

UNIVERSIDAD AUTONOMA DE MADRID

ESCUELA POLITECNICA SUPERIOR



**Grado en Ingeniería de Tecnologías y Servicios de
Telecomunicación**

TRABAJO FIN DE GRADO

**Aplicación de Inteligencia Artificial para la predicción del
consumo de materiales en un despliegue FTTH a nivel nacional**

**Diego Alonso San Segundo
Tutor: Fernando Martín Canal
Ponente: Miguel Ángel García García**

MAYO 2019

Aplicación de Inteligencia Artificial para la predicción del consumo de materiales en un despliegue FTTH a nivel nacional

AUTOR: Diego Alonso San Segundo

TUTOR: Fernando Martín Canal

Dpto. Tecnología Electrónica y de las Comunicaciones

Escuela Politécnica Superior

Universidad Autónoma de Madrid

Mayo de 2019

Resumen (castellano)

Este Trabajo Fin de Grado presenta un estudio de la aplicación de IA en el forecasting de la demanda de determinados ítems en un despliegue FTTH a nivel nacional, con el fin de determinar cuáles serían los algoritmos óptimos para la predicción, utilizando como datos de entrada los valores reales de los últimos 4 años.

No todos los recursos tienen un consumo similar, o siguen un mismo patrón, por lo que habrá que estudiar el impacto de cada algoritmo para la predicción de los valores para cada ítem de manera individual. De este modo, una vez aplicados los algoritmos escogidos, en función de cómo se asemejen a los datos reales, se podrá crear un modelo personalizado para cada ítem, de tal manera que las predicciones para cada uno de estos ítems puedan ser predichas de manera óptima.

El objetivo de este trabajo es encontrar los mejores algoritmos para las predicciones de los ítems en cuestión, que produzcan mejores resultados que el método actual, que está basado en una media ajustada de los valores más recientes. Con un método mejor para la predicción de la demanda de los ítems, se podrían reducir costes y evitar la compra de material en exceso.

En resumen, la principal motivación de este estudio es encontrar un predictor que permita mejorar las operaciones financieras de la empresa. El método de estimación actual no incluye ningún tipo de IA, por lo que este trabajo intentará dar una respuesta a la siguiente pregunta: ¿Podría un modelo de predicción basado en IA sobrepasar a un método tradicional de predicción que no requiere de IA y que es calculado por personas?

Abstract (English)

This Bachelor Thesis introduces an study of the application of Artificial Intelligence to forecast the demand of stock for certain items used in a nationwide FTTH deployment, to determine which algorithms are the most efficient to do the forecasting, using real data from a telecommunications service provider from the last 4 years.

The values of the demand of every item are different, and they don't necessarily follow the same trend as any of the other items, so it will be useful to study the impact of every algorithm in the forecasting of every one of these items individually. This way, once the algorithms are applied, depending on how precise the forecaster can be, a customized model could be created for the forecasting of every single item, so every item can be forecasted in the optimal way possible.

This work's goal is to find the best algorithms for the forecasting of the items in question, to obtain better results than the ones that the current method provides, which is based on an adjusted mean using short term data. With a better way to forecast the demand of every item, costs can be reduced and overbuying can be avoided.

To sum up, the primary motivation in this study is to find a better predictor that could improve the financial operations of the company. The current estimation method does not include any kind of AI, so this work will try to answer the following question: Could an AI-based forecasting method surpass a traditional non-AI forecasting man-made method?

Palabras clave (castellano)

Predicción, predecir, Weka, Waikato, IA, Inteligencia Artificial, Aprendizaje Automático, despliegue de fibra, fibra óptica, despliegue FTTH, error absoluto medio, raíz del error cuadrático medio, red de alimentación, red de distribución, área bajo la curva, Java, NetBeans

Keywords (inglés)

Forecast, forecasting, time series, Weka, Waikato, AI, Artificial Intelligence, ML, Machine Learning, fiber, FTTH deployment, optical fiber, MAE, RMSE, MAPE, SMAPE, Java, NetBeans

Agradecimientos

Este Trabajo de Fin de Grado no habría sido posible sin la inestimable ayuda de mi tutor Fernando, cuyos consejos ayudaron a dar forma a este trabajo y a encontrar nuevas vías para avanzar.

También quiero darle las gracias al resto de mis compañeros de Everis, que me ayudaron a entender en profundidad cómo funciona el despliegue FTTH y la logística.

A mis padres, a mi hermano, y a mi abuela, que no permitieron que me rindiera a pesar de las dificultades.

A mis amigos, mi otra familia, que me ayudaron a desconectar y a comprender que lo malo también tiene un final.

A Miguel Ángel, por ofrecerse como ponente, al que le agradezco que me permitiera realizar este trabajo.

Y a mis profesores, por enseñarme gran parte de lo que sé.

Gracias a todos.

Diego

INDICE DE CONTENIDOS

1	Introducción.....	7
1.1	Motivación.....	7
1.2	Objetivos.....	7
1.3	Organización de la memoria.....	7
2	Estado del arte	8
2.1	Qué es la Inteligencia Artificial.....	8
2.2	Qué es el Machine Learning.....	8
2.3	Qué es un despliegue FTTH.....	9
3	Diseño.....	11
3.1	Weka 11	
3.1.1	Qué es Weka.....	11
3.1.2	Cómo funciona Weka.....	11
3.1.3	Ficheros ARFF.....	12
3.1.4	Algoritmos de Weka.....	14
4	Desarrollo	15
4.1	Ítem utilizado durante el estudio	15
4.2	Predicciones.....	15
4.2.1	Cómo se realizan las predicciones con Weka.....	15
4.3	Métodos de error.....	16
4.3.1	Introducción a los métodos de error	16
4.3.2	MAE	16
4.3.3	RMSE	16
4.3.4	MAPE.....	17
4.3.5	SMAPE.....	17
4.4	Otros criterios de evaluación	18
4.4.1	Diferencia	18
4.4.2	Área bajo la curva del error	18
4.5	Estudio preliminar	19
4.5.1	Predicciones de salida.....	19
4.5.2	Datos de entrada	22
5	Integración, pruebas y resultados	24
5.1	Pruebas y resultados con los métodos de error.....	24
5.2	Pruebas y resultados con la diferencia.....	30
5.3	Pruebas y resultados con el área bajo la curva	31
6	Conclusiones y trabajo futuro.....	35
6.1	Conclusiones.....	35
6.2	Trabajo futuro	35
	Referencias	37
	Glosario	39
	Anexos.....	- 1 -
A	Manual de instalación.....	- 1 -
B	Manual del programador	- 4 -
C	Anexo de Tablas Adicionales	- 6 -

INDICE DE FIGURAS

FIGURA 3-1: LOGO WEKA	11
FIGURA 4-1: REPRESENTACIÓN GRÁFICA DE LAS PREDICCIONES ACTUALES Y DE UN ALGORITMO DE WEKA FRENTE A LOS VALORES REALES DESDE LA SEMANA 1 A LA 8.	20
FIGURA 4-2: REPRESENTACIÓN GRÁFICA DE LAS PREDICCIONES ACTUALES Y DE UN ALGORITMO DE WEKA FRENTE A LOS VALORES REALES DESDE LA SEMANA 2 A LA 9.	20
FIGURA 4-3: REPRESENTACIÓN GRÁFICA DE LA DEMANDA REAL Y LAS PREDICCIONES DE UN ALGORITMO DE WEKA SUPERPUESTAS TRAS LA INTRODUCCIÓN DE NUEVAS INSTANCIAS.....	21
FIGURA 4-1: REPRESENTACIÓN GRÁFICA DE LOS DATOS REALES DE LA DEMANDA UTILIZADOS PARA EL ENTRENAMIENTO Y LAS FUTURAS INSTANCIAS.	22
FIGURA 4-2: REPRESENTACIÓN GRÁFICA DE LOS DATOS REALES DE ENTRADA UTILIZADOS PARA EL CABLE CB01, Y SUS DIFERENTES FORMAS AJUSTADAS DURANTE EL AÑO 2017.	23
FIGURA 5-1: REPRESENTACIÓN GRÁFICA DE LOS DATOS REALES FUTUROS FRENTE A LAS PREDICCIONES ACTUALES Y DEL ALGORITMO GAUSSIANPROCESSES PARA EL CABLE CB01, USANDO COMO INPUT LA CURVA AJUSTADA 2, DURANTE 2017 Y 2018.	31
FIGURA 5-2: REPRESENTACIÓN GRÁFICA DE LOS DATOS REALES FUTUROS FRENTE A LAS PREDICCIONES ACTUALES Y DEL ALGORITMO GAUSSIANPROCESSES PARA EL CABLE CB01, USANDO COMO INPUT LA CURVA AJUSTADA 1, DURANTE 2017 Y 2018.	32
FIGURA 5-3: REPRESENTACIÓN GRÁFICA DE LOS DATOS REALES FUTUROS FRENTE A LAS PREDICCIONES ACTUALES Y DEL ALGORITMO LINEARREGRESSION PARA EL CABLE CB01, USANDO COMO INPUT LA CURVA AJUSTADA 2, DURANTE 2017 Y 2018.	33
FIGURA 5-4: REPRESENTACIÓN GRÁFICA DE LAS DIFERENCIAS AL CUADRADO NORMALIZADAS DE LAS PREDICCIONES ACTUALES Y DEL ALGORITMO GAUSSIANPROCESSES RESPECTO AL PROMEDIO DE LOS VALORES REALES FUTUROS PARA EL CABLE CB01, USANDO COMO INPUT LA CURVA AJUSTADA 2, DURANTE 2017 Y 2018.	33
FIGURA 5-5: REPRESENTACIÓN GRÁFICA DE LAS DIFERENCIAS AL CUADRADO NORMALIZADAS DE LAS PREDICCIONES ACTUALES Y DEL ALGORITMO GAUSSIANPROCESSES RESPECTO AL PROMEDIO DE LOS VALORES REALES FUTUROS PARA EL CABLE CB01, USANDO COMO INPUT LA CURVA AJUSTADA 1, DURANTE 2017 Y 2018.	34
FIGURA A-1: VISTA WEB PARA LA DESCARGA DE NETBEANS EN SU PÁGINA WEB.....	- 1 -
FIGURA A-2: VISTA WEB PARA LA DESCARGA DE WEKA EN SU PÁGINA WEB.	- 2 -
FIGURA A-3: VISTA DEL FICHERO COMPRIMIDO DE LA VERSIÓN DE WEKA DESCARGADA.	- 2 -
FIGURA A-4: VISTA DE LA SECCIÓN PROPERTIES>LIBRARIES DEL PROYECTO DE NETBEANS.....	- 3 -

INDICE DE TABLAS

TABLA 4-1: DEMANDA REAL Y PREDICCIONES DEL CABLE CB01.....	19
TABLA 5-1: DEMANDA REAL DEL CABLE CB01 Y SUS PROMEDIOS A DOS, CUATRO Y OCHO SEMANAS.	24
TABLA 5-2: PREDICCIONES DEL MÉTODO ACTUAL PARA EL CABLE CB01 Y SUS PROMEDIOS A DOS, CUATRO Y OCHO SEMANAS.	25
TABLA 5-3: PREDICCIONES DEL ALGORITMO GAUSSIANPROCESSES PARA EL CABLE CB01 Y SUS PROMEDIOS A DOS, CUATRO Y OCHO SEMANAS.	25
TABLA 5-4: ERRORES MAE Y RMSE DEL ALGORITMO GAUSSIANPROCESSES PARA EL CABLE CB01.	26
TABLA 5-5: ERRORES MAPE Y SMAPE DEL ALGORITMO GAUSSIANPROCESSES PARA EL CABLE CB01.....	27
TABLA 5-6: COMPARATIVA DEL MAE_1 PARA EL CABLE CB01.	27
TABLA 5-7: COMPARATIVA DEL PROMEDIO DEL MAE_1 PARA EL CABLE CB01.	27
TABLA 5-8: COMPARATIVA DEL PROMEDIO DE LOS ERRORES PARA LAS MUESTRAS DE LA PRIMERA SEMANA DEL CABLE CB01.	28
TABLA 5-9: COMPARATIVA DEL PROMEDIO DE LOS ERRORES PARA LAS MUESTRAS DE LAS DOS PRIMERAS SEMANAS DEL CABLE CB01.....	28
TABLA 5-10: COMPARATIVA DEL PROMEDIO DE LOS ERRORES PARA LAS MUESTRAS DE LAS CUATRO PRIMERAS SEMANAS DEL CABLE CB01.....	29
TABLA 5-11: COMPARATIVA DEL PROMEDIO DE LOS ERRORES PARA LAS MUESTRAS DE LAS OCHO SEMANAS DEL CABLE CB01.....	29
TABLA 5-12: VALORES MEDIOS REALES Y DE LAS PREDICCIONES DEL CABLE CB01 PARA LOS CUATRO CONJUNTOS DE MUESTRAS Y TODOS LOS MÉTODOS DE PREDICCIÓN.	30
TABLA 5-13: PORCENTAJE DE DESVIACIÓN DE LOS VALORES MEDIOS DE LAS PREDICCIONES DEL CABLE CB01 PARA LOS CUATRO CONJUNTOS DE MUESTRAS Y TODOS LOS MÉTODOS DE PREDICCIÓN RESPECTO A LOS VALORES MEDIOS REALES.....	30
TABLA C-1: PREDICCIONES DE RANDOMFOREST PARA EL CABLE CB01.	- 6 -
TABLA C-2: PREDICCIONES DE SMOREG PARA EL CABLE CB01.....	- 7 -
TABLA C-3: PREDICCIONES DE REGRESSIONBYDISCRETIZATION PARA EL CABLE CB01.	- 7 -
TABLA C-4: PREDICCIONES DE ADDITIVEREGRESSION PARA EL CABLE CB01.	- 8 -
TABLA C-5: PREDICCIONES DE M5P PARA EL CABLE CB01.	- 8 -

TABLA C-6: PREDICCIONES DE LINEARREGRESSION PARA EL CABLE CB01.....	- 9 -
TABLA C-7: COMPARATIVA DEL MAE_2 PARA EL CABLE CB01.....	- 9 -
TABLA C-8: COMPARATIVA DEL MAE_4 PARA EL CABLE CB01.....	- 10 -
TABLA C-9: COMPARATIVA DEL MAE_8 PARA EL CABLE CB01.....	- 10 -
TABLA C-10: PRIMERA PARTE DE LA COMPARATIVA DEL RMSE_1 PARA EL CABLE CB01.....	- 11 -
TABLA C-11: SEGUNDA PARTE DE LA COMPARATIVA DEL RMSE_1 PARA EL CABLE CB01.....	- 11 -
TABLA C-12: PRIMERA PARTE DE LA COMPARATIVA DEL RMSE_2 PARA EL CABLE CB01.....	- 12 -
TABLA C-13: SEGUNDA PARTE DE LA COMPARATIVA DEL RMSE_2 PARA EL CABLE CB01.....	- 12 -
TABLA C-14: PRIMERA PARTE DE LA COMPARATIVA DEL RMSE_4 PARA EL CABLE CB01.....	- 13 -
TABLA C-15: SEGUNDA PARTE DE LA COMPARATIVA DEL RMSE_4 PARA EL CABLE CB01.....	- 13 -
TABLA C-16: PRIMERA PARTE DE LA COMPARATIVA DEL RMSE_8 PARA EL CABLE CB01.....	- 14 -
TABLA C-17: SEGUNDA PARTE DE LA COMPARATIVA DEL RMSE_8 PARA EL CABLE CB01.....	- 14 -
TABLA C-18: COMPARATIVA DEL MAPE_1 PARA EL CABLE CB01.	- 15 -
TABLA C-19: COMPARATIVA DEL MAPE_2 PARA EL CABLE CB01.	- 15 -
TABLA C-20: COMPARATIVA DEL MAPE_4 PARA EL CABLE CB01.	- 16 -
TABLA C-21: COMPARATIVA DEL MAPE_8 PARA EL CABLE CB01.	- 16 -
TABLA C-22: COMPARATIVA DEL SMAPE_1 PARA EL CABLE CB01.	- 17 -
TABLA C-23: COMPARATIVA DEL SMAPE_2 PARA EL CABLE CB01.	- 17 -
TABLA C-24: COMPARATIVA DEL SMAPE_4 PARA EL CABLE CB01.	- 18 -
TABLA C-25: COMPARATIVA DEL SMAPE_8 PARA EL CABLE CB01.	- 18 -
TABLA C-26: DATOS DE LA GRÁFICA DE LA FIGURA 5-1.....	- 19 -
TABLA C-27: DATOS DE LA GRÁFICA DE LA FIGURA 5-2.....	- 20 -
TABLA C-28: DATOS DE LA GRÁFICA DE LA FIGURA 5-3.....	- 22 -
TABLA C-29: PRIMERA PARTE DE LOS DATOS USADOS PARA LA REPRESENTACIÓN Y EL CÁLCULO DEL ÁREA BAJO LA CURVA Y LAS DIFERENCIAS AL CUADRADO ENTRE LAS PREDICCIONES ACTUALES Y DE GAUSSIANPROCESSES RESPECTO A LA DEMANDA REAL PARA EL CABLE CB01, USANDO EL INPUT AJUSTADO 2 DURANTE 2017 Y 2018.....	- 23 -

TABLA C-30: SEGUNDA PARTE DE LOS DATOS USADOS PARA LA REPRESENTACIÓN Y EL CÁLCULO DEL ÁREA BAJO LA CURVA Y LAS DIFERENCIAS AL CUADRADO ENTRE LAS PREDICCIONES ACTUALES Y DE GAUSSIANPROCESSES RESPECTO A LA DEMANDA REAL PARA EL CABLE CB01, USANDO EL INPUT AJUSTADO 2 DURANTE 2017 Y 2018..... - 24 -

TABLA C-31: PRIMERA PARTE DE LOS DATOS USADOS PARA EL CÁLCULO DEL ÁREA BAJO LA CURVA Y LAS DIFERENCIAS AL CUADRADO ENTRE LAS PREDICCIONES ACTUALES Y DE GAUSSIANPROCESSES RESPECTO A LA DEMANDA REAL PARA EL CABLE CB01, USANDO EL INPUT AJUSTADO 1 DURANTE 2017 Y 2018..... - 26 -

TABLA C-32: SEGUNDA PARTE DE LOS DATOS USADOS PARA EL CÁLCULO DEL ÁREA BAJO LA CURVA Y LAS DIFERENCIAS AL CUADRADO ENTRE LAS PREDICCIONES ACTUALES Y DE GAUSSIANPROCESSES RESPECTO A LA DEMANDA REAL PARA EL CABLE CB01, USANDO EL INPUT AJUSTADO 1 DURANTE 2017 Y 2018..... - 27 -

1 Introducción

1.1 Motivación

Esta memoria de TFG muestra el estudio de la aplicación de algoritmos de IA para las predicciones de la demanda de ítems utilizados en un despliegue FTTH a nivel nacional. El uso de esta tecnología para la predicción de la demanda permite dar alternativas al desarrollo humano del seguimiento y estimación de ítems en dicho despliegue, además de comprobar el impacto de esta tecnología para esta función, su precisión, y sus posibilidades a la hora de implementarlo en otras tareas similares.

La razón principal por la que se decidió realizar el estudio fue para comprobar su efecto en la labor de predicción, y además, incorporar alguna tecnología con IA que pudiera ahorrar trabajo manual, para concentrar ese tiempo ahorrado en otras tareas en las que no fuera posible una implementación parcial o total de IA.

