L_t^{\text{med}})$$

Siendo L_t^{med} la media consecutiva de las cinco horas o días anteriores (paseos en general), SD es la desviación estándar y L_t la media de los datos originales.

Imputación mediante la media: A partir de una serie datos que presenta valores perdidos, mediante este método se reemplaza cada uno de ellos por la media de los valores observados. Aunque esta estrategia es sencilla y puede resultar intuitivamente satisfactoria, presenta un importante defecto y es que tiende a subestimar la variabilidad

real de la muestra al sustituir los faltantes por valores centrales de la distribución.[30][29][29][29][29]

Imputación mediante regresión: Es una manera de calcular la falta de valores que se tenga de manera más exacta pero mucho más compleja que las anteriores. Consiste en estimarla regresión de la variable a partir de los casos completos y se imputa cada valor perdido con la predicción dada por la ecuación de regresión estimada. Esto es:

$$X_i = \beta_0_{\text{obs}} + \sum \beta_j_{\text{obs}} * x_j$$

Donde β representa los coeficientes de regresión de x_i sobre x_j basado en los valores existentes completos.

Imputación mediante regresión estocástica: Al imputar mediante regresión se está reemplazando el valor perdido por una media condicionada, por lo que, como ocurre en el caso de imputación mediante la media se tiende sistemáticamente a subestimar la variabilidad. Una sencilla alternativa para atenuar este efecto consiste en añadir al valor predicho por la regresión una perturbación aleatoria, de forma que se obtiene una realización de la distribución predictiva de los valores perdidos condicionada a los valores observados.

$$X_i = \beta_0_{\text{obs}} + \sum \beta_j_{\text{obs}} * x_j + \varepsilon_i$$

Donde ε_i es próximo a σ^2 que es a su vez la varianza residual de la regresión de x_i sobre x_j .

Métodos basados en verosimilitudes: Es un método de los más versátiles que existen y que se puede aplicar para gran cantidad de situaciones con el fin de obtener el valor que se desconoce de alguno de los parámetros. Es una metodología más compleja que otras ya que no es una simple ecuación, sino que depende de los valores de los parámetros existentes que hacen que la probabilidad de obtener dicha muestra sea máxima.

Conclusión: De los diversos métodos comentados y existiendo más para hallar los valores desconocidos, un buen método por su sencillez, facilidad de empleo y precisión es el método de la media consecutiva, ya que se encuentra en un punto intermedio a otros métodos, es decir, se acerca al valor real buscado con un pequeño error y es un método fácil de utilizar debido a que no es excesivamente complejo.[36]

10. Anexo IV. Cálculo del error

El error absoluto es el método más común usado para la determinación de la precisión tenida en las mediciones. Es decir, aplicándolo al caso que confiere en este Trabajo Fin de Máster se determinará un error absoluto para cada predicción horaria / semanal. A partir del error absoluto, se puede obtener el porcentaje de error absoluto de forma que se puede determinar la cantidad de predicciones bien realizadas, este valor siempre es superior a cero.

Otro tipo de error aplicable es el error escalado o estacional cuando se usan series de datos que se encuentran escalados de forma distinta. Una característica buena de este tipo de error es que si uno de sus valores obtenidos es mejor que el promedio se aplica pero en cambio si es peor que el valor medio no lo emplea.

Uno de los errores más comúnmente conocidos es el error cuadrado, el cual se calcula como su propio nombre indica como resultado de la raíz cuadrada de la diferencia entre el predicho y el valor real. De forma que minimiza el fallo generado en la predicción.[30]

Para poder determinar cuál de todos los métodos anteriormente mencionados es mejor, se debe calcular el error de cada una de los procedimientos [32]. Los errores que se calculan son el error de predicción y el error normalizado a partir del error de predicción. Estos valores se calculan mediante la siguiente programación:

```
    % Calculo del error
for n=1:10
    error(:,n) = prediccion(11:num_sem,n)-dem_semanal(11:num_sem,1);
    rmse(n,1) = sqrt(nanmean(error(:,n).^2));
    m = nanmean(dem_semanal(11:num_sem));
    m(m==0) = 1;
    nrmse(n,1) = rmse(n,1)./m;
end
```

Cuando se trabaja con métodos algo más complejos como el método AR o ARMA, se deben calcular otros errores previos al cálculo del error de predicción y el error normalizado. En este caso, se hace esto para ver el error de las distintas partes de la predicción, ya que en estos métodos se hace una división en dos partes y eso supone dos predicciones distintas, así se sabe que parte es menos precisa. Se tratan de los errores estacionales y de los errores aleatorios para los cuales se realiza la siguiente programación:

```

%*****
%%cálculo del error seasoal
%*****
error_seasonal= prediccion_seasonal(h,1)' - demanda_seasonal(n_h);
rmse_seasonal(1) = sqrt(nanmean(error_seasonal(h,1).^2));

m = nanmean(demanda_seasonal(n_h,1));
m(m==0) = 1;
nrmse_seasonal(1) = rmse_seasonal(1)./m;

%*****
%%cálculo del error aleatorio
%*****

error_stochastic= prediccion_stochastic(h,1)' - demanda_stochastic(n_h);
rmse_stochastic(1) = sqrt(nanmean(error_stochastic(h,1).^2));

m = abs(nanmean(demanda_stochastic(n_h,1)));
m(m==0) = 1;
nrmse_stochastic(1) = rmse_stochastic(1)./m;

```

Una vez se obtienen estos dos errores para estos métodos se requiere del error total de predicción para posteriormente determinar el error normalizado. Para ello se realiza la siguiente programación:

```

%*****
%%cálculo de la predicción total
%*****

prediccion(h,1)=prediccion_seasonal(h,1) + prediccion_stochastic(h,1);

%*****
%%cálculo del error total
%*****

error= prediccion(h,1)' - demanda(n_h);
rmse(1) = sqrt(nanmean(error(h,1).^2));

m = nanmean(demanda(n_h,1));
m(m==0) = 1;
nrmse(1) = rmse(1)./m;

```