1.2 Objetivos

El objetivo de este Trabajo de Fin de Grado es comprobar si esa alternativa es viable y hasta qué punto puede mejorar la calidad de las predicciones, con el fin de evitar sobrecostes, tanto en el proceso de compra como en el alquiler de espacio de almacenaje de los ítems usados en el despliegue, y de evitar lo que se conoce como roturas de stock, es decir, no estimar por debajo de la cantidad real con el fin de prevenir una compra de material antes de tiempo. Estas compras de material se realizan cada cierto tiempo, y permiten mantener un stock suficiente para un periodo aproximado de 15 semanas.

1.3 Organización de la memoria

La memoria consta de los siguientes capítulos:

- Estado del arte: en este capítulo se hablará de la Inteligencia Artificial, el Machine Learning, y se explicará con detalle en qué consiste un despliegue FTTH, así como las partes de la red por las que se tienden los cables de fibra.
- Diseño: se habla de la librería Weka, de cómo funciona y cómo se debe usar para realizar las predicciones.
- Desarrollo: en este apartado se verá cómo Weka calcula las predicciones con los datos, y se hablará de todos los criterios de evaluación utilizados en el estudio para comprobar la eficacia de cada uno de los métodos de predicción. También se tratará el pre-procesado de los datos de entrada.
- Integración, pruebas y desarrollo: pruebas y datos para presentar el veredicto.
- Conclusiones y trabajo futuro: veredicto final y posibles salidas.

2 Estado del arte

2.1 Qué es la Inteligencia Artificial

La Inteligencia Artificial (IA) es la combinación de algoritmos planteados con el propósito de crear máquinas que presenten las mismas capacidades que el ser humano.

La IA es una tecnología presente en la vida cotidiana, desde teléfonos inteligentes, hasta sistemas de tráfico automatizados, detección facial, de voz, de patrones, o sistemas de recomendación. En las próximas décadas, combinada con el uso del ‘big data’, será la tecnología sobre la que se cimentará la sociedad.

En su libro “Artificial Intelligence: A Modern Approach” [1], Stuart J. Russell y Peter Norvig determinan que se pueden distinguir cuatro tipos de sistemas de IA:

- Sistemas que piensan como humanos: aquellos sistemas implicados en tomas de decisiones y razonamientos lógicos, tales como resolución de problemas, i.e. redes neuronales artificiales.
- Sistemas que actúan como humanos: aquellos capaces de realizar tareas o acciones, que son realizadas por personas, que requieren de inteligencia, i.e. robots.
- Sistemas que piensan racionalmente: aquellos que intentan emular el proceso del pensamiento humano, i.e. sistemas expertos.
- Sistemas que actúan racionalmente: aquellos que tratan de imitar el comportamiento humano de una manera racional, i.e. agentes inteligentes.

Además, recalcan el hecho de que la distinción entre comportamiento humano y racional no sugiere una necesaria irracionalidad o inestabilidad mental o emocional del ser humano, sino que tiene como fin reconocer la imperfección humana y la tendencia a cometer errores sistemáticamente.

2.2 Qué es el Machine Learning

Es un subcampo de las ciencias de la computación y pertenece al ámbito de la Inteligencia Artificial [2], y tiene como objetivo el aprendizaje autónomo basado en observaciones y análisis de patrones en un set de datos sin ninguna regla de programación explícitamente impuesta, de tal manera que la máquina (un ordenador) aprende a tomar decisiones gracias al análisis de unos datos de entrada, que funcionan en forma de ejemplo con el fin de que la máquina cree sus propias reglas y criterios (árboles de decisión, reglas de asociación, algoritmos de agrupamiento, etc).

La IA y el Machine Learning permiten un análisis en profundidad de un conjunto de datos que no podría ser analizado por una persona con el mismo nivel de eficiencia dado que los algoritmos buscan relaciones que a simple vista una persona podría no encontrar, o para lo cual debería emplear una cantidad desproporcionada de tiempo. La IA y el Machine Learning pueden reducir esa cantidad de tiempo significativamente, e incluso determinar qué datos podrían ser excluidos del conjunto para evitar redundancia, exceso de linealidad, y otros factores que podrían empeorar las predicciones del ‘forecaster’. El Machine Learning,

como se menciona anteriormente, supone un aprendizaje por parte de la máquina, y esto se observa al proporcionar nuevos datos de entrada.

2.3 Qué es un despliegue FTTH

Las siglas FTTH se refieren a “Fiber-to-the-home”, que significa “fibra hasta el hogar”. Esta tecnología se basa en el uso de cableado de fibra óptica a través de unos sistemas de distribución desde una central de un operador de telecomunicaciones hasta el interior de un hogar.

El uso de las redes de fibra óptica permite alcanzar velocidades de acceso a Internet del orden de gigabits por segundo [3]. Cada operador o proveedor ofrece distintas velocidades a los clientes, con precios variables, siendo más caras las velocidades más altas.

Para entender cómo se realiza un despliegue FTTH se deben conocer dos conceptos importantes: la red de alimentación y la red de distribución. El primero de estos conceptos, la de red de alimentación, a la que llamaremos RA, forma la red que tiene como origen la central del operador, y que se ramifica llegando a distintos barrios de una ciudad. El segundo, la red de distribución, abreviada como RD, se trata de la unión entre la RA y los hogares, de tal manera que el cableado de la red de distribución entra en un edificio determinado para así llevar la conexión hasta cada uno de los hogares.

La red más simple es la conocida como “fibra directa” [3], en la cual una fibra sale de la central hasta cada domicilio, pero lo habitual es que una fibra se ramifique y sea utilizada por un conjunto de domicilios/viviendas, produciéndose esta separación en las proximidades de la zona que se quiere alimentar. Para que se produzca el caso de “fibra directa”, la instalación debe pertenecer al operador que el usuario haya contratado y, de ser una infraestructura alquilada, se trata de “fibra indirecta” [4].

En España, Telefónica posee la mayor red de fibra y acceso a Internet, bajo la marca Movistar para la oferta de esos servicios, por lo que es común que el resto de operadores alquile alguna zona de su red para proveer servicios. A pesar de esto, otros operadores, como Orange, Vodafone y MásMóvil (ordenados de mayor a menor según el tamaño de sus redes) también poseen redes propias. El año pasado, en 2018, el portal web ADSLZone [5] cifró la cantidad de unidades inmobiliarias (en siglas UUIs) de estos operadores, siendo Movistar el poseedor del mayor número de UUIs en el territorio español. Las cifras son las siguientes:

- Movistar: 19.7 millones de UUIs, con el objetivo de alcanzar los 25 millones en 2020.
- Orange: 12.2 millones de UUIs, con el objetivo de lograr estar presente en 26 millones de hogares en la misma fecha.
- Vodafone: más de 10 millones de UUIs (el operador no presentó cifras exactas).
- MásMóvil: más de 2.1 millones de UUIs en el momento de redactar el artículo, con el objetivo de tener más de 5 millones de UUIs para el final del año 2018.

En este artículo también se menciona que gracias a las redes de Movistar y Orange, España posee las dos redes de fibra más grandes de Europa, habiendo estado en el puesto 14 en despliegue de cifra a nivel europeo tan sólo 10 años antes, en 2008.

Actualmente, la mayoría de obras que se realizan comprenden construcción y/o ampliación de la RD, ya que la infraestructura de RA lleva construyéndose durante muchos años, y se puede decir que ya está presente en la mayoría de barrios. La construcción de RD, sigue produciéndose, aunque cada día se aproxima más a su fin. A pesar de ello, siguen surgiendo nuevas construcciones, esto es debido a que, como la RD entra en los edificios para llevar la fibra hasta el hogar, una red de distribución puede atravesar edificios cercanos para alimentar a varios bloques de la zona y, para ello, es necesario reunir los permisos pertinentes para aprobar su construcción, permisos que en algunas ocasiones no son concedidos a la primera, por lo que la construcción de RD se hace en varias fases, que pueden estar separadas por meses y/o años. Por ejemplo, si en un edificio no se permite el paso del cableado de una red de distribución, porque los propietarios no lo permiten, con el objetivo de alimentar a un edificio cercano, deberá realizarse otra obra con el fin de construir una nueva RD que lleve la fibra hasta esos hogares desde otro punto de la red de alimentación. Además, la creación de nuevas zonas residenciales también implica construcciones de RD.

3 Diseño

3.1 Weka

3.1.1 Qué es Weka

Weka es un acrónimo formado por Waikato Environment for Knowledge Analysis, conocido en castellano como “Entorno para Análisis del Conocimiento de la Universidad de Waikato”.



Figura 3-1: Logo Weka

Weka [6] es un software desarrollado por miembros de la Universidad de Waikato, situada en Nueva Zelanda, que conforma una colección de algoritmos y técnicas de Machine Learning implementada en Java y de código abierto. Sus principales funcionalidades se aplican en tareas de minería de datos, clasificación, regresión, y clustering entre otras cosas.

Weka, a su vez, hace alusión a un ave que habita únicamente en las islas de Nueva Zelanda, llamado Gallirallus australis [7], y que presenta una alta probabilidad de convertirse en “especie en peligro de extinción” según la Comisión de Supervivencia de Especies de la UICN.

Los objetivos del proyecto Weka son los siguientes [8]:

- Hacer que las técnicas de Machine Learning sean accesibles.
- Aplicar esas técnicas para resolver problemas prácticos que repercutan en la industria neozelandesa.
- Desarrollar nuevos algoritmos de Machine Learning y entregárselos al mundo.
- Contribuir al entorno de trabajo teórico de este campo.

3.1.2 Cómo funciona Weka

La librería Weka es capaz de crear un modelo a partir de unos datos de entrada. Este modelo viene determinado por el propio código de la librería cuando se selecciona el algoritmo deseado, pero puede ser “parametrizado” con algunas funciones en el código, que alteran en cierto nivel cómo tiene que tratar los datos, como el peso o la importancia de algunos de ellos en función del período en el que se encuentran (meses, trimestres, años), para así ajustar las predicciones y que los resultados no se desvíen en exceso del resultado que debería esperarse.

Tras seleccionar un algoritmo de la colección, el forecaster interpretará los datos de entrada, realizará los cálculos internos necesarios y devolverá las predicciones. Cada algoritmo tiene sus propias reglas y métodos para calcular estos valores de salida. Los datos de entrada deben seguir un formato específico para su correcta lectura, y deben estar escritos en un fichero de texto llamado fichero ARFF.

3.1.3 Ficheros ARFF

Los ficheros utilizados por la librería Weka utilizan la terminación “.arff” [9]. Estos ficheros tienen una estructura fija que utiliza Weka para el ‘input’ de los datos previo a la creación del modelo de forecasting, conocido como ‘forecaster’. Este fichero ARFF consta de una cabecera y una sección de datos. En la cabecera, se puede nombrar la relación de los datos (sería un título), la cual se declara como “relation”, y la cadena utilizada como nombre para la relación deberá ir entre comillas si dicho nombre contiene espacios.

Formato: @relation <nombre-de-la-relacion>

Ejemplo: @relation “datos de demanda”

A continuación, también dentro de la cabecera, la declaración de los atributos, que serían las declaraciones de los datos de entrada para la creación del forecaster, utilizando la palabra clave ‘attribute’.

Estos atributos pueden ser de 4 tipos:

- Tipo ‘numeric’ (numérico): números enteros, decimales, coma flotante, etc.
- Tipo ‘string’ (cadena de texto): en caso de ser varias palabras, deberán ir entre comillas.
- Tipo ‘nominal’ (un nombre): un valor de una lista de valores.
- Tipo ‘date’ (fecha): se puede especificar el formato de la fecha.

Formato: @attribute <nombre-del-atributo> <tipo>

Ejemplo: @attribute lluvia numeric

En el caso de ser de tipo nominal, no se utilizará la palabra nominal, dado que es un tipo especial, y habrá que indicar entre llaves cada uno de los valores que podrá adoptar dicho atributo como si de una lista se tratara, separadas por comas (y entre comillas simples en caso de contener espacios). Los valores declarados serán los únicos aceptados para ese atributo.

La declaración será la siguiente:

Formato: @attribute <nombre-del-atributo> {valor1, valor2, valor3,...}

Ejemplo: @attribute color_ojos {azul-claro, azul-oscuro, gris, marron, verde}

Cabe decir que, en la sección reservada para los datos, es necesario que estos tengan el formato establecido en el apartado ‘attribute’, dado que el algoritmo interpretará cada uno de ellos como se establece en la declaración de los mismos y, si no concuerda con el tipo, el algoritmo no podrá realizar la predicción.

En el caso de que un dato sea un número decimal, deberá utilizarse un punto como separador decimal, dado que la coma es el separador de atributos en la sección de datos.

Las palabras clave ‘relation’, ‘attribute’ y ‘data’ serán precedidas siempre por el símbolo ‘@’, para denotar que son secciones diferenciadas.

En el caso de ser un atributo de tipo fecha, se puede indicar el formato de esta, aunque Weka acepta por defecto el estándar ISO-8601, que combina fecha y hora (“yyyy-MM-dd HH:mm:ss”).

Existe un comodín para denotar que no se conoce el valor de un dato, y se representa con el símbolo ‘?’. Sirve para cualquier tipo de atributo, incluyendo el de tipo nominal, que acepta este símbolo como excepción a su lista de valores previamente declarada en la cabecera del fichero.

La última sección del fichero ARFF será la compuesta por los datos para el modelo. La sección comenzará con la instrucción “@data”, y los datos estarán escritos bajo esa línea del fichero, a diferencia de los atributos y la relación, que se indica tras la palabra clave de respectivas secciones. Cada una de las líneas de datos se denomina instancia, y en ellas estarán los valores de cada atributo declarado y separados por comas. El fin de una instancia está marcado por el salto de línea, por lo que en cada línea se representará una muestra de cada atributo, usando tantas líneas como muestras se quieran introducir en el modelo. Cada uno de los valores de la instancia deberá ser del tipo correspondiente al de su declaración, y se interpretarán con el mismo orden en el que se hayan declarado los atributos en la sección “@attribute”. Como se mencionaba anteriormente, si el valor de algún atributo es desconocido se utilizará el símbolo ‘?’ (sin las comillas), dado que debe haber el mismo número de valores por instancia que atributos declarados, a pesar de desconocer el valor de alguno de ellos en alguna de las instancias.

Un ejemplo de un fichero ARFF sería así:

```
@relation pronostico-lluvia

@attribute litros_m2 numeric
@attribute tiempo {soleado, nublado, lluvioso}
@attribute fecha date 'yyyy-MM-dd'

@data
0.0002,nublado,2019-03-15
0,soleado,2019-03-16
2.2,lluvioso,2019-03-17
0,?,2019-03-18
.
.
.
0.0013,nublado,2019-06-10
```

3.1.4 Algoritmos de Weka

Weka es una herramienta muy completa que posee una gran cantidad de algoritmos, pero no todos ellos permiten un forecasting numérico, ya que algunos de estos algoritmos únicamente proporcionan predicciones binarias (“Sí” o “No”), además de otros que requieren que los datos base sean de un tipo determinado (numérico, cadenas de texto, nominales, etc). Para este estudio, todos los datos numéricos son iguales o mayor que cero para cada una de las referencias, además del último campo necesario, que es la fecha del consumo.

Los algoritmos utilizados en este trabajo fueron seleccionados “a priori” en función de su capacidad para predecir resultados, es decir, tras realizar numerosas pruebas con los diversos algoritmos implementados en la librería Weka, solo aquellos capaces de predecir muestras futuras en función de los datos de origen fueron estudiados en la primera fase.

Los algoritmos utilizados en este estudio son los siguientes [10]:

- GaussianProcesses
- RandomForest
- SMOreg
- RegressionByDiscretization
- AdditiveRegression
- M5P
- LinearRegression

4 Desarrollo

4.1 Ítem utilizado durante el estudio

Debido a que debe ser mantenido un nivel de confidencialidad, no se hablará del componente utilizado como objetivo de las predicciones con su verdadero nombre.

Este cable pertenece al despliegue de fibra a nivel nacional de un operador de telecomunicaciones y es empleado en la red de distribución. A lo largo del estudio será referido como CB01 (cable 1) y los datos presentados de demanda son los datos reales proporcionados por el equipo de logística.

Asimismo, manteniendo esa confidencialidad, la fórmula del método actual de predicción no será revelada pero se garantiza que es un promedio modificado bajo criterios desconocidos.

4.2 Predicciones

4.2.1 Cómo se realizan las predicciones con Weka

En capítulos anteriores se ha mencionado la estructura de los ficheros ARFF, utilizados para la lectura de los datos de entrada. Estos datos son los que interpreta la librería Weka en Java para la construcción del modelo de forecasting, ‘llamado forecaster’, como se vio anteriormente.

Weka utiliza algoritmos de IA para la minería de datos, de la que extrae la información necesaria para establecer los pesos a cada uno de los valores de ese conjunto de datos. Este proceso se realiza con aprendizaje no supervisado, es decir, cada algoritmo decide por sí mismo qué peso tendrá cada dato en función del análisis de los datos de entrada, y las predicciones que realiza son predicciones “a ciegas” basadas en los criterios que establece tras ese procesamiento de los datos y la creación del modelo de forecasting.

Al realizar una predicción utilizando N instancias (cada una de las líneas de datos del fichero ARFF, véase el 3.1.3) determinará que la primera muestra de las predicciones, llamada muestra p , al conjunto de datos tendrá un valor ‘ x ’ y la posterior ($p+1$) un valor ‘ y ’. Cuanto mayor sea el número de instancias utilizadas en el entrenamiento, mayor será el número de ejemplos que puede observar el algoritmo. De esta manera, la selección de pesos será diferente, y teóricamente más precisa, dado que el procesado de los datos será más rico y se adaptará a nuevas situaciones.

Si a continuación se utilizan $N+1$ instancias, se tendrá el valor conocido de la muestra que previamente se predijo, la muestra p , y en la próxima predicción, el valor de la muestra $p+1$ podrá ser diferente gracias al nuevo input. Es posible que el valor de la predicción para esa muestra no cambie pero esto no implica que el modelo no sea correcto sino que, tras el procesado de las $N+1$ instancias, las reglas utilizadas para la asignación de los pesos y la asociación de los datos puede no haber variado lo suficiente como para que el valor predicho para la anteriormente denominada muestra $p+1$ sea distinto.

En términos generales, un mayor número de muestras implica una resolución mayor pero, por ejemplo, en los casos de clasificación, esto podría producir el fenómeno conocido como “overfitting”, también conocido como sobreentrenamiento. Esto se traduce como un

exceso de ejemplos en el set de datos de entrada, por lo que, tras la creación del modelo, al recibir un nuevo dato desconocido, la predicción estará tan ajustada que el valor predicho puede ser completamente dispar al valor real. En el estudio de forecasting no se da este suceso, dado que son muestras espaciadas en el tiempo y que siguen una estructura temporal lineal.

4.3 Métodos de error

4.3.1 Introducción a los métodos de error

Uno de los criterios para evaluar el rendimiento de los algoritmos a la hora de realizar las predicciones será la comparación de los distintos métodos de error que se presentarán a continuación. El equipo de la Universidad de Waikato propone varios métodos de error [11]:

- MAE (Mean Absolute Error): Error Absoluto Medio
- MSE (Mean Squared Error): Error Cuadrático Medio
- RMSE (Root Mean Square Error): Raíz Cuadrada del Error Cuadrático Medio
- MAPE (Mean Absolute Percentage Error): Error Porcentual Absoluto Medio
- DAC (Direction Accuracy): Precisión de la Dirección
- RAE (Relative Absolute Error): Error Absoluto Relativo
- RRSE (Root Relative Square Error): Raíz Cuadrada del Error Cuadrático Relativo

Algunos de los métodos anteriormente mencionados serán los que se verán más adelante, además de otro método de error, el SMAPE (Symmetric Mean Absolute Percentage Error).

4.3.2 MAE

También se lo conoce como MAD (Mean Absolute Deviation) [12] que se traduce como Desviación Absoluta Media, y es la medida de la diferencia entre dos variables continuas, que representan el mismo fenómeno, por ejemplo, una de ellas representaría el observado y otra la predicción de este.

$$MAE = \frac{1}{n} \times \sum_{i=1}^n |p_i - r_i|$$

Siendo p_i el valor de la predicción y r_i el valor real en el instante i . Dado que todos los valores serán igual o mayores que cero, el orden de la resta se podría invertir y sería el mismo resultado.

Este error es el más fácil de interpretar ya que es una operación muy sencilla.

4.3.3 RMSE

También conocido como RMSD (la D corresponde a desviación), es la raíz del error cuadrático medio. Se trata de la desviación estándar de los residuos [13], los cuales corresponden a las distancias verticales entre los puntos de las predicciones y la línea de

regresión. De esta manera, cada punto tiene su residuo (positivo si está por encima de la línea, negativo si se encuentra debajo de esta).

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (p_i - r_i)^2}$$

Siendo p_i el valor de la predicción y r_i el valor real en el instante i , este error es la raíz cuadrada de la media de los errores al cuadrado. Siempre será mayor o igual que cero (si fuera equivalente a cero significaría que no hay error), aunque esto último no es muy frecuente.

4.3.4 MAPE

Hace referencia al Error Porcentual Absoluto Medio [14], y es una medida de error que se utiliza como función de pérdida en problema de regresión en Machine Learning, y representa la precisión de forma porcentual.

$$MAPE = \frac{100\%}{n} \times \sum_{i=1}^n \left| \frac{r_i - p_i}{r_i} \right|$$

La diferencia entre el valor real r_i y el valor predicho p_i se divide por el real. Su valor absoluto es sumado junto al del resto de puntos y se realiza el promedio. Finalmente, se multiplica por 100% para obtener el porcentaje de error. Este error no será de utilidad cuando el valor real r_i sea igual a cero.

4.3.5 SMAPE

Se trata del Error Porcentual Absoluto Medio Simétrico [15], y permite mostrar el grado de error en porcentaje de una manera similar al MAPE, pero teniendo en cuenta también el valor proporcionado por el forecaster en el denominador. La fórmula que se utiliza en este TFG es la siguiente:

$$SMAPE = \frac{100\%}{n} \times \sum_{i=1}^n \frac{|r_i - p_i|}{|r_i| + |p_i|}$$

Como sucedía con el MAPE, cuando el denominador sea igual a cero, no se podrá calcular el error, pero es más sencillo que esta operación funcione dado que el valor real y el predicho no siempre serán iguales, por lo que si solo uno de ellos es igual a cero, la operación se podrá realizar.

4.4 Otros criterios de evaluación

4.4.1 Diferencia

Este es el método de evaluación más básico que hay, dado que es simplemente la diferencia relativa entre el valor predicho y el real, con el fin de observar cuán grande es la desviación en la estimación de demanda de los ítems.

Este criterio se tuvo en cuenta puesto que durante la primera fase de evaluación de los métodos de error se observó que, a pesar de que algunos algoritmos fueran más precisos o cometieran menos errores, la estimación final de la demanda por parte del método actual seguía siendo más cercana al valor real que la que proporcionaban los algoritmos.

4.4.2 Área bajo la curva del error

Este es el último método que se tendrá en cuenta en el estudio, y es una manera de observar el error en su totalidad, durante un periodo de semanas consecutivas.

Las predicciones producen un error cuadrático en cada punto, y este error es representable en una gráfica, en una serie de puntos consecutivos, por lo que forman una curva, siendo cada punto una semana de un periodo concreto.

La forma de comparar el error en este método será la de cuantificar el área bajo dicha curva, para el método actual y para los algoritmos utilizados, de tal manera que el área más pequeño determinará el algoritmo que menos fallos ha cometido al realizar las predicciones.

Los puntos de la curva serán el resultado de las diferencias al cuadrado entre el valor real y cada uno de los algoritmos y el método actual. Esta operación dará un valor para cada semana y, al obtenerlos todos, se normalizarán dichas curvas para mantener siempre la misma escala, entre 0 y 1. Dado que es una diferencia al cuadrado, el valor siempre será mayor o igual que cero. A continuación, para poder observar si los nuevos métodos (algoritmos) funcionan mejor que el actual, se establecerá que el área bajo la curva del error producido por el método actual será el 100%. Esto permitirá ver la proporción de un área frente a otro, en vez de cuantificar en unidades de superficie. Ese 100% sirve como referencia, y significa para este estudio que ese es el máximo error que se puede cometer, dado que el objetivo es mejorar las predicciones, de tal manera que si el área bajo las curvas de los errores producidos por el resto de algoritmos es inferior al 100% se determinará que los errores cometidos son menores.

El valor del área bajo la curva en un punto consistirá en un promedio del valor de la diferencia al cuadrado normalizada de la muestra de la semana siguiente y de la actual. De esta manera, al cuantificar todas esas áreas pequeñas, se formará el área total bajo la curva.

4.5 Estudio preliminar

4.5.1 Predicciones de salida

Como se vio en los apartados 3.1.3 y 4.2.1, los algoritmos utilizan instancias, es decir, líneas con datos, para realizar las predicciones y, cuanto mayor sea el número de instancias, mayor será, teóricamente, la precisión de las predicciones futuras (cuanto más se conozca del conjunto de datos, mejor se ajustará, pero datos muy dispares pueden alterar la predicción y empeorar su precisión).

Para comprobar el efecto de la adición de instancias, a continuación se puede ver una serie de gráficos y tablas donde se muestra la evolución de las predicciones.

Semana	Real	Predicción actual	Predicción IA
W01	31.364	46.352	38.354
W02	47.412	46.352	39.318
W03	47.615	46.352	44.276
W04	45.999	46.352	47.536
W05	27.636	46.352	47.753
W06	67.938	46.352	46.161
W07	40.777	46.352	42.885
W08	57.157	46.352	42.885

Tabla 4-1: Demanda real y predicciones del cable CB01.

En la tabla superior, se puede ver la demanda real, los valores de las predicciones realizadas con el método actual, y los valores de las predicciones con uno de los algoritmos de Weka, en concreto, el algoritmo GaussianProcesses.

Los valores de la predicción del método actual son los mismos durante ocho semanas, dado que ese es el criterio que se estipuló cuando se diseñó este método de promedio ajustado. Es decir, cada semana, el equipo de logística determina el valor de la predicción futura, que es una media para las ocho semanas posteriores. Puede parecer un error que la predicción sea la misma para las ocho semanas consecutivas pero es solo una estimación como referencia. Como se puede ver en la cuarta columna de la tabla, las predicciones de Weka son distintas para cada semana, puesto que su objetivo es predecir cómo será la curva de la demanda en periodos futuros, y el programa determina que no será plana, puesto que su objetivo no es proporcionar un promedio.

De esta manera, una primera muestra de cómo se observan gráficamente las predicciones frente al valor real sería la siguiente:

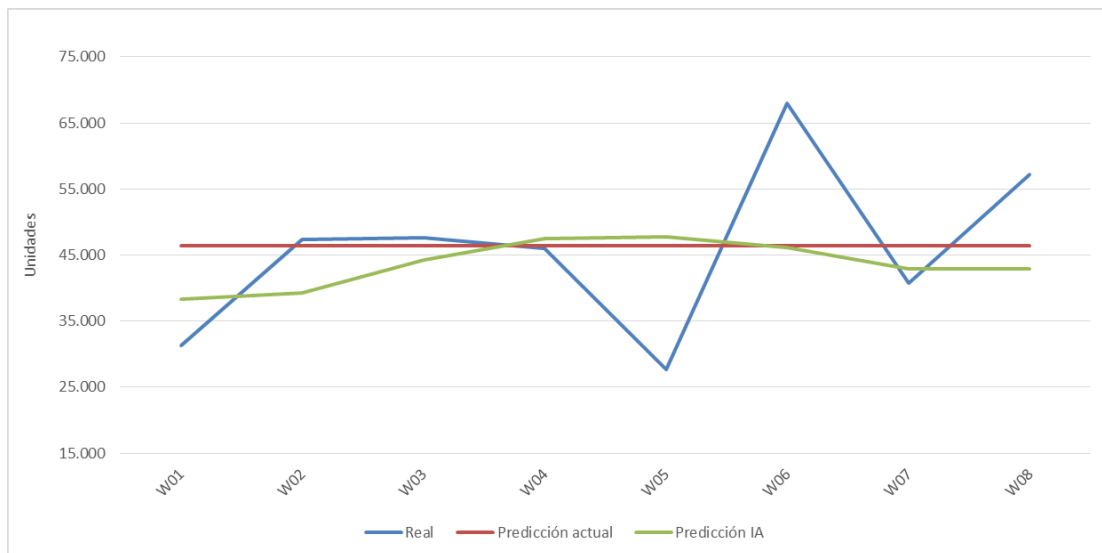


Figura 4-1: Representación gráfica de las predicciones actuales y de un algoritmo de Weka frente a los valores reales desde la semana 1 a la 8.

En esta gráfica se observan las predicciones del método actual (en rojo), las predicciones de un algoritmo de Weka (en verde) y los valores reales (en azul) durante un periodo de ocho semanas consecutivas. La predicción actual mantiene una media durante las ocho semanas, como se vio anteriormente, mientras que el algoritmo de Weka intenta adaptarse a la forma real de la curva, utilizando sus criterios propios para establecer cómo será esa forma en un periodo futuro basándose en los datos de entrada con los que se entrenó el modelo.

A continuación se mostrará otra gráfica similar, en la que se habrá utilizado una instancia más, en la que figurará el dato de la semana 1 junto al resto de datos del entrenamiento:




Figura 4-2: Representación gráfica de las predicciones actuales y de un algoritmo de Weka frente a los valores reales desde la semana 2 a la 9.

De acuerdo con lo que se observó en la gráfica de la Figura 4-1, se aprecia un cambio en los valores de las predicciones tanto en las de Weka como en las del método actual. Ahora el valor del método actual se encuentra por debajo de los 45.000, mientras que antes se situaba por encima de este valor. Asimismo, el valor de la predicción de Weka en la semana 3 en la Figura 4-1 era igual a 44.276, mientras que tras la introducción de la nueva instancia Weka ha ajustado esta predicción y ha determinado que en el periodo de la Figura 4-2 será igual a 38.995.

Para estos casos particulares, se puede observar que en ciertas semanas, el algoritmo reacciona a los cambios de la demanda real, pero no es capaz de hacerlo a tiempo, por lo que las predicciones no son tan acertadas como se podría esperar. Sin embargo, esto es solo un ejemplo de lo que los algoritmos de IA son capaces de hacer.

Con el objetivo de mostrar con más precisión cómo el aumento del número de instancias afecta al sistema de predicción de Weka, se mostrará a continuación una gráfica con el valor real de la demanda y una serie de curvas superpuestas, cada una de ellas corresponderá a las predicciones realizadas por un algoritmo de la librería Weka. De esta manera, se verá claramente cómo tras el paso de cada semana y el uso de una instancia más, el proceso de predicción se ve afectado.




Figura 4-3: Representación gráfica de la demanda real y las predicciones de un algoritmo de Weka superpuestas tras la introducción de nuevas instancias.

Las curvas de las predicciones de Weka siguen una tendencia clara pero con el uso de nuevas instancias las predicciones de las semanas posteriores se reajustan y sus valores varían.

A priori, se puede afirmar que el resultado no parece satisfactorio, y esto puede deberse a varios motivos:

- Los datos de entrada son muy volátiles, es decir, hay cambios muy abruptos en el consumo y además no siguen un patrón claro.
- Es posible que el sistema requiera de más muestras (instancias) para el entrenamiento.
- El algoritmo da prioridad a ciertas muestras frente a otras, y estas primeras muestras disparan la predicción, o todo lo contrario.
- Este algoritmo no es el más adecuado para predecir las muestras.

Dejando a un lado los posibles motivos por los que el algoritmo no es capaz de predecir estas fluctuaciones, el algoritmo presenta cierta semejanza con la predicción actual, y eso no es deseable dado que el objetivo es mejorar esa predicción, no igualarla.

Frente a esos problemas comentados anteriormente, se puede presentar una serie de soluciones, las cuales se evaluarán más adelante para comprobar su impacto en el resultado buscado, pero no es desacertado pensar que no todas garantizarán mejoras en las predicciones.

4.5.2 Datos de entrada

Antes de presentar esas soluciones es necesario ver cómo son los datos de entrada utilizados en este estudio, porque permitirán tener una visión más clara y comprensiva a la hora de evaluar los algoritmos. A continuación se puede ver una gráfica con los datos de entrenamiento y los datos usados durante las predicciones (que servían de alimentación después de cada semana), ambos datos reales de la demanda de un cable durante un periodo de tiempo sin especificar.




Figura 4-1: Representación gráfica de los datos reales de la demanda utilizados para el entrenamiento y las futuras instancias.

Observando la gráfica anterior, se puede ver en azul el conjunto de datos de entrenamiento (instancias) utilizado para las predicciones y, conforme se avanza en el tiempo sobre la línea roja, cada muestra pasada de ésta se añade a ese conjunto para las predicciones posteriores. A simple vista, los datos presentan caídas y subidas muy abruptas, sin mantener una tendencia fija sobre la que centrarse para realizar una predicción clara. Un humano, a ojo, quizás podría determinar cuándo se producen estos cambios abruptos pero resulta extremadamente complicado (si no imposible) intuir cuán grande es la subida o caída en cada uno de esos puntos.

En una de las pruebas que se verán en el próximo capítulo, se podrá comprobar el efecto de las predicciones debido la estructura de los datos. Como se comentaba anteriormente, la falta de linealidad y tendencias claramente marcadas, y la presencia de valores abruptos, provocaban predicciones desacertadas, por lo que habrá una parte de las pruebas en las que se usarán distintos tipos de datos, como los de la gráfica siguiente:




Figura 4-2: Representación gráfica de los datos reales de entrada utilizados para el cable CB01, y sus diferentes formas ajustadas durante el año 2017.

En la gráfica superior, se observan tres curvas:

- En morado, la curva original de la demanda real del cable CB01 durante el año 2017.
- En naranja, la curva original ajustada mediante una fórmula que recorta los valores abruptos (mínimos y máximos locales) en función del promedio de muestras pasadas.
- En gris, la curva naranja tras un suavizado con una media móvil.

En el próximo capítulo se podrá ver el impacto del uso de distintos inputs.

5 Integración, pruebas y resultados

5.1 Pruebas y resultados con los métodos de error

A continuación se presentan datos reales de la demanda del cable CB01, de sus valores futuros predichos por el método actual y por los distintos algoritmos de Weka utilizados en este estudio.

Demanda Real											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	31.364	47.412	47.615	45.999	27.636	67.938	40.777	57.157	39.388	43.098	45.737
2	47.412	47.615	45.999	27.636	67.938	40.777	57.157	58.000	47.514	42.166	49.067
3	47.615	45.999	27.636	67.938	40.777	57.157	58.000	40.850	46.807	47.297	48.247
4	45.999	27.636	67.938	40.777	57.157	58.000	40.850	70.000	36.818	45.588	51.045
5	27.636	67.938	40.777	57.157	58.000	40.850	70.000	15.000	47.787	48.377	47.170
6	67.938	40.777	57.157	58.000	40.850	70.000	15.000	66.000	54.358	55.968	51.965
7	40.777	57.157	58.000	40.850	70.000	15.000	66.000	39.000	48.967	49.196	48.348
8	57.157	58.000	40.850	70.000	15.000	66.000	39.000	48.393	57.579	56.502	49.300
9	58.000	40.850	70.000	15.000	66.000	39.000	48.393	29.209	49.425	45.963	45.807
10	40.850	70.000	15.000	66.000	39.000	48.393	29.209	52.967	55.425	47.963	45.177
11	70.000	15.000	66.000	39.000	48.393	29.209	52.967	50.042	42.500	47.500	46.326
12	15.000	66.000	39.000	48.393	29.209	52.967	50.042	66.000	40.500	42.098	45.826
13	66.000	39.000	48.393	29.209	52.967	50.042	66.000	0	52.500	45.651	
14	39.000	48.393	29.209	52.967	50.042	66.000	0	0	43.697	42.392	
15	48.393	29.209	52.967	50.042	66.000	0	0	0	38.801	45.153	
16	29.209	52.967	50.042	66.000	0	0	0	0	41.088	49.555	
17	52.967	50.042	66.000	0	0	0	0	0	51.505		
18	50.042	66.000	0	0	0	0	0	0	58.021		
19	66.000	0	0	0	0	0	0	0			

Tabla 5-1: Demanda real del cable CB01 y sus promedios a dos, cuatro y ocho semanas.

La tabla superior muestra los valores reales de la demanda del cable CB01, y sus promedios como referencia para observar cómo varían de una semana a otra.

A continuación, los valores de las predicciones del método actual para ese periodo, y sus promedios:

Forecasting del método actual											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	46.352	46.352	46.352	46.352	46.352	46.352	46.352	46.352	46.352	46.352	46.352
2	39.276	39.276	39.276	39.276	39.276	39.276	39.276	39.276	39.276	39.276	39.276
3	41.681	41.681	41.681	41.681	41.681	41.681	41.681	41.681	41.681	41.681	41.681
4	41.624	41.624	41.624	41.624	41.624	41.624	41.624	41.624	41.624	41.624	41.624
5	43.122	43.122	43.122	43.122	43.122	43.122	43.122	43.122	43.122	43.122	43.122

6	41.075	41.075	41.075	41.075	41.075	41.075	41.075	41.075	41.075	41.075	41.075
7	40.543	40.543	40.543	40.543	40.543	40.543	40.543	40.543	40.543	40.543	40.543
8	42.166	42.166	42.166	42.166	42.166	42.166	42.166	42.166	42.166	42.166	42.166
9	44.650	44.650	44.650	44.650	44.650	44.650	44.650	44.650	44.650	44.650	44.650
10	45.884	45.884	45.884	45.884	45.884	45.884	45.884	45.884	45.884	45.884	45.884
11	45.527	45.527	45.527	45.527	45.527	45.527	45.527	45.527	45.527	45.527	45.527
12	48.384	48.384	48.384	48.384	48.384	48.384	48.384	48.384	48.384	48.384	48.384
13	48.378	48.378	48.378	48.378	48.378	48.378	48.378	48.378	48.378	48.378	48.378
14	51.508	51.508	51.508	51.508	51.508	51.508	51.508	51.508	51.508	51.508	51.508
15	51.528	51.528	51.528	51.528	51.528	51.528	51.528	51.528	51.528	51.528	51.528
16	50.788	50.788	50.788	50.788	50.788	50.788	50.788	50.788	50.788	50.788	50.788
17	47.330	47.330	47.330	47.330	47.330	47.330	47.330	47.330	47.330	47.330	47.330
18	48.215	48.215	48.215	48.215	48.215	48.215	48.215	48.215	48.215	48.215	48.215
19	50.409	50.409	50.409	50.409	50.409	50.409	50.409	50.409	50.409	50.409	50.409

Tabla 5-2: Predicciones del método actual para el cable CB01 y sus promedios a dos, cuatro y ocho semanas.

En la Tabla 5-2 se puede ver cómo las predicciones para cada semana cubren las ocho semanas posteriores con el mismo valor, como se comentó en capítulos anteriores.

Forecasting de GaussianProcesses											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	38.354	39.318	44.276	47.536	47.753	46.161	42.885	42.885	38.836	42.371	43.646
2	34.216	38.995	42.367	44.859	43.882	41.240	38.779	38.779	36.606	40.109	40.390
3	43.775	48.894	48.500	47.359	43.387	40.774	38.585	38.585	46.335	47.132	43.732
4	49.800	49.321	48.233	44.261	41.538	39.527	39.222	39.222	49.561	47.904	43.891
5	47.972	47.221	43.975	41.659	39.844	39.436	39.673	39.673	47.597	45.207	42.432
6	33.634	30.771	29.056	29.453	36.549	36.703	38.371	38.371	32.203	30.729	34.114
7	47.145	44.710	43.031	41.568	40.197	44.010	38.455	38.455	45.928	44.114	42.196
8	41.870	40.766	40.351	39.252	43.119	37.111	46.511	46.511	41.318	40.560	41.936
9	44.912	42.643	41.473	45.275	38.385	47.402	45.364	45.364	43.778	43.576	43.852
10	43.640	43.117	46.701	39.492	47.892	47.207	46.309	46.309	43.379	43.238	45.083
11	41.469	44.925	37.772	47.644	47.001	46.001	49.000	49.000	43.197	42.953	45.352
12	54.242	49.524	52.707	46.973	49.296	51.627	42.217	42.217	51.883	50.862	48.600
13	40.616	47.081	41.024	52.048	44.508	43.969	45.569	45.569	43.849	45.192	43.849
14	48.728	45.067	55.680	42.220	50.126	41.330	44.733	44.733	46.898	47.924	46.898
15	38.351	48.505	35.212	47.981	37.968	43.523	43.084	43.084	43.428	42.512	43.428
16	51.524	40.142	50.030	38.342	46.480	42.675	42.815	42.815	45.833	45.010	45.833
17	36.509	43.780	35.321	43.218	38.072	42.109	57.000	57.000	40.145	40.145	40.145
18	43.941	39.251	44.632	41.070	43.684	57.722	59.661	59.661	41.596	41.596	41.596
19	41.531	47.956	43.866	46.867	59.565	61.371	60.389	60.389	41.531	41.531	41.531

Tabla 5-3: Predicciones del algoritmo GaussianProcesses para el cable CB01 y sus promedios a dos, cuatro y ocho semanas.

Para evitar mostrar demasiada información, en el Anexo de Tablas Adicionales se podrán encontrar el resto de predicciones de los algoritmos de Weka para este mismo periodo. Esos valores servirán para los cálculos del error que se mostrarán en esta sección.

Tras mostrar los dos ejemplos de las predicciones, la del método actual y la del algoritmo GaussianProcesses, se calcularán los errores comentados en la sección 4.3.

W	MAE				RMSE			
	MAE_1	MAE_2	MAE_4	MAE_8	RMSE_1	RMSE_2	RMSE_4	RMSE_8
1	6.990,00	552,00	726,50	2.091,25	6.990,00	7.562,17	5.654,30	12.323,50
2	13.196,00	10.908,00	2.056,25	8.677,13	13.196,00	11.145,38	11.813,78	15.183,73
3	3.840,00	472,50	165,00	4.514,13	3.840,00	3.400,49	14.848,64	13.870,90
4	3.801,00	12.743,00	2.316,25	7.154,13	3.801,00	15.567,38	14.875,42	17.393,44
5	20.336,00	190,50	3.170,25	4.738,13	20.336,00	20.527,38	16.531,50	19.213,56
6	34.304,00	22.155,00	25.239,50	17.851,75	34.304,00	25.267,41	26.839,72	25.783,32
7	6.368,00	3.039,50	5.082,50	6.151,63	6.368,00	9.886,33	10.247,75	19.068,59
8	15.287,00	16.260,50	15.942,00	7.363,63	15.287,00	16.289,62	19.211,92	19.879,64
9	13.088,00	5.647,50	2.386,75	1.954,25	13.088,00	9.341,05	21.822,44	19.391,42
10	2.790,00	12.046,50	4.725,00	94,00	2.790,00	19.111,25	24.688,60	18.892,20
11	28.531,00	697,00	4.547,50	974,88	28.531,00	29.236,31	25.402,08	18.979,57
12	39.242,00	11.383,00	8.763,25	2.774,00	39.242,00	30.094,79	22.367,90	19.472,53
13	25.384,00	8.651,50	458,25		25.384,00	18.836,80	17.927,44	
14	9.728,00	3.201,00	5.531,50		9.728,00	7.269,67	15.181,47	
15	10.042,00	4.627,00	2.640,50		10.042,00	15.381,44	14.077,15	
16	22.315,00	4.745,00	4.545,00		22.315,00	18.199,45	18.890,51	
17	16.458,00	11.360,00			16.458,00	12.451,47		
18	6.101,00	16.425,00			6.101,00	19.400,14		
19	24.469,00				24.469,00			

Tabla 5-4: Errores MAE y RMSE del algoritmo GaussianProcesses para el cable CB01.

W	MAPE				SMAPE			
	MAPE_1	MAPE_2	MAPE_4	MAPE_8	SMAPE_1	SMAPE_2	SMAPE_4	SMAPE_8
1	22,29%	19,68%	12,43%	23,09%	10,03%	9,61%	6,12%	10,90%
2	27,83%	22,97%	29,04%	27,25%	16,17%	12,61%	13,27%	14,39%
3	8,06%	7,18%	30,04%	24,28%	4,20%	3,51%	13,07%	11,91%
4	8,26%	43,36%	31,07%	28,93%	3,97%	16,08%	13,31%	14,77%
5	73,59%	52,04%	34,76%	47,70%	26,90%	22,58%	16,15%	19,68%
6	50,49%	37,52%	43,35%	53,65%	33,77%	24,37%	28,49%	27,50%
7	15,62%	18,70%	16,24%	43,01%	7,24%	9,83%	8,84%	17,30%
8	26,75%	28,23%	25,40%	44,50%	15,44%	16,53%	15,45%	18,60%
9	22,57%	13,48%	67,39%	49,31%	12,72%	7,58%	22,74%	18,97%
10	6,83%	22,62%	74,18%	49,14%	3,30%	13,54%	25,90%	18,05%
11	40,76%	120,13%	76,30%	46,89%	25,60%	37,38%	27,99%	17,68%
12	261,61%	143,29%	81,16%	55,95%	56,67%	37,54%	22,88%	18,09%
13	38,46%	29,59%	38,15%		23,81%	15,92%	17,05%	
14	24,94%	15,91%	35,68%		11,09%	7,57%	14,40%	

15	20,75%	43,41%	31,11%	11,58%	17,60%	14,36%
16	76,40%	50,31%	35,64%	27,64%	22,98%	18,12%
17	31,07%	21,79%		18,39%	11,84%	
18	12,19%	26,36%		6,49%	16,12%	
19	37,07%			22,76%		

Tabla 5-5: Errores MAPE y SMAPE del algoritmo GaussianProcesses para el cable CB01.

Estos errores permitirán entender cómo de precisos son los algoritmos de la librería Weka y si sus predicciones son mejores que las del método actual. Para ello, se ha sometido al método actual a los mismos criterios de evaluación, por lo que a continuación se verá una comparativa de cada uno de los algoritmos utilizados para observar su MAE.

W	ACTUAL	MAE_1						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	14.988,00	6.990,00	4.628,00	11.299,00	18.593,00	14.442,00	26.963,00	4.429,00
2	8.136,00	13.196,00	11.634,00	3.890,00	15.759,00	22.900,00	11.935,00	11.935,00
3	5.934,00	3.840,00	4.269,00	11.391,00	9.153,00	4.338,00	11.342,00	9.134,00
4	4.375,00	3.801,00	2.636,00	25.643,00	3.340,00	13.937,00	9.018,00	10.384,00
5	15.486,00	20.336,00	26.178,00	10.386,00	21.618,00	40.575,00	30.691,00	32.176,00
6	26.863,00	34.304,00	26.895,00	43.680,00	37.088,00	34.150,00	30.975,00	33.225,00
7	234,00	6.368,00	14.845,00	13.646,00	8.427,00	9.528,00	2.184,00	6.710,00
8	14.991,00	15.287,00	14.534,00	20.551,00	11.616,00	8.151,00	375,00	14.178,00
9	13.350,00	13.088,00	6.933,00	7.747,00	9.266,00	12.645,00	1.204,00	13.628,00
10	5.034,00	2.790,00	3.867,00	640,00	8.523,00	10.404,00	6.066,00	5.813,00
11	24.473,00	28.531,00	26.146,00	33.376,00	31.456,00	18.952,00	32.303,00	56.220,00
12	33.384,00	39.242,00	30.343,00	43.028,00	38.295,00	23.118,00	34.442,00	40.089,00
13	17.622,00	25.384,00	27.384,00	25.943,00	26.303,00	31.820,00	27.822,00	23.457,00
14	12.508,00	9.728,00	7.052,00	29.012,00	10.255,00	4.465,00	10.449,00	6.919,00
15	3.135,00	10.042,00	7.426,00	36.493,00	9.798,00	23.607,00	23.288,00	10.798,00
16	21.579,00	22.315,00	18.699,00	13.522,00	12.982,00	37.045,00	8.954,00	21.562,00
17	5.637,00	16.458,00	13.246,00	5.047,00	14.648,00	18.468,00	15.252,00	11.668,00
18	1.827,00	6.101,00	3.593,00	6.564,00	15.456,00	1.246,00	16.545,00	8.354,00
19	15.591,00	24.469,00	27.348,00	15.376,00	25.736,00	37.522,00	40.805,00	24.043,00

Tabla 5-6: Comparativa del MAE_1 para el cable CB01.

Para tener una visión más clara, se ha hallado el promedio de este error para cada algoritmo y para el método actual.

MEDIAS DEL MAE_1							
ACTUAL	GP	RF	SMOreg	RBD	AR	M5P	LR
12.902,47	15.908,95	14.613,47	18.801,79	17.279,58	19.332,26	17.927,00	18.143,26

Tabla 5-7: Comparativa del promedio del MAE_1 para el cable CB01.

A la vista de los resultados, se ve que el método actual es el que comete el menor error para este criterio. El siguiente método que mejor se ajusta es el algoritmo RandomForest, que comete un error un 13.26% mayor que el método actual.

Realizando esos mismos cálculos con todos los errores y todos los algoritmos utilizados, se han obtenido las mismas tablas de forecasting para cada uno de ellos, y las tablas de los errores MAE, RMSE, MAPE y SMAPE para la primera muestra de cada semana, para las dos primeras, para las cuatro primeras, y para las ocho muestras. Todas estas tablas están en el Anexo C, desde la Tabla C-1 a la Tabla C-25.

Si se realiza la media de cada columna de las tablas del MAE, RMSE, MAPE y SMAPE para los cuatro tipos de conjuntos de muestras, se obtiene la media de esos errores para cada algoritmo y para el método actual. Teniendo el dato del error medio que se quiera tener en cuenta del método actual, como el que se observa en la Tabla 5-7 a la izquierda, se puede calcular el porcentaje de diferencia de los errores, como se afirmaba anteriormente al compararlo con el MAE_1 de RandomForest.

Realizando esos cálculos para todos los algoritmos y todos los errores para los cuatro conjuntos de muestras, se obtiene las siguientes tablas:

	Una semana			
	MAE	RMSE	MAPE	SMAPE
GaussianProcesses	-23,30%	-23,30%	-18,60%	-22,78%
RandomForest	-13,26%	-13,26%	-6,56%	-12,84%
SMOreg	-45,72%	-45,72%	-36,34%	-49,93%
RBD	-33,92%	-33,92%	-26,36%	-34,84%
Add.Reggression	-49,83%	-49,83%	-36,40%	-58,03%
M5P	-38,94%	-38,94%	-29,76%	-43,02%
LinearRegression	-40,62%	-40,62%	-32,14%	-41,57%
MEJOR:	-13,26%	-13,26%	-6,56%	-12,84%

Tabla 5-8: Comparativa del promedio de los errores para las muestras de la primera semana del cable CB01.

	Dos semanas			
	MAE	RMSE	MAPE	SMAPE
GaussianProcesses	-3,29%	-13,58%	-14,99%	-19,81%
RandomForest	6,85%	-4,47%	-4,49%	-6,81%
SMOreg	-53,68%	-43,90%	-43,01%	-54,43%
RBD	-14,87%	-13,99%	-14,30%	-23,00%
Add.Reggression	-53,13%	-35,88%	-26,03%	-39,64%
M5P	-19,39%	-19,44%	-20,47%	-24,82%
LinearRegression	-46,06%	-26,78%	-19,50%	-31,23%
MEJOR:	6,85%	-4,47%	-4,49%	-6,81%

Tabla 5-9: Comparativa del promedio de los errores para las muestras de las dos primeras semanas del cable CB01.

	Cuatro semanas			
	MAE	RMSE	MAPE	SMAPE
GaussianProcesses	1,85%	-13,71%	-16,71%	-21,07%
RandomForest	27,77%	-3,58%	-7,53%	-9,66%
SMOreg	-100,11%	-60,25%	-64,96%	-77,41%
RBD	-13,27%	-9,94%	-17,59%	-20,74%
Add.Reggression	-93,36%	-45,60%	-37,67%	-56,87%
M5P	-32,47%	-24,31%	-35,09%	-31,14%
LinearRegression	-74,15%	-27,91%	-25,21%	-38,84%
MEJOR:	27,77%	-3,58%	-7,53%	-9,66%

Tabla 5-10: Comparativa del promedio de los errores para las muestras de las cuatro primeras semanas del cable CB01.

	Ocho semanas			
	MAE	RMSE	MAPE	SMAPE
GaussianProcesses	-4,64%	-8,80%	-8,63%	-10,49%
RandomForest	24,10%	0,13%	-2,91%	-1,79%
SMOreg	-69,02%	-57,02%	-50,52%	-79,62%
RBD	32,44%	-2,35%	-15,97%	-8,24%
Add.Reggression	-85,21%	-38,35%	-27,66%	-52,45%
M5P	-6,61%	-12,53%	-31,95%	-10,48%
LinearRegression	-29,33%	-22,77%	-25,10%	-27,17%
MEJOR:	32,44%	0,13%	-2,91%	-1,79%

Tabla 5-11: Comparativa del promedio de los errores para las muestras de las ocho semanas del cable CB01.

Analizando las cuatro tablas se pueden sacar varias conclusiones:

1. El método actual comete un menor error en media en la gran mayoría de los casos.
2. Ningún algoritmo predice mejor cuando se tienen en cuenta los errores de la primera semana.
3. A largo plazo, cuando se tienen en cuenta los ocho valores de las predicciones semanales, dos algoritmos mejoran y obtienen predicciones con un MAE inferior al del método actual.
4. A largo plazo, los errores son menores.

La justificación de que se cometan errores mayores al tener en cuenta solo la primera muestra se debe a los cambios de tendencia (véase el apartado 4.5 para entender cómo son los datos de entrada). Los algoritmos de Weka no son capaces de reaccionar a estos cambios rápidamente, por lo que el método actual, que es un promedio, se ajusta mejor al no “arriesgarse” con las predicciones. Un ejemplo: si se produce un error por una subida abrupta una semana, la gráfica del método actual tendrá un valor mucho más neutro que cualquiera de los algoritmos porque no intentará vaticinar estas subidas y bajadas y no habrá posibilidad de que prediga lo contrario (una bajada abrupta), porque mantendrá una tendencia constante, y esto hará que la diferencia nunca sea excesivamente grande.

Al mantener esa tendencia más constante, la gráfica de la demanda real, que tiene subidas y bajadas, se cruzará en muchos puntos de la gráfica de la estimación del método actual, y eso producirá errores bastante bajos.

5.2 Pruebas y resultados con la diferencia

Otra forma de observar si las predicciones se desvían en exceso de los valores reales futuros es comprobar si los valores medios de las predicciones para los cuatro conjuntos de muestras se asemejan a los valores medios reales futuros de esos mismos conjuntos.

	Una semana	Dos semanas	Cuatro semanas	Ocho semanas
REAL	47.440	47.371	47.154	47.835
MÉT. ACT.	45.707	45.446	45.155	43.357
GP	43.275	43.465	43.712	42.935
RF	44.221	44.402	44.390	43.945
SMOreg	44.140	44.182	43.551	39.265
RBD	43.006	43.322	44.933	46.980
AR	40.316	41.798	43.766	40.592
M5P	41.888	44.537	47.751	52.478
LR	43.034	42.718	42.705	44.254

Tabla 5-12: Valores medios reales y de las predicciones del cable CB01 para los cuatro conjuntos de muestras y todos los métodos de predicción.

	Una semana	Dos semanas	Cuatro semanas	Ocho semanas
MÉT. ACT.	3,65%	4,06%	4,24%	9,36%
GP	8,78%	8,25%	7,30%	10,24%
RF	6,79%	6,27%	5,86%	8,13%
SMOreg	6,96%	6,73%	7,64%	17,91%
RBD	9,35%	8,55%	4,71%	1,79%
AR	15,02%	11,76%	7,19%	15,14%
M5P	11,70%	5,98%	1,27%	9,71%
LR	9,29%	9,82%	9,44%	7,48%

Tabla 5-13: Porcentaje de desviación de los valores medios de las predicciones del cable CB01 para los cuatro conjuntos de muestras y todos los métodos de predicción respecto a los valores medios reales.

Como se observó en las pruebas del apartado anterior, a corto plazo se asemejan más los valores del método actual, mientras que a largo plazo los valores de algunos de los algoritmos son más acertados. En rojo se observan los mejores resultados (cuanto menor sea el porcentaje, mayor será la similitud al valor real).

Esto es importante si no es prioridad conseguir aciertos a corto plazo. Dado que sabiendo que a largo plazo es relativamente efectivo, se podría comprar material en base a

lo que determinen los algoritmos porque, a pesar de cometer errores a corto plazo, a largo plazo el nuevo método resulta fiable. La única dificultad residiría en qué algoritmo habría que fiarse para realizar esas compras de material.

5.3 Pruebas y resultados con el área bajo la curva

En el apartado 4.5.2 se habló de la forma de la curva de los datos de entrada, y de cómo esos picos producidos por valores abruptos podrían afectar a las predicciones.

Antes de mostrar el efecto mencionado, es necesario recordar que este estudio trata de evaluar predicciones, es decir, valores futuros, ya que el objetivo era mejorar las predicciones del método actual. Esta predicción se utiliza para la compra de material, para el reabastecimiento de los almacenes de cara a las próximas semanas, por lo que a partir de ahora se dejará de tener en cuenta el valor real de la demanda semanal, y se compararán todas las predicciones con la media de las 8 próximas semanas. El hecho de que se vaya a hacer esta comparación no implica que el sistema se haya entrenado con valores futuros (esto sería imposible), pero resulta un buen criterio porque permitirá observar si esas predicciones fueron acertadas o no en el momento en el que debían serlo.

De esta manera, tras entrenar el sistema con los datos ajustados bajo el segundo criterio del apartado 4.5.2, es decir, recortando picos y suavizando la curva de la gráfica, las tendencias resultan más fáciles de seguir, por lo que el error tenderá a ser menor.

A continuación, una gráfica con ese resultado para el algoritmo GaussianProcesses:




Figura 5-1: Representación gráfica de los datos reales futuros frente a las predicciones actuales y del algoritmo GaussianProcesses para el cable CB01, usando como input la curva ajustada 2, durante 2017 y 2018.

Esta comparación parece más justa, ya que ahora se observa si de verdad está estimando los valores futuros cuando se necesitan. Se observa que durante el segundo cuatrimestre de 2017, la gráfica de las predicciones del algoritmo de Weka no llega a conseguir acercarse a los valores reales tanto como debería pero que, a partir del tramo final de 2017, es capaz de prever los cambios de tendencia con mayor rapidez (observar especialmente el tramo 2017-W49 – 2018-W09).

Cabe decir que para ese resultado, no sólo se ha usado un input mucho más suave, sino que además el criterio para el valor de las predicciones de Weka es distinto. La curva determinada por las predicciones del método actual no ha cambiado (sigue siendo un promedio ajustado) pero la curva de las predicciones del algoritmo de Weka está formada por el promedio de las ocho muestras de salida que se obtienen cada semana. Utilizar la media de esos ocho valores concede estabilidad a la curva, porque resta importancia a las muestras que puedan afectar negativamente a la forma de la curva y da el mismo peso al valor de la semana W (primera semana que se predice) que al de la semana W+7 (último valor predicho, es decir, la octava muestra). Este criterio se tuvo en cuenta gracias a lo que se vio en el apartado 5.2, en el que se demuestra que los valores medios a largo plazo son más cercanos a los valores medios reales en ese periodo más que en cualquier otro.

Visto este asunto, se puede afirmar que la elección de criterios adecuada y el pre-procesado de los datos pueden afectar significativamente a los resultados.

Para comprobar cómo cambia el uso del input, a continuación se mostrará una gráfica con los mismos datos para los criterios de salida pero usando como entrada la curva ajustada con el primer criterio del apartado 4.5.2, es decir, solo recortando los picos en función del promedio de muestras pasadas recientes.

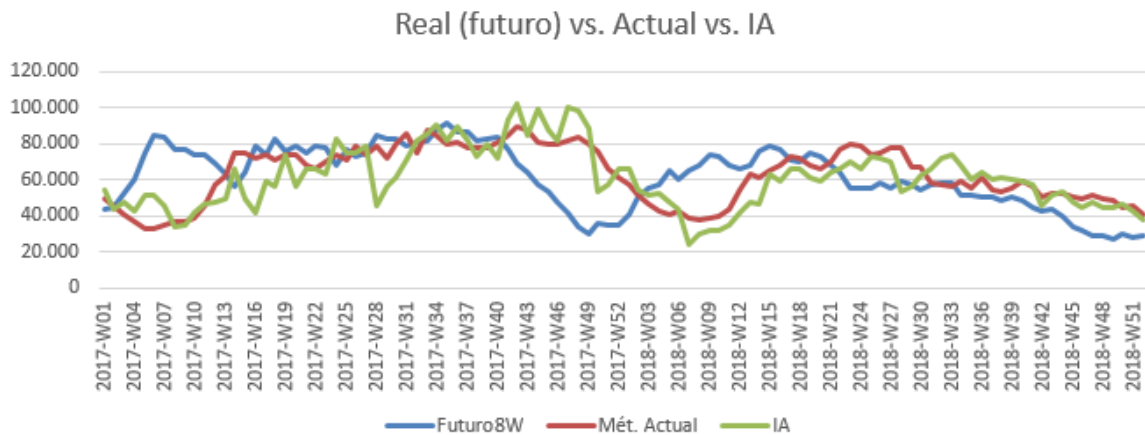


Figura 5-2: Representación gráfica de los datos reales futuros frente a las predicciones actuales y del algoritmo GaussianProcesses para el cable CB01, usando como input la curva ajustada 1, durante 2017 y 2018.

Es evidente que la curva de las predicciones del algoritmo de Weka es más errática y menos constante que cuando se utiliza el input ajustado 2. A pesar de esto, hay algunos algoritmos que, utilizando el input ajustado 2, presentan una curva de predicciones repleta de valores abruptos, como el algoritmo LinearRegression (datos de la gráfica en el anexo de tablas adicionales).




Figura 5-3: Representación gráfica de los datos reales futuros frente a las predicciones actuales y del algoritmo LinearRegression para el cable CB01, usando como input la curva ajustada 2, durante 2017 y 2018.

Esto recuerda una vez más la importancia de la elección del algoritmo adecuado, ya que no todos garantizan éxito.

Por último, para comprobar la eficacia de las predicciones, se tendrá en cuenta el criterio del apartado 4.4.2, el área bajo la curva, recordando que el error producido por las predicciones del método actual se tratará como el 100% para así ver la proporción del área bajo la curva producida por las predicciones de los nuevos métodos.

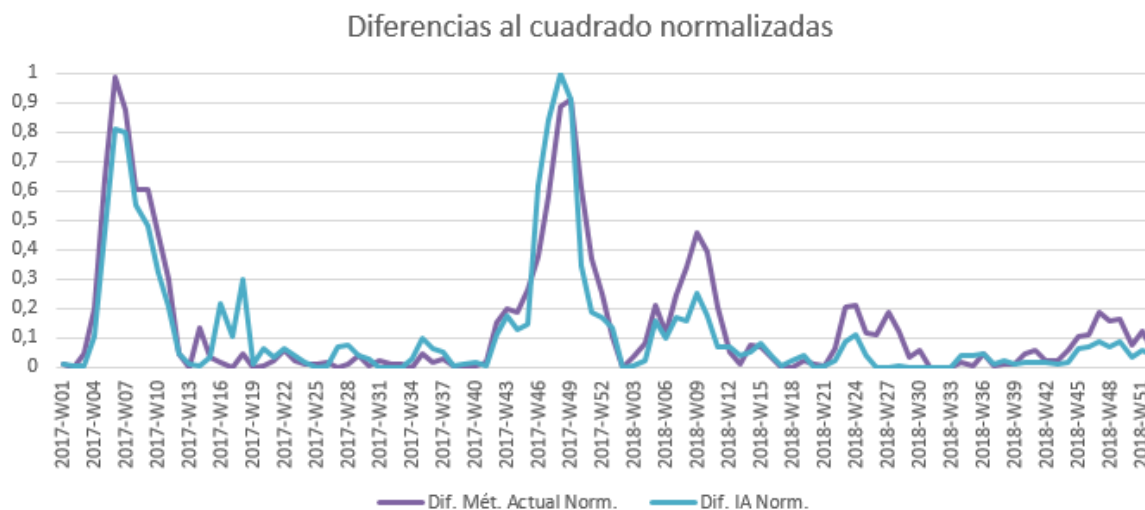


Figura 5-4: Representación gráfica de las diferencias al cuadrado normalizadas de las predicciones actuales y del algoritmo GaussianProcesses respecto al promedio de los valores reales futuros para el cable CB01, usando como input la curva ajustada 2, durante 2017 y 2018.

Observando la gráfica, cada vez que la curva azul está situada por debajo de la morada, implica que el error producido por el algoritmo de Weka es menor en ese punto, y viceversa.

Teniendo en cuenta la gráfica de la Figura 5-4, el área bajo la curva durante todo ese periodo para las predicciones de Weka representa el 83% del área creada por el método actual, y si se tiene en cuenta únicamente el año 2018, el área bajo la curva de Weka supone solamente el 53%.

De nuevo, para comprobar que este efecto cambia al utilizar otro input, se mostrará a continuación la misma gráfica con el input ajustado 1.




Figura 5-5: Representación gráfica de las diferencias al cuadrado normalizadas de las predicciones actuales y del algoritmo GaussianProcesses respecto al promedio de los valores reales futuros para el cable CB01, usando como input la curva ajustada 1, durante 2017 y 2018.

En este caso, el área bajo la curva de Weka durante esos dos años supone un 126%, y un 124% durante 2018.

6 Conclusiones y trabajo futuro

6.1 Conclusiones

Weka es una herramienta potente y que ofrece buenos resultados. Su librería es muy completa, y no solo permite forecasting en series temporales (lo que se ha visto en este trabajo) sino que también ofrece a su vez soluciones a problemas de clasificación y clustering. La cantidad de opciones con las que se puede personalizar el forecaster es enorme, y evaluar todas y cada una de ellas es una ardua tarea. No todas las opciones y configuraciones del forecaster rinden de la misma manera y, como se ha visto en secciones anteriores, dependiendo del criterio de error o evaluación, cada configuración será prácticamente única.

El principal problema de un estudio como este en el que se comparan unos datos frente a otros, y a la vez frente al dato real, es que no se observa realmente cuándo un método es mejor que otro porque nada garantiza estabilidad. Es decir, una semana se puede determinar que el algoritmo X es el que mejor rinde (a corto o largo plazo), y la semana siguiente los resultados pueden afirmar que eso ya no es cierto.

Esta investigación con Weka y los ítems del despliegue FTTH duró aproximadamente seis meses y, durante este periodo, se observó que ciertos algoritmos rendían de una manera satisfactoria a largo plazo, por lo que se decidió observar esos algoritmos para monitorizar las predicciones durante un periodo de varias semanas consecutivas. Los resultados determinaron que durante ese periodo, aproximadamente la mitad de los ítems estaban siendo predichos por algoritmos que ya no ofrecían resultados positivos, por lo que el estudio se reinició y se cambiaron los criterios de evaluación.

Para concluir, tras realizar todos los análisis, se determinó que utilizar Weka como sustituto del método actual no era una alternativa lo suficientemente fiable debido a la estructura de los datos. La falta de coherencia de los mismos producía predicciones erróneas y provocaba que el modelo de forecasting que se había diseñado careciera de fiabilidad. Por lo tanto, como decisión final, se mantuvo este método de predicciones con IA como una segunda voz que decía si esa semana habría subida o bajada de la demanda.

Actualmente, se mantiene el método del promedio ajustado, teniendo en cuenta a su vez lo que el sistema de Weka propone.

6.2 Trabajo futuro

Resulta complicado determinar qué se puede hacer con Weka para seguir obteniendo una mejora. Durante este proyecto, también se aplicó Weka usando sus funciones de clasificador en otro ámbito del mismo proyecto del operador, y sus resultados eran bastante positivos. Se llegó a determinar que tenía un 75% de acierto durante su clasificación, partiendo con unos datos de entrada que aparentemente no presentaban demasiada cohesión.

Para la tarea del forecasting, entre los próximos objetivos estaría mantener la monitorización del rendimiento de los algoritmos. Un objetivo realmente ambicioso que se planteó durante el proyecto fue una automatización en Java, que permitiera analizar los datos que se habían predicho para que se seleccionaran nuevos algoritmos automáticamente en caso de que el rendimiento decayera más de un 10-15% respecto a los anteriores resultados.

Es una labor bastante compleja y solo se podría medir el rendimiento tras el paso de varias semanas. Una muestra no debe ser significativa si en una semana puntual un algoritmo rinde peor que otro sabiendo que durante un largo periodo se ha demostrado que es capaz de proporcionar resultados favorables.

Referencias

- [1] Russell, Stuart; Norvig, Peter, “Inteligencia Artificial: Un Enfoque Moderno” (3rd edición), p.3, 2009.
- [2] J.F. Kurose, K.W. Ross, “Redes de Computadoras: Un enfoque descendente”, Pearson Educación, S.A., pp-17-18, 2010
- [3] “Aprendizaje automático - Wikipedia, la enciclopedia libre”, Wikipedia, https://es.wikipedia.org/wiki/Aprendizaje_autom%C3%A1tico
- [4] “Cobertura ADSL directa o indirecta, ¿cuáles son las diferencias?”, ComputerHoy.com, 21 Junio 2018, <https://computerhoy.com/noticias/tecnologia/cobertura-adsl-directa-indirecta-cuales-son-diferencias-266163>
- [5] “A falta de una, España tiene las dos redes de fibra más grandes de Europa”, ADSLZone, 26 abril 2018, <https://www.adslzone.net/2018/04/26/espana-dos-redes-fibra-europa/>
- [6] “Weka 3 – Data Mining with Open Source Machine Learning Software in Java”, The University of Waikato (NZ), <https://www.cs.waikato.ac.nz/ml/weka/>
- [7] Bernis, F; De Juana, E; Del Hoyo, J; Fernández-Cruz, M; Ferrer, X; Sáez-Royuela, R; Sargatal, J, “Nombres en castellano de las aves del mundo recomendados por la Sociedad Española de Ornitología (Tercera parte: Opisthocomiformes, Gruiformes y Charadriiformes)”, p.232, 1996
- [8] “Machine Learning Project at the University of Waikato in New Zealand”, The University of Waikato, <https://www.cs.waikato.ac.nz/ml/index.html>
- [9] “Attribute-Relation File Format”, The University of Waikato, <https://www.cs.waikato.ac.nz/ml/weka/arff.html>
- [10] “BatchPredictor”, Mark Hall, <http://weka.sourceforge.net/doc.dev/weka/core/BatchPredictor.html>
- [11] “Time Series Analysis and Forecasting with Weka”, Pentaho Data Mining, Pentaho Wiki, <https://wiki.pentaho.com/display/DATAMINING/Time+Series+Analysis+and+Forecasting+with+Weka#TimeSeriesAnalysisandForecastingwithWeka-3.2.5Evaluation>
- [12] “Average absolute deviation - Wikipedia”, Wikipedia, https://en.wikipedia.org/wiki/Average_absolute_deviation
- [13] “RMSE: Root Mean Square Error – Statistics How To”, 25 Octubre 2016, <https://www.statisticshowto.datasciencecentral.com/rmse/>
- [14] “Mean absolute percentage error (MAPE) – Statistics How To”, 9 Septiembre 2017, <https://www.statisticshowto.datasciencecentral.com/mean-absolute-percentage-error-mape/>
- [15] “Symmetric mean absolute percentage error — Wikipedia Republished // WIKI 2”, https://wiki2.org/en/Symmetric_mean_absolute_percentage_error

Glosario

AR	AdditiveRegression
ARFF	Attribute-Relation File Format
FTTH	Fiber-to-the-home (fibra hasta el hogar)
GP	GaussianProcesses
IA	Inteligencia Artificial
LR	LinearRegression
M5P	M5 model trees algorithm for Prediction (Algoritmo de predicción basado en árboles M5)
MAE	Mean Absolute Error (Error Absoluto Medio)
MAPE	Mean Absolute Percentage Error (Error Absoluto Medio Porcentual)
ML	Machine Learning
RA	Red de Alimentación
RBD	RegressionByDiscretization
RD	Red de Distribución
RF	RandomForest
RMSE	Root Mean Square Error (Raíz del Error Cuadrático Medio)
SMAPE	Symmetric Mean Absolute Percentage Error (Error Absoluto Medio Porcentual Simétrico)
SMOreg	SMO (Sequential Minimal Optimization) + reg (Regression)
UICN	International Union for Conservation of Nature (Unión Internacional para la Conservación de la Naturaleza)
UIII	Unidades Inmobiliarias
WEKA	Waikato Environment for Knowledge Analysis

Anexos

A Manual de instalación

El entorno utilizado para este TFG ha sido el software gratuito NetBeans, en su versión 8.2, con el paquete de Java.

Puede ser descargado en la siguiente URL: <https://netbeans.org/downloads/8.2/>

Supported technologies *	Java SE	Java EE	HTML5/JavaScript	PHP	C/C++	All
NetBeans Platform SDK	•	•				•
Java SE	•	•				•
Java FX	•	•				•
Java EE		•				•
Java ME						•
HTML5/JavaScript		•	•	•		•
PHP			•	•		•
C/C++					•	•
Groovy						•
Java Card™ 3 Connected						•
Bundled servers						
GlassFish Server Open Source Edition 4.1.1		•				•
Apache Tomcat 8.0.27		•				•

Download buttons and file sizes:

- Download (Free, 95 MB)
- Download (Free, 197 MB)
- Download x86 (Free, 108 - 112 MB)
- Download x64 (Free, 108 - 112 MB)
- Download x86 (Free, 107 - 110 MB)
- Download x64 (Free, 107 - 110 MB)
- Download (Free, 221 MB)

Figura A-1: Vista web para la descarga de NetBeans en su página web.

Con el paquete de Java es suficiente, dado que el software de Weka está desarrollado en este lenguaje.

Tras instalar el programa, habrá que acudir a la web del proyecto de Weka para descargar el material necesario.

La URL donde se encuentran las descargas es la siguiente: <https://www.cs.waikato.ac.nz/ml/weka/downloading.html>

La forma empleada en este trabajo fue la descarga del comprimido con el archivo “.jar” de Weka, por lo que se recomienda que se realice el mismo procedimiento.

o **Other platforms (Linux, etc.)**

Click [here](#) to download a zip archive containing Weka (weka-3-8-3.zip; 51.4 MB)

First unzip the zip file. This will create a new directory called weka-3-8-3. To run Weka, change into that directory and type

```
java -jar weka.jar
```

Note that Java needs to be installed on your system for this to work. Also note, that using -jar will override your current CLASSPATH variable and only use the weka.jar.

Figura A-2: Vista web para la descarga de Weka en su página web.

Existe la opción de descargar una versión estable de Weka y otra para desarrolladores. Cualquiera de ellas es válida, pero hay que decir que la versión de desarrolladores es más actual y puede contener un mayor número de opciones para “trastear”.

Tras pinchar en el enlace (“Click here”), se abrirá una pestaña nueva y comenzará la descarga del fichero comprimido.

Tras su descarga, al abrir el fichero comprimido se verán los ficheros “.jar” necesarios para la utilización del software.

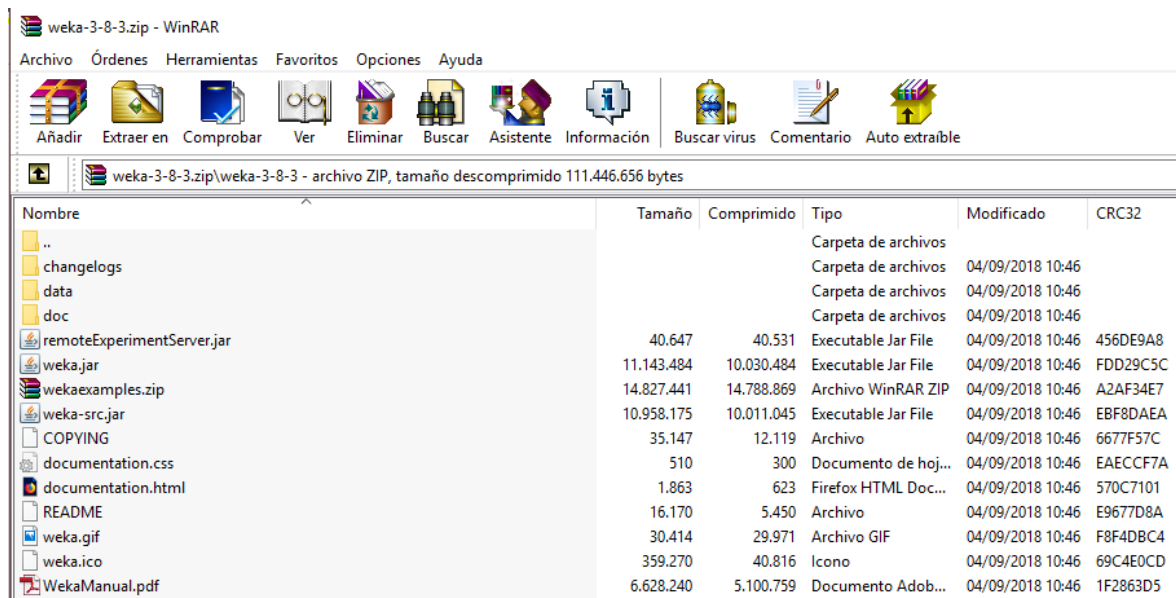


Figura A-3: Vista del fichero comprimido de la versión de Weka descargada.

El último paso sería descomprimir el “.zip”, crear el proyecto en NetBeans y asociar las librerías al proyecto pinchando con el botón derecho sobre el nombre del proyecto, después en Propiedades o Properties, a continuación en “Libraries”, y posteriormente en la

opción “Add JAR/folder”, para buscar los ficheros “.jar” de Weka y que estén enlazados al proyecto.

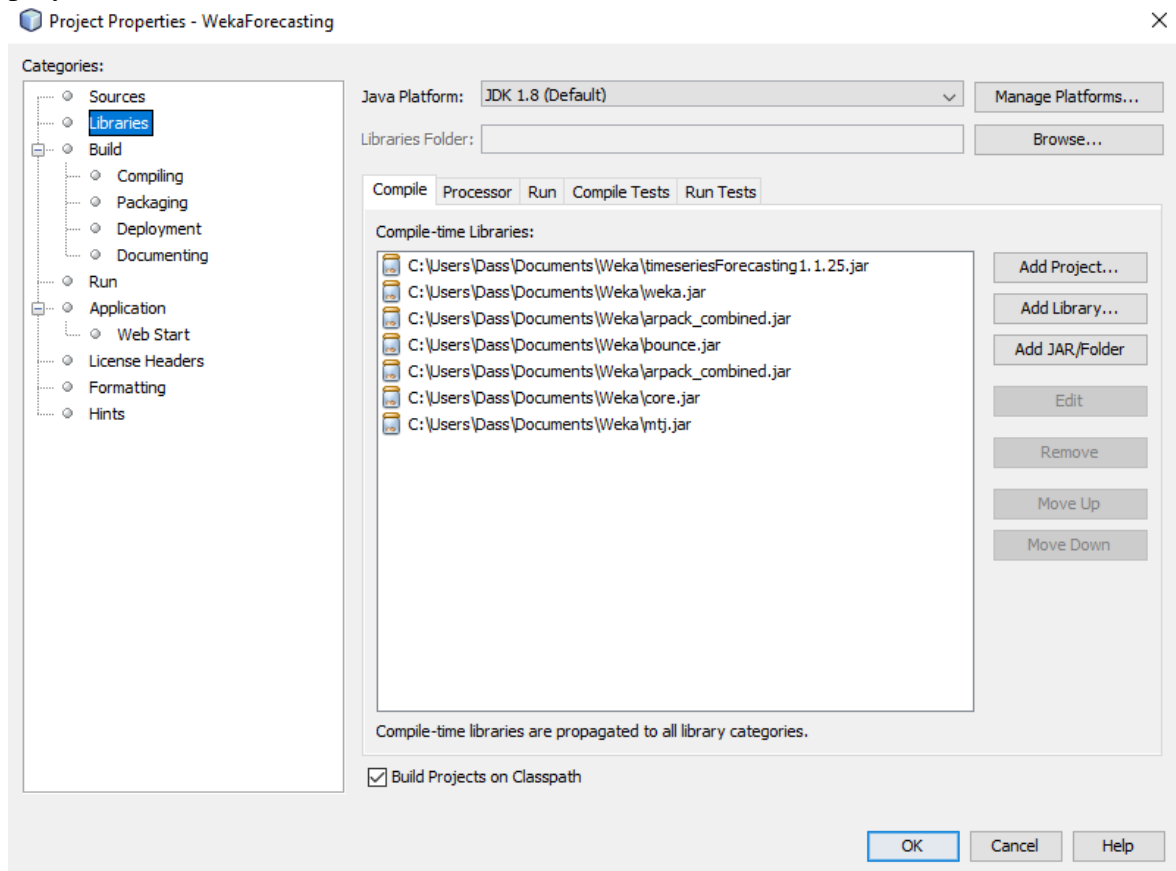


Figura A-4: Vista de la sección Properties>Libraries del proyecto de NetBeans.

Debido a que la versión de Weka utilizada en este TFG fue proporcionada por el tutor, es posible que el nuevo comprimido sea distinto al utilizado en este trabajo por lo que, de ser así, en la Figura A-4 se muestra la lista de los “.jar” utilizados. La mayoría de ellos solo sirven para ejemplos de Weka, pero viene bien observar los ejemplos desarrollados por el equipo de Weka antes de lanzarse a programar sin conocimiento alguno. En el caso de requerir algún “.jar” adicional, resulta sencillo descargarlos de repositorios.

Aparte del uso de Weka mediante código, el “weka.jar” permite hacer uso de la interfaz gráfica de Weka para no tener que escribir líneas de código pero resulta confusa por la cantidad de opciones que tiene, por lo que de usar esta opción se recomienda la búsqueda de documentación y tutoriales. El equipo de Weka ha publicado cursos y documentación para entender su software y que lo pueda usar quien así lo desee.

B Manual del programador

Esta es una version del código básico con comentarios del main del programa.

```
public static void main(String[] args) {
    try {
        // Ruta del fichero ARFF
        String pathToData = "datos.arff";

        // Se cargan las instancias leyendo el fichero ARFF
        Instances data = new Instances(new BufferedReader(new FileReader(pathToData)));

        // Inicialización del forecaster o modelo de forecasting
        WekaForecaster forecaster = new WekaForecaster();

        // Este parámetro marca qué atributo será el que se va a predecir
        forecaster.setFieldsToForecast("CB01");

        // Asignación del algoritmo de Weka que se usará
        forecaster.setBaseForecaster(new GaussianProcesses());

        // Se declara la existencia de un campo de tipo fecha para tener en cuenta la linealidad
        temporal de las muestras
        forecaster.getTSLagMaker().setTimeStampField("Date");

        // Parámetros opcionales que permiten usar muestras atrasadas para dar forma a los datos
        y aportar coherencia
        forecaster.getTSLagMaker().setMinLag(1);
        forecaster.getTSLagMaker().setMaxLag(12); // 12 meses, si se utilizan datos mensuales,
        por ejemplo

        // Con este parámetro establecerá relaciones entre los datos del mismo mes del año
        forecaster.getTSLagMaker().setAddMonthOfYear(true);
        // Con este parámetro establecerá relaciones entre los datos del mismo trimestre del año
        forecaster.getTSLagMaker().setAddQuarterOfYear(true);

        // Se construye el modelo con los datos
        forecaster.buildForecaster(data, System.out);

        // Se entrena el sistema para cubrir como mínimo la ventana del lag fijado
        forecaster.primeForecaster(data);

        // Se fija el número de predicciones de salida
        List<List<NumericPrediction>> forecast = forecaster.forecast(8, System.out);

        // Salida de las predicciones por pantalla (los ocho valores)
        for (int i = 0; i < 8; i++) {
            List<NumericPrediction> predsAtStep = forecast.get(i);
            NumericPrediction predForTarget = predsAtStep.get(0);
        }
    }
}
```

```
        System.out.println("" + predForTarget.predicted());
    }

    } catch (Exception ex) {
        ex.printStackTrace();
    }
}
```

Ese código constituye la versión más sencilla de un código que leería un fichero ARFF, y presentaría por pantalla la predicción de una semana con sus ocho valores futuros.

Los códigos utilizados en este TFG son mucho más densos, llenos de bucles, condiciones, métodos propios desarrollados para facilitar la extracción de datos por fichero y por pantalla, y con todos los algoritmos del estudio, por lo que no sé verán en este apartado.

C Anexo de Tablas Adicionales

Forecasting de RandomForest											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	35.992	37.112	41.649	39.991	43.817	44.316	38.952	38.424	36.552	38.686	40.032
2	35.778	42.479	41.276	47.647	47.389	41.362	40.358	39.981	39.129	41.795	42.034
3	43.346	44.280	45.905	45.998	44.377	42.007	41.935	40.759	43.813	44.882	43.576
4	48.635	50.704	50.449	49.406	45.485	43.332	42.288	42.114	49.670	49.799	46.552
5	53.814	51.778	45.831	43.965	43.567	41.914	41.583	42.868	52.796	48.847	45.665
6	41.043	40.689	40.148	39.852	39.898	39.962	41.338	41.712	40.866	40.433	40.580
7	55.622	49.219	48.814	43.655	42.228	43.136	41.418	43.057	52.421	49.328	45.894
8	42.623	42.984	44.095	43.624	43.478	44.028	47.289	46.880	42.804	43.332	44.375
9	51.067	42.968	45.933	44.170	43.447	45.217	45.933	45.779	47.018	46.035	45.564
10	44.717	45.685	44.898	43.861	41.802	45.152	44.686	45.441	45.201	44.790	44.530
11	43.854	46.008	41.513	45.677	46.816	45.906	46.380	40.713	44.931	44.263	44.608
12	45.343	48.553	44.367	45.194	43.765	43.685	40.702	39.854	46.948	45.864	43.933
13	38.616	43.741	38.018	47.448	42.572	42.193	41.984	39.337	41.179	41.956	
14	46.052	41.377	50.475	38.573	49.171	34.045	41.251	42.328	43.715	44.119	
15	40.967	46.463	39.749	46.710	37.367	44.090	41.685	41.134	43.715	43.472	
16	47.908	41.443	45.229	35.982	42.373	39.590	40.752	55.560	44.676	42.641	
17	39.721	42.920	35.813	40.579	38.707	40.832	55.419	53.522	41.321		
18	46.449	38.532	41.673	40.022	42.446	51.337	53.546	52.970	42.491		
19	38.652	46.845	42.173	45.970	52.284	53.486	52.494	52.712			

Tabla C-1: Predicciones de RandomForest para el cable CB01.

Forecasting de SMOreg											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	20.065	32.955	44.684	67.686	65.642	62.352	43.246	20.218	26.510	41.348	44.606
2	43.522	55.095	77.823	67.914	56.429	35.724	12.062	0	49.309	61.089	43.571
3	59.006	80.999	66.727	54.500	32.490	8.721	0	4.159	70.003	65.308	38.325
4	71.642	55.161	45.540	24.915	14.453	3.464	18.447	28.008	63.402	49.315	32.704
5	38.022	34.334	28.179	30.508	31.539	34.354	34.832	34.385	36.178	32.761	33.269
6	24.258	18.247	20.606	25.540	36.491	34.362	35.177	29.260	21.253	22.163	27.993
7	54.423	48.628	45.050	31.889	33.255	44.362	27.317	28.342	51.526	44.998	39.158
8	36.606	35.022	25.793	30.738	43.295	25.500	34.889	36.316	35.814	32.040	33.520
9	50.253	37.543	33.542	47.001	30.738	50.143	47.410	41.615	43.898	42.085	42.281
10	41.490	37.415	51.277	32.546	51.396	52.022	43.811	48.428	39.453	40.682	44.798
11	36.624	50.516	31.915	51.418	52.384	44.086	48.501	41.240	43.570	42.618	44.586
12	58.028	40.550	58.979	32.089	43.527	59.455	26.821	51.553	49.289	47.412	46.375
13	40.057	51.433	23.677	58.548	40.853	21.773	64.193	23.145	45.745	43.429	
14	68.012	41.048	77.864	43.488	44.460	76.457	25.489	62.741	54.530	57.603	
15	11.900	48.191	13.595	40.587	64.500	17.644	63.836	43.946	30.046	28.568	
16	42.731	48.286	49.752	40.822	58.195	44.576	50.960	60.656	45.509	45.398	
17	47.920	42.210	37.411	47.793	42.152	42.514	59.107	65.835	45.065		

18	43.478	44.868	50.645	49.096	45.721	65.888	70.303	65.949	44.173
19	50.624	57.594	55.275	53.204	71.159	77.025	73.169	75.149	

Tabla C-2: Predicciones de SMOreg para el cable CB01.

Forecasting de RegressionByDiscretization											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	49.957	49.957	49.957	49.957	49.957	49.957	49.957	49.957	49.957	49.957	49.957
2	31.653	31.653	31.653	49.441	49.441	49.441	49.441	49.441	31.653	36.100	42.771
3	38.462	38.462	49.386	49.386	49.386	49.386	49.386	49.386	38.462	43.924	46.655
4	49.339	49.339	49.339	49.339	49.339	49.339	49.339	49.339	49.339	49.339	49.339
5	49.254	49.254	49.254	49.254	49.254	49.254	49.254	49.254	49.254	49.254	49.254
6	30.850	30.850	30.850	30.850	48.713	48.713	48.713	48.713	30.850	30.850	39.782
7	49.204	49.204	49.204	49.182	49.182	49.182	49.182	49.182	49.204	49.199	49.190
8	45.541	45.541	48.982	48.982	48.982	48.982	48.982	48.982	45.541	47.262	48.122
9	48.734	49.172	49.172	49.172	49.172	49.172	49.172	49.172	48.953	49.063	49.117
10	49.373	49.373	49.373	49.373	49.373	49.373	49.373	49.373	49.373	49.373	49.373
11	38.544	38.544	38.544	49.183	49.183	49.183	49.183	34.697	38.544	41.204	43.383
12	53.295	53.295	49.636	49.636	49.636	49.636	34.697	34.697	53.295	51.466	46.816
13	39.697	48.899	48.899	48.899	48.899	34.697	34.697	34.697	44.298	46.599	
14	49.255	49.255	49.255	49.255	34.697	34.697	34.697	34.697	49.255	49.255	
15	38.595	38.595	38.595	34.722	34.722	34.722	34.722	34.722	38.595	37.627	
16	42.191	42.191	34.722	34.722	34.722	34.722	34.722	49.634	42.191	38.457	
17	38.319	34.586	34.586	34.586	34.586	34.586	49.634	49.634	36.453		
18	34.586	34.586	34.586	34.586	34.586	49.634	49.634	49.634	34.586		
19	40.264	40.264	40.264	40.264	72.102	72.102	72.102	72.102			

Tabla C-3: Predicciones de RegressionByDiscretization para el cable CB01.

Forecasting de AdditiveRegression											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	16.922	35.504	31.692	10.760	42.482	42.482	71.239	19.309	26.213	23.720	33.799
2	24.512	31.942	3.178	44.653	44.653	22.218	44.653	3.178	28.227	26.071	27.373
3	43.277	31.884	65.759	74.997	88.727	52.514	26.063	43.481	37.581	53.979	53.338
4	32.062	65.732	74.825	88.995	52.719	26.402	43.836	40.097	48.897	65.404	53.084
5	68.211	68.211	86.063	50.488	50.488	31.415	21.999	51.332	68.211	68.243	53.526
6	33.788	38.770	38.770	38.770	24.758	24.758	24.758	24.758	36.279	37.525	31.141
7	50.305	56.164	47.241	35.458	53.761	41.662	38.598	47.241	53.235	47.292	46.304
8	49.006	49.006	32.365	28.716	32.365	49.006	49.006	32.365	49.006	39.773	40.229
9	45.355	32.708	45.438	26.798	31.591	45.355	32.708	45.355	39.032	37.575	38.164
10	30.446	49.660	29.277	36.839	27.906	21.512	49.660	21.512	40.053	36.556	33.352
11	51.048	24.089	37.437	27.984	41.932	37.437	29.540	52.604	37.569	35.140	37.759
12	38.118	38.609	30.018	50.923	57.458	29.526	38.118	29.526	38.364	39.417	39.037
13	34.180	26.542	40.920	54.174	42.847	49.877	23.834	46.258	30.361	38.954	

14	43.465	34.600	68.046	39.872	100.909	43.465	34.600	68.046	39.033	46.496
15	24.786	72.069	34.507	76.772	23.173	45.283	81.762	24.786	48.428	52.034
16	66.254	37.935	77.496	26.620	49.574	66.254	34.831	73.023	52.095	52.076
17	34.499	47.377	18.847	51.307	24.982	48.109	39.266	46.539	40.938	
18	51.288	26.398	49.675	26.398	61.286	48.546	36.787	60.157	38.843	
19	28.478	51.164	35.693	51.164	40.670	46.188	53.602	28.478		

Tabla C-4: Predicciones de AdditiveRegression para el cable CB01.

Forecasting de MSP											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	58.327	58.327	58.327	58.327	58.327	58.327	58.327	58.327	58.327	58.327	58.327
2	35.477	35.477	35.477	58.327	58.327	58.327	58.327	58.327	35.477	41.190	49.758
3	36.273	36.273	58.327	58.327	58.327	58.327	58.327	58.327	36.273	47.300	52.814
4	36.981	58.327	58.327	58.327	58.327	58.327	58.327	58.327	47.654	52.991	55.659
5	58.327	58.327	58.327	58.327	58.327	58.327	58.327	58.327	58.327	58.327	58.327
6	36.963	36.963	36.963	36.963	58.327	58.327	58.327	58.327	36.963	36.963	47.645
7	38.593	38.593	38.593	58.327	58.327	58.327	58.327	58.327	38.593	43.527	50.927
8	56.782	56.782	56.782	56.782	56.782	56.782	56.782	56.782	56.782	56.782	56.782
9	56.796	56.796	56.796	56.796	56.796	56.796	56.796	56.796	56.796	56.796	56.796
10	46.916	54.055	49.323	48.837	51.763	49.481	50.644	50.576	50.486	49.783	50.199
11	37.697	37.697	37.697	56.841	56.841	56.841	56.841	37.697	37.697	42.483	47.269
12	49.442	48.940	53.752	44.818	50.768	50.702	30.400	33.001	49.191	49.238	45.228
13	38.178	56.841	56.841	56.841	56.841	38.178	38.178	38.178	47.510	52.175	
14	49.449	41.897	59.764	39.181	53.735	23.719	37.163	38.810	45.673	47.573	
15	25.105	43.689	25.793	35.030	39.828	32.925	39.319	35.727	34.397	32.404	
16	38.163	38.163	38.163	38.163	38.163	38.163	38.163	55.695	38.163	38.163	
17	37.715	37.715	37.715	37.715	37.715	37.715	55.695	55.695	37.715		
18	33.497	37.772	35.789	39.082	34.220	48.323	47.193	47.360	35.635		
19	25.195	34.312	30.794	37.451	44.890	45.712	54.757	51.183			

Tabla C-5: Predicciones de MSP para el cable CB01.

Forecasting de LinearRegression											
W	W	W+1	W+2	W+3	W+4	W+5	W+6	W+7	MEDIA_2	MEDIA_4	MEDIA_8
1	35.793	35.793	35.793	35.793	35.793	35.793	35.793	35.793	35.793	35.793	35.793
2	35.477	35.477	35.477	35.477	35.477	35.477	35.477	35.477	35.477	35.477	35.477
3	56.749	56.749	56.749	56.749	56.749	56.749	56.749	56.749	56.749	56.749	56.749
4	56.383	56.383	56.383	56.383	56.383	56.383	56.383	56.383	56.383	56.383	56.383
5	59.812	56.312	50.516	51.656	52.095	26.509	29.694	31.731	58.062	54.574	44.791
6	34.713	29.675	31.882	32.334	59.755	52.375	56.265	53.730	32.194	32.151	43.841
7	34.067	34.609	35.028	60.612	40.897	60.365	55.973	55.650	34.338	41.079	47.150
8	42.979	42.808	47.666	34.762	42.671	41.386	40.876	38.539	42.894	42.054	41.461
9	44.372	48.761	37.096	44.242	38.751	42.120	40.141	43.536	46.567	43.618	42.377

10	46.663	28.707	45.109	34.074	36.334	41.518	47.636	35.959	37.685	38.638	39.500
11	13.780	33.814	19.739	41.481	50.262	60.618	41.979	36.435	23.797	27.204	37.264
12	55.089	55.089	55.089	55.089	55.089	55.089	35.793	35.793	55.089	55.089	50.265
13	42.543	41.825	44.535	38.265	49.187	23.251	22.997	21.931	42.184	41.792	
14	45.919	45.348	50.917	40.605	42.343	24.072	31.005	30.984	45.634	45.697	
15	37.595	37.595	37.595	37.595	37.595	37.595	37.595	37.595	37.595	37.595	
16	50.771	40.237	42.602	23.938	33.578	29.858	28.707	49.539	45.504	39.387	
17	41.299	41.299	41.299	41.299	41.299	41.299	58.327	58.327	41.299		
18	41.688	41.688	41.688	41.688	41.688	58.327	58.327	58.327	41.688		
19	41.957	41.957	41.957	41.957	58.327	58.327	58.327	58.327			

Tabla C-6: Predicciones de LinearRegression para el cable CB01.

W	ACTUAL	MAE_2						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	6.964,00	552,00	2.836,00	12.878,00	10.569,00	13.175,00	18.939,00	3.595,00
2	8.237,50	10.908,00	8.385,00	1.795,00	15.860,50	19.286,50	12.036,50	12.036,50
3	5.126,00	472,50	2.994,00	23.195,50	8.345,00	9.226,50	10.534,00	9.942,00
4	4.806,50	12.743,00	12.852,00	26.584,00	12.521,50	12.079,50	10.836,50	19.565,50
5	4.665,00	190,50	5.009,00	11.609,00	1.467,00	20.424,00	10.540,00	10.275,00
6	13.282,50	22.155,00	13.491,50	33.105,00	23.507,50	18.078,50	17.394,50	22.163,50
7	8.424,00	3.039,50	3.453,50	2.558,50	237,00	4.267,50	10.374,00	14.629,00
8	15.412,50	16.260,50	14.775,00	21.764,50	12.037,50	8.572,50	796,50	14.685,00
9	4.775,00	5.647,50	2.407,50	5.527,00	472,00	10.393,50	7.371,00	2.858,50
10	9.541,00	12.046,50	10.224,00	15.972,50	6.052,00	15.372,00	4.939,50	17.740,00
11	3.027,00	697,00	2.431,00	1.070,00	3.956,00	4.931,50	4.803,00	18.703,00
12	7.884,00	11.383,00	6.448,00	8.789,00	12.795,00	2.136,50	8.691,00	14.589,00
13	4.122,00	8.651,50	11.321,50	6.755,00	8.202,00	22.139,00	4.990,50	10.316,00
14	7.811,50	3.201,00	18,00	10.833,50	5.558,50	4.664,00	1.976,50	1.937,00
15	12.727,00	4.627,00	4.914,00	8.755,50	206,00	9.626,50	4.404,00	1.206,00
16	9.700,00	4.745,00	3.587,50	4.420,50	1.103,00	11.006,50	2.925,00	4.416,00
17	4.174,50	11.360,00	10.184,00	6.439,50	15.052,00	10.566,50	13.789,50	10.205,50
18	9.806,00	16.425,00	15.530,50	13.848,00	23.435,00	19.178,00	22.386,50	16.333,00

Tabla C-7: Comparativa del MAE_2 para el cable CB01.

W	ACTUAL	MAE_4						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	3.254,50	726,50	4.411,50	1.750,00	6.859,50	19.378,00	15.229,50	7.304,50
2	2.889,50	2.056,25	370,50	18.923,00	6.065,50	16.094,25	976,00	6.688,50
3	5.616,00	165,00	2.414,75	18.011,00	3.373,00	6.682,25	3,00	9.452,00
4	3.963,50	2.316,25	4.211,00	3.727,00	3.751,50	19.816,00	7.403,00	10.795,50
5	5.255,00	3.170,25	470,00	15.616,25	877,00	19.866,25	9.950,00	6.197,00
6	14.893,00	25.239,50	15.535,00	33.805,25	25.118,00	18.443,50	19.005,00	23.817,00

7	8.653,00	5.082,50	131,50	4.198,50	2,50	1.904,00	5.669,50	8.117,00
8	14.335,75	15.942,00	13.170,25	24.462,00	9.240,25	16.728,50	280,25	14.448,00
9	1.312,50	2.386,75	72,00	3.877,75	3.100,00	8.387,75	10.833,50	2.344,75
10	2.078,50	4.725,00	3.172,25	7.280,50	1.410,50	11.407,00	1.820,25	9.324,25
11	1.973,00	4.547,50	3.237,00	4.881,75	6.296,25	12.360,50	5.017,00	20.296,50
12	6.285,75	8.763,25	3.766,00	5.313,25	9.367,25	2.681,25	7.139,75	12.990,75
13	2.727,50	458,25	3.694,75	2.221,75	948,00	6.696,50	6.524,75	3.858,50
14	9.115,75	5.531,50	1.727,00	15.210,75	6.862,75	4.103,50	5.180,50	3.305,00
15	6.375,25	2.640,50	1.680,50	16.584,50	7.526,00	6.880,75	12.748,50	7.557,75
16	1.233,50	4.545,00	6.914,00	4.156,75	11.098,00	2.521,75	11.391,50	10.167,50

Tabla C-8: Comparativa del MAE_4 para el cable CB01.

W	ACTUAL	MAE_8						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	614,75	2.091,25	5.705,63	1.131,25	4.219,75	11.938,50	12.589,75	9.944,25
2	9.790,75	8.677,13	7.033,00	5.495,63	6.296,25	21.693,38	691,50	13.589,75
3	6.565,50	4.514,13	4.670,63	9.921,25	1.591,50	5.091,25	4.567,00	8.502,50
4	9.420,63	7.154,13	4.493,00	18.340,88	1.705,63	2.038,88	4.614,13	5.338,38
5	4.047,75	4.738,13	1.504,75	13.900,63	2.084,25	6.356,13	11.157,25	2.379,13
6	10.890,25	17.851,75	11.385,00	23.972,63	12.183,75	20.824,00	4.320,25	8.124,13
7	7.805,00	6.151,63	2.454,38	9.189,75	842,25	2.044,25	2.578,75	1.197,88
8	7.134,00	7.363,63	4.924,88	15.780,13	1.178,25	9.070,63	7.482,00	7.839,13
9	1.156,50	1.954,25	242,25	3.525,88	3.310,75	7.643,00	10.989,50	3.429,13
10	706,63	94,00	647,13	379,25	4.195,63	11.825,88	5.022,00	5.677,38
11	799,38	974,88	1.718,00	1.740,88	2.943,75	8.567,50	942,63	9.062,88
12	2.557,63	2.774,00	1.893,50	548,88	989,63	6.789,38	598,50	4.438,63

Tabla C-9: Comparativa del MAE_8 para el cable CB01.

W	ACTUAL	RMSE_1		
		GP	RF	SMOreg
1	14.988,00	6.990,00	4.628,00	11.299,00
2	8.136,00	13.196,00	11.634,00	3.890,00
3	5.934,00	3.840,00	4.269,00	11.391,00
4	4.375,00	3.801,00	2.636,00	25.643,00
5	15.486,00	20.336,00	26.178,00	10.386,00
6	26.863,00	34.304,00	26.895,00	43.680,00
7	234,00	6.368,00	14.845,00	13.646,00
8	14.991,00	15.287,00	14.534,00	20.551,00
9	13.350,00	13.088,00	6.933,00	7.747,00
10	5.034,00	2.790,00	3.867,00	640,00
11	24.473,00	28.531,00	26.146,00	33.376,00
12	33.384,00	39.242,00	30.343,00	43.028,00

13	17.622,00	25.384,00	27.384,00	25.943,00
14	12.508,00	9.728,00	7.052,00	29.012,00
15	3.135,00	10.042,00	7.426,00	36.493,00
16	21.579,00	22.315,00	18.699,00	13.522,00
17	5.637,00	16.458,00	13.246,00	5.047,00
18	1.827,00	6.101,00	3.593,00	6.564,00
19	15.591,00	24.469,00	27.348,00	15.376,00

Tabla C-10: Primera parte de la comparativa del RMSE_1 para el cable CB01.

W	RMSE_1			
	RBD	AR	M5P	LR
1	18.593,00	14.442,00	26.963,00	4.429,00
2	15.759,00	22.900,00	11.935,00	11.935,00
3	9.153,00	4.338,00	11.342,00	9.134,00
4	3.340,00	13.937,00	9.018,00	10.384,00
5	21.618,00	40.575,00	30.691,00	32.176,00
6	37.088,00	34.150,00	30.975,00	33.225,00
7	8.427,00	9.528,00	2.184,00	6.710,00
8	11.616,00	8.151,00	375,00	14.178,00
9	9.266,00	12.645,00	1.204,00	13.628,00
10	8.523,00	10.404,00	6.066,00	5.813,00
11	31.456,00	18.952,00	32.303,00	56.220,00
12	38.295,00	23.118,00	34.442,00	40.089,00
13	26.303,00	31.820,00	27.822,00	23.457,00
14	10.255,00	4.465,00	10.449,00	6.919,00
15	9.798,00	23.607,00	23.288,00	10.798,00
16	12.982,00	37.045,00	8.954,00	21.562,00
17	14.648,00	18.468,00	15.252,00	11.668,00
18	15.456,00	1.246,00	16.545,00	8.354,00
19	25.736,00	37.522,00	40.805,00	24.043,00

Tabla C-11: Segunda parte de la comparativa del RMSE_1 para el cable CB01.

W	RMSE_1			
	ACTUAL	GP	RF	SMOreg
1	14.988,00	6.990,00	4.628,00	11.299,00
2	8.136,00	13.196,00	11.634,00	3.890,00
3	5.934,00	3.840,00	4.269,00	11.391,00
4	4.375,00	3.801,00	2.636,00	25.643,00
5	15.486,00	20.336,00	26.178,00	10.386,00
6	26.863,00	34.304,00	26.895,00	43.680,00
7	234,00	6.368,00	14.845,00	13.646,00
8	14.991,00	15.287,00	14.534,00	20.551,00

9	13.350,00	13.088,00	6.933,00	7.747,00
10	5.034,00	2.790,00	3.867,00	640,00
11	24.473,00	28.531,00	26.146,00	33.376,00
12	33.384,00	39.242,00	30.343,00	43.028,00
13	17.622,00	25.384,00	27.384,00	25.943,00
14	12.508,00	9.728,00	7.052,00	29.012,00
15	3.135,00	10.042,00	7.426,00	36.493,00
16	21.579,00	22.315,00	18.699,00	13.522,00
17	5.637,00	16.458,00	13.246,00	5.047,00
18	1.827,00	6.101,00	3.593,00	6.564,00
19	15.591,00	24.469,00	27.348,00	15.376,00

Tabla C-12: Primera parte de la comparativa del RMSE_2 para el cable CB01.

RMSE_2				
W	RBD	AR	M5P	LR
1	13.269,83	13.235,78	20.568,67	8.792,53
2	15.860,82	19.622,09	12.036,93	12.036,93
3	8.384,03	10.441,54	10.564,94	9.974,78
4	15.527,01	28.684,01	22.619,26	21.612,70
5	20.204,33	28.691,51	22.741,03	24.191,52
6	27.148,34	24.189,36	22.068,05	24.770,50
7	8.193,43	6.773,80	13.217,26	16.634,85
8	12.044,88	8.582,86	901,15	14.693,75
9	8.806,66	10.634,57	11.307,62	11.142,40
10	15.781,55	16.154,86	12.063,15	29.486,46
11	27.783,09	14.862,51	27.916,28	41.920,49
12	28.530,02	25.344,71	27.178,07	29.378,38
13	19.872,57	24.163,13	23.370,55	16.706,46
14	7.276,95	10.251,42	8.699,99	5.345,31
15	9.594,21	34.599,64	19.390,74	9.667,52
16	11.930,10	28.269,18	12.233,82	17.705,55
17	15.057,42	13.194,11	13.866,84	10.309,76
18	24.756,08	28.016,70	23.136,09	18.177,77

Tabla C-13: Segunda parte de la comparativa del RMSE_2 para el cable CB01.

RMSE_4				
W	ACTUAL	GP	RF	SMOreg
1	7.541,28	5.654,30	7.056,87	14.279,26
2	8.894,12	11.813,78	12.087,96	26.010,42
3	15.334,19	14.848,64	14.459,42	27.674,18

4	15.066,09	14.875,42	15.160,85	23.283,38
5	16.264,46	16.531,50	16.926,35	22.945,46
6	17.796,04	26.839,72	18.316,69	34.659,67
7	12.051,15	10.247,75	9.690,67	11.257,88
8	17.691,16	19.211,92	16.903,70	26.069,86
9	20.702,70	21.822,44	19.252,67	24.618,09
10	22.166,40	24.688,60	22.305,82	29.569,34
11	22.319,11	25.402,08	23.923,34	30.378,19
12	19.447,84	22.367,90	17.777,33	28.125,13
13	13.837,74	17.927,44	17.411,65	23.975,38
14	12.898,91	15.181,47	13.769,39	28.951,71
15	11.316,41	14.077,15	11.604,57	28.860,04
16	13.251,06	18.890,51	18.753,00	14.480,78

Tabla C-14: Primera parte de la comparativa del RMSE_4 para el cable CB01.

W	RMSE_4			
	RBD	AR	M5P	LR
1	9.660,84	21.480,81	16.679,83	9.981,72
2	17.207,54	26.894,56	18.319,56	10.746,73
3	15.474,36	20.743,94	17.730,94	17.115,44
4	15.011,72	31.693,66	18.865,55	18.105,82
5	15.417,09	30.584,73	18.328,12	17.997,00
6	26.940,89	21.668,67	21.356,21	25.123,32
7	8.382,37	7.690,88	16.058,25	19.181,28
8	14.124,84	21.929,97	10.370,25	20.736,36
9	20.956,18	15.561,75	23.329,04	23.377,74
10	22.113,77	19.850,41	20.998,07	30.268,48
11	24.501,66	18.567,35	25.874,69	37.619,44
12	20.872,19	18.518,81	20.662,15	22.527,04
13	17.159,47	21.487,27	21.950,29	12.797,53
14	11.418,51	21.736,92	17.853,86	13.049,91
15	12.503,55	29.366,37	20.711,03	12.022,35
16	19.349,87	31.236,20	17.430,88	24.756,51

Tabla C-15: Segunda parte de la comparativa del RMSE_4 para el cable CB01.

W	RMSE_8			
	ACTUAL	GP	RF	SMOreg
1	12.204,28	12.323,50	13.101,89	21.394,61
2	15.043,70	15.183,73	14.203,74	32.135,87
3	13.453,04	13.870,90	12.927,08	35.686,82
4	16.670,31	17.393,44	16.009,72	33.969,64
5	18.701,34	19.213,56	19.168,99	23.613,89

6	20.629,66	25.783,32	21.002,35	31.327,26
7	18.545,62	19.068,59	17.886,06	23.262,76
8	18.051,17	19.879,64	17.704,88	25.792,83
9	17.516,37	19.391,42	16.994,73	22.211,07
10	17.129,31	18.892,20	16.973,26	22.073,84
11	17.112,86	18.979,57	18.374,58	22.433,27
12	16.638,18	19.472,53	17.077,09	22.801,10

Tabla C-16: Primera parte de la comparativa del RMSE_8 para el cable CB01.

RMSE_8				
W	RBD	AR	M5P	LR
1	12.898,56	25.185,60	17.523,37	15.730,69
2	14.724,11	29.456,96	14.765,99	17.752,05
3	12.446,84	25.171,66	15.298,97	14.497,27
4	13.858,57	27.246,99	15.275,86	14.752,94
5	18.376,61	30.641,60	21.397,20	20.738,25
6	24.631,32	27.340,53	22.918,77	25.115,03
7	16.842,55	15.929,33	20.848,76	24.378,31
8	17.111,47	18.944,16	18.191,52	19.975,43
9	17.827,03	18.370,32	20.645,94	20.036,45
10	17.621,50	21.878,87	17.294,98	23.312,88
11	19.527,86	15.983,66	21.448,49	29.488,97
12	20.573,95	22.890,52	21.366,91	21.850,76

Tabla C-17: Segunda parte de la comparativa del RMSE_8 para el cable CB01.

MAPE_1								
W	ACTUAL	GP	RF	SMOreg	RBD	AR	M5P	LR
1	0,4779	0,2229	0,1476	0,3603	0,5928	0,4605	0,8597	0,1412
2	0,1716	0,2783	0,2454	0,0820	0,3324	0,4830	0,2517	0,2517
3	0,1246	0,0806	0,0897	0,2392	0,1922	0,0911	0,2382	0,1918
4	0,0951	0,0826	0,0573	0,5575	0,0726	0,3030	0,1960	0,2257
5	0,5604	0,7359	0,9472	0,3758	0,7822	1,4682	1,1105	1,1643
6	0,3954	0,5049	0,3959	0,6429	0,5459	0,5027	0,4559	0,4890
7	0,0057	0,1562	0,3641	0,3346	0,2067	0,2337	0,0536	0,1646
8	0,2623	0,2675	0,2543	0,3596	0,2032	0,1426	0,0066	0,2481
9	0,2302	0,2257	0,1195	0,1336	0,1598	0,2180	0,0208	0,2350
10	0,1232	0,0683	0,0947	0,0157	0,2086	0,2547	0,1485	0,1423
11	0,3496	0,4076	0,3735	0,4768	0,4494	0,2707	0,4615	0,8031
12	2,2256	2,6161	2,0229	2,8685	2,5530	1,5412	2,2961	2,6726
13	0,2670	0,3846	0,4149	0,3931	0,3985	0,4821	0,4215	0,3554
14	0,3207	0,2494	0,1808	0,7439	0,2629	0,1145	0,2679	0,1774
15	0,0648	0,2075	0,1535	0,7541	0,2025	0,4878	0,4812	0,2231

16	0,7388	0,7640	0,6402	0,4629	0,4445	1,2683	0,3065	0,7382
17	0,1064	0,3107	0,2501	0,0953	0,2765	0,3487	0,2880	0,2203
18	0,0365	0,1219	0,0718	0,1312	0,3089	0,0249	0,3306	0,1669
19	0,2362	0,3707	0,4144	0,2330	0,3899	0,5685	0,6183	0,3643

Tabla C-18: Comparativa del MAPE_1 para el cable CB01.

W	ACTUAL	MAPE_2						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	0,2501	0,1968	0,1824	0,3326	0,3232	0,3558	0,5449	0,1931
2	0,1734	0,2297	0,1766	0,1196	0,3338	0,4061	0,2533	0,2533
3	0,1092	0,0718	0,0635	0,5001	0,1780	0,1990	0,2248	0,2128
4	0,3006	0,4336	0,4460	0,7767	0,4290	0,8407	0,6533	0,6330
5	0,4628	0,5204	0,5926	0,4352	0,5286	0,7361	0,6260	0,6677
6	0,2014	0,3752	0,1990	0,5977	0,3947	0,2759	0,2747	0,3807
7	0,1482	0,1870	0,2515	0,2419	0,1729	0,1255	0,1892	0,2795
8	0,2676	0,2823	0,2566	0,3779	0,2090	0,1488	0,0138	0,2550
9	0,1616	0,1348	0,0857	0,1073	0,1817	0,2087	0,2056	0,2143
10	0,2339	0,2262	0,2210	0,2406	0,2517	0,2726	0,1881	0,3661
11	1,1924	1,2013	1,2204	1,4223	1,0095	0,4383	0,9873	1,0287
12	1,2463	1,4329	1,1436	1,6271	1,3728	0,9781	1,2773	1,4190
13	0,2537	0,2959	0,2682	0,3559	0,3262	0,4008	0,4395	0,2139
14	0,1925	0,1591	0,1629	0,4478	0,1404	0,1998	0,2011	0,1202
15	0,4144	0,4341	0,3721	0,7020	0,2619	0,9776	0,4885	0,2551
16	0,3900	0,5031	0,4289	0,2757	0,3239	0,7760	0,2930	0,4893
17	0,0803	0,2179	0,1962	0,1259	0,2927	0,2010	0,2671	0,1975
18	0,1530	0,2636	0,2440	0,2257	0,3924	0,3125	0,3792	0,2677

Tabla C-19: Comparativa del MAPE_2 para el cable CB01.

W	ACTUAL	MAPE_4						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	0,1336	0,1243	0,1552	0,2995	0,1954	0,4530	0,3957	0,2141
2	0,2285	0,2904	0,2950	0,5971	0,4421	0,5897	0,4615	0,2548
3	0,2783	0,3004	0,2778	0,6531	0,3540	0,4703	0,4254	0,4109
4	0,2523	0,3107	0,3403	0,5680	0,3354	0,7413	0,4696	0,4547
5	0,3072	0,3476	0,3850	0,4114	0,3509	0,6749	0,4257	0,4176
6	0,2440	0,4335	0,2521	0,5986	0,4294	0,3013	0,3164	0,4115
7	0,1512	0,1624	0,1825	0,2316	0,1754	0,1421	0,2852	0,3597
8	0,2413	0,2540	0,2424	0,4213	0,2293	0,2738	0,1516	0,2951
9	0,6655	0,6739	0,6150	0,7172	0,7348	0,3887	0,8465	0,7120
10	0,7079	0,7418	0,6927	0,8516	0,7617	0,4847	0,7311	0,8058
11	0,7156	0,7630	0,7457	0,9198	0,6740	0,3980	0,7152	0,7055
12	0,6833	0,8116	0,6227	1,0258	0,7610	0,5597	0,7517	0,8472

13	0,2910	0,3815	0,3438	0,5568	0,3342	0,4527	0,4999	0,2044
14	0,2940	0,3568	0,3314	0,6851	0,2593	0,4941	0,4271	0,3042
15	0,2214	0,3111	0,2651	0,5841	0,2753	0,7095	0,4475	0,2623
16	0,2563	0,3564	0,3522	0,2346	0,3570	0,6743	0,3113	0,4411

Tabla C-20: Comparativa del MAPE_4 para el cable CB01.

		MAPE_8						
W	ACTUAL	GP	RF	SMOreg	RBD	AR	M5P	LR
1	0,2319	0,2309	0,2408	0,4203	0,2756	0,5167	0,4107	0,2651
2	0,2511	0,2725	0,2627	0,5588	0,3170	0,5401	0,3055	0,2993
3	0,2135	0,2428	0,2179	0,6952	0,2651	0,4692	0,3232	0,3067
4	0,2485	0,2893	0,2815	0,6385	0,2663	0,5110	0,3124	0,3044
5	0,4749	0,4770	0,5098	0,5070	0,5425	0,7710	0,6489	0,4768
6	0,4388	0,5365	0,4481	0,6140	0,5905	0,4401	0,6081	0,6622
7	0,3942	0,4301	0,4349	0,5335	0,4742	0,4006	0,6010	0,6822
8	0,4184	0,4450	0,4306	0,5675	0,4636	0,3873	0,5201	0,4562
9	0,4670	0,4931	0,4474	0,5167	0,5193	0,3895	0,6375	0,5003
10	0,4706	0,4914	0,4477	0,5481	0,5114	0,5091	0,5067	0,5482
11	0,4639	0,4689	0,4872	0,5664	0,4718	0,3126	0,5377	0,5519
12	0,4720	0,5595	0,4684	0,6749	0,5734	0,5549	0,5850	0,6322

Tabla C-21: Comparativa del MAPE_8 para el cable CB01.

		SMAPE_1						
W	ACTUAL	GP	RF	SMOreg	RBD	AR	M5P	LR
1	0,1929	0,1003	0,0687	0,2197	0,2286	0,2991	0,3006	0,0659
2	0,0939	0,1617	0,1398	0,0428	0,1993	0,3184	0,1440	0,1440
3	0,0665	0,0420	0,0469	0,1068	0,1063	0,0477	0,1352	0,0875
4	0,0499	0,0397	0,0279	0,2180	0,0350	0,1785	0,1087	0,1014
5	0,2189	0,2690	0,3214	0,1582	0,2812	0,4233	0,3570	0,3679
6	0,2464	0,3377	0,2468	0,4738	0,3754	0,3357	0,2953	0,3237
7	0,0029	0,0724	0,1540	0,1433	0,0937	0,1046	0,0275	0,0897
8	0,1509	0,1544	0,1457	0,2192	0,1131	0,0768	0,0033	0,1416
9	0,1301	0,1272	0,0636	0,0716	0,0868	0,1223	0,0105	0,1331
10	0,0580	0,0330	0,0452	0,0078	0,0945	0,1459	0,0691	0,0664
11	0,2118	0,2560	0,2296	0,3130	0,2898	0,1566	0,2999	0,6710
12	0,5267	0,5667	0,5028	0,5892	0,5607	0,4352	0,5345	0,5720
13	0,1541	0,2381	0,2618	0,2446	0,2489	0,3176	0,2671	0,2161
14	0,1382	0,1109	0,0829	0,2711	0,1162	0,0541	0,1181	0,0815
15	0,0314	0,1158	0,0831	0,6053	0,1126	0,3226	0,3169	0,1256
16	0,2697	0,2764	0,2425	0,1880	0,1818	0,3881	0,1329	0,2696
17	0,0562	0,1839	0,1429	0,0500	0,1605	0,2111	0,1682	0,1238
18	0,0186	0,0649	0,0372	0,0702	0,1826	0,0123	0,1981	0,0911

19	0,1339	0,2276	0,2613	0,1318	0,2422	0,3972	0,4474	0,2227
----	--------	--------	--------	--------	--------	--------	--------	--------

Tabla C-22: Comparativa del SMAPE_1 para el cable CB01.

W	ACTUAL	SMAPE_2						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	0,1021	0,0961	0,0947	0,1778	0,1274	0,1798	0,2019	0,1028
2	0,0949	0,1261	0,0932	0,0554	0,2003	0,2428	0,1450	0,1450
3	0,0579	0,0351	0,0327	0,1821	0,0978	0,1179	0,1267	0,0961
4	0,1259	0,1608	0,1609	0,2930	0,1585	0,2664	0,2217	0,2218
5	0,2212	0,2258	0,2323	0,2481	0,2203	0,2127	0,2166	0,2384
6	0,1250	0,2437	0,1243	0,4443	0,2570	0,1726	0,1722	0,2490
7	0,0865	0,0983	0,1198	0,1166	0,0842	0,0535	0,1107	0,1674
8	0,1545	0,1653	0,1469	0,2350	0,1167	0,0804	0,0070	0,1463
9	0,0872	0,0758	0,0470	0,0616	0,0895	0,1250	0,0869	0,1080
10	0,1331	0,1354	0,1274	0,1558	0,1336	0,1425	0,0962	0,2510
11	0,3581	0,3738	0,3668	0,4095	0,3648	0,2170	0,3653	0,4635
12	0,3404	0,3754	0,3149	0,5067	0,3336	0,3465	0,3435	0,3310
13	0,1307	0,1592	0,1534	0,1792	0,1708	0,2670	0,2063	0,1262
14	0,0847	0,0757	0,0829	0,2223	0,0625	0,1134	0,1006	0,0573
15	0,1539	0,1760	0,1531	0,3115	0,1255	0,3096	0,2258	0,1256
16	0,1454	0,2298	0,1934	0,1104	0,1475	0,3585	0,1477	0,2235
17	0,0420	0,1184	0,1074	0,0690	0,1750	0,1057	0,1543	0,1097
18	0,0872	0,1612	0,1517	0,1299	0,2475	0,2225	0,2302	0,1584

Tabla C-23: Comparativa del SMAPE_2 para el cable CB01.

W	ACTUAL	SMAPE_4						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	0,0554	0,0612	0,0815	0,1445	0,0800	0,2953	0,1558	0,1180
2	0,1107	0,1327	0,1266	0,1973	0,2171	0,3979	0,1941	0,1359
3	0,1395	0,1307	0,1266	0,2220	0,1590	0,1733	0,1716	0,1567
4	0,1256	0,1331	0,1413	0,2562	0,1426	0,2381	0,1742	0,1743
5	0,1526	0,1615	0,1634	0,2457	0,1523	0,2111	0,1551	0,1585
6	0,1462	0,2849	0,1522	0,4368	0,2796	0,1839	0,1951	0,2665
7	0,0885	0,0884	0,0897	0,1205	0,0858	0,0700	0,1496	0,1941
8	0,1433	0,1545	0,1410	0,2714	0,1252	0,1737	0,0703	0,1765
9	0,2232	0,2274	0,1986	0,2479	0,2215	0,1863	0,2150	0,2542
10	0,2383	0,2590	0,2389	0,2996	0,2363	0,2227	0,2189	0,3305
11	0,2442	0,2799	0,2601	0,3261	0,2769	0,2186	0,2974	0,3743
12	0,1970	0,2288	0,1821	0,3550	0,2000	0,2122	0,2211	0,2244
13	0,1272	0,1705	0,1662	0,2589	0,1497	0,2292	0,2035	0,1071
14	0,1149	0,1440	0,1475	0,2493	0,1042	0,1918	0,1735	0,1294
15	0,0841	0,1436	0,1208	0,3297	0,1472	0,2602	0,2433	0,1407

16	0,1071	0,1812	0,1829	0,1148	0,1966	0,3394	0,1743	0,2488
----	--------	--------	--------	--------	--------	--------	--------	--------

Tabla C-24: Comparativa del SMAPE_4 para el cable CB01.

W	ACTUAL	SMAPE_8						
		GP	RF	SMOreg	RBD	AR	M5P	LR
1	0,1040	0,1090	0,1229	0,1974	0,1161	0,3092	0,1554	0,1507
2	0,1383	0,1439	0,1323	0,3255	0,1592	0,3927	0,1303	0,1752
3	0,1124	0,1191	0,1080	0,4462	0,1224	0,1888	0,1316	0,1210
4	0,1359	0,1477	0,1363	0,4099	0,1240	0,2160	0,1249	0,1232
5	0,1882	0,1968	0,1921	0,2604	0,1864	0,2642	0,1852	0,2060
6	0,1932	0,2750	0,1983	0,3625	0,2582	0,2717	0,2125	0,2578
7	0,1673	0,1730	0,1697	0,2370	0,1640	0,1557	0,1926	0,2374
8	0,1720	0,1860	0,1704	0,2760	0,1624	0,1902	0,1505	0,1939
9	0,1753	0,1897	0,1645	0,2071	0,1763	0,1957	0,1902	0,2014
10	0,1693	0,1805	0,1639	0,2020	0,1706	0,2692	0,1655	0,2310
11	0,1686	0,1768	0,1816	0,2154	0,1986	0,1667	0,2209	0,2836
12	0,1564	0,1809	0,1749	0,2393	0,1979	0,2475	0,2187	0,2109

Tabla C-25: Comparativa del SMAPE_8 para el cable CB01.

SEMANA	Futuro8W	Mét. Actual	IA	SEMANA	Futuro8W	Mét. Actual	IA
2017-W01	44.248	49.571	50.302	2018-W01	40.688	57.606	59.790
2017-W02	44.977	45.675	48.431	2018-W02	50.230	51.467	52.437
2017-W03	52.597	41.098	47.886	2018-W03	55.750	46.408	52.194
2017-W04	60.071	36.817	43.124	2018-W04	57.843	42.990	50.364
2017-W05	75.180	33.335	39.800	2018-W05	65.088	41.073	44.167
2017-W06	84.549	32.629	37.517	2018-W06	60.466	42.520	44.025
2017-W07	83.806	34.821	37.032	2018-W07	65.298	39.240	43.880
2017-W08	77.344	36.591	38.481	2018-W08	68.226	37.620	47.285
2017-W09	77.463	36.839	41.250	2018-W09	74.523	39.100	48.132
2017-W10	73.670	38.493	43.835	2018-W10	73.201	40.294	51.345
2017-W11	74.545	45.844	50.799	2018-W11	67.828	44.101	53.965
2017-W12	68.996	57.819	57.663	2018-W12	66.614	54.503	52.885
2017-W13	63.555	62.156	57.370	2018-W13	68.546	63.325	58.321
2017-W14	56.180	75.355	53.174	2018-W14	75.786	61.467	64.016
2017-W15	64.631	74.717	54.986	2018-W15	79.109	65.303	64.092
2017-W16	78.958	72.137	54.721	2018-W16	77.199	67.882	66.816
2017-W17	73.719	74.110	56.901	2018-W17	71.379	72.683	67.100
2017-W18	83.031	71.626	54.441	2018-W18	70.448	71.692	62.481
2017-W19	76.367	74.326	70.472	2018-W19	75.125	67.734	64.918
2017-W20	78.540	74.326	65.482	2018-W20	72.793	66.721	70.680
2017-W21	75.248	67.789	65.751	2018-W21	67.786	70.301	71.663
2017-W22	79.028	66.275	65.882	2018-W22	63.999	77.403	71.409

2017-W23	78.180	69.890	67.833	2018-W23	55.819	79.661	71.273
2017-W24	68.601	74.281	75.484	2018-W24	55.183	79.182	72.433
2017-W25	76.874	71.548	74.557	2018-W25	55.524	73.614	65.834
2017-W26	72.756	79.157	68.759	2018-W26	58.091	75.345	58.071
2017-W27	75.498	73.622	61.685	2018-W27	55.546	78.234	55.571
2017-W28	84.787	79.374	70.323	2018-W28	59.324	77.633	62.049
2017-W29	82.487	71.783	72.334	2018-W29	57.124	66.763	59.231
2017-W30	83.280	80.256	74.513	2018-W30	54.370	67.020	56.001
2017-W31	78.498	86.036	79.000	2018-W31	57.107	58.121	56.629
2017-W32	81.038	75.380	78.915	2018-W32	58.647	57.719	59.931
2017-W33	82.137	87.444	80.093	2018-W33	58.529	56.957	60.044
2017-W34	87.385	85.052	78.391	2018-W34	51.885	59.181	62.264
2017-W35	91.384	80.181	74.951	2018-W35	51.818	55.743	62.481
2017-W36	87.050	80.428	73.677	2018-W36	50.269	61.646	61.326
2017-W37	86.843	77.809	74.875	2018-W37	50.594	54.981	55.355
2017-W38	82.232	77.922	78.305	2018-W38	48.812	53.842	56.707
2017-W39	82.453	77.753	76.697	2018-W39	50.618	55.382	56.021
2017-W40	83.357	80.527	76.858	2018-W40	48.335	59.466	55.129
2017-W41	77.320	84.690	80.560	2018-W41	44.467	56.918	51.136
2017-W42	69.636	90.156	86.976	2018-W42	43.118	50.710	49.775
2017-W43	64.428	87.787	86.528	2018-W43	43.860	52.208	48.889
2017-W44	57.956	80.579	76.801	2018-W44	40.023	52.756	47.058
2017-W45	53.309	80.112	73.383	2018-W45	34.175	51.027	47.129
2017-W46	47.349	79.462	88.332	2018-W46	32.288	49.912	45.979
2017-W47	41.788	81.722	89.777	2018-W47	28.825	51.579	44.445
2017-W48	34.312	83.600	86.578	2018-W48	28.987	49.799	42.911
2017-W49	30.248	80.184	80.095	2018-W49	27.587	48.600	42.865
2017-W50	35.705	76.474	66.525	2018-W50	29.886	44.476	39.873
2017-W51	34.768	66.687	57.312	2018-W51	27.797	46.184	40.126
2017-W52	34.628	60.909	55.998	2018-W52	28.828	41.209	39.509

Tabla C-26: Datos de la gráfica de la Figura 5-1.

SEMANA	Futuro8W	Mét. Actual	IA	SEMANA	Futuro8W	Mét. Actual	IA
2017-W01	44.248	49.571	54.117	2018-W01	40.688	57.606	66.190
2017-W02	44.977	45.675	44.015	2018-W02	50.230	51.467	54.068
2017-W03	52.597	41.098	47.882	2018-W03	55.750	46.408	51.628
2017-W04	60.071	36.817	42.891	2018-W04	57.843	42.990	52.494
2017-W05	75.180	33.335	51.620	2018-W05	65.088	41.073	48.015
2017-W06	84.549	32.629	51.364	2018-W06	60.466	42.520	43.633
2017-W07	83.806	34.821	46.035	2018-W07	65.298	39.240	23.975
2017-W08	77.344	36.591	33.977	2018-W08	68.226	37.620	30.517
2017-W09	77.463	36.839	34.876	2018-W09	74.523	39.100	32.450
2017-W10	73.670	38.493	42.244	2018-W10	73.201	40.294	32.396
2017-W11	74.545	45.844	47.188	2018-W11	67.828	44.101	35.349

2017-W12	68.996	57.819	47.642	2018-W12	66.614	54.503	42.336
2017-W13	63.555	62.156	49.303	2018-W13	68.546	63.325	48.207
2017-W14	56.180	75.355	66.213	2018-W14	75.786	61.467	46.892
2017-W15	64.631	74.717	49.585	2018-W15	79.109	65.303	62.919
2017-W16	78.958	72.137	42.277	2018-W16	77.199	67.882	59.041
2017-W17	73.719	74.110	59.874	2018-W17	71.379	72.683	66.058
2017-W18	83.031	71.626	56.752	2018-W18	70.448	71.692	66.299
2017-W19	76.367	74.326	74.193	2018-W19	75.125	67.734	61.395
2017-W20	78.540	74.326	56.816	2018-W20	72.793	66.721	59.498
2017-W21	75.248	67.789	65.790	2018-W21	67.786	70.301	64.691
2017-W22	79.028	66.275	65.806	2018-W22	63.999	77.403	66.440
2017-W23	78.180	69.890	63.335	2018-W23	55.819	79.661	69.792
2017-W24	68.601	74.281	82.514	2018-W24	55.183	79.182	66.372
2017-W25	76.874	71.548	74.878	2018-W25	55.524	73.614	73.125
2017-W26	72.756	79.157	74.825	2018-W26	58.091	75.345	72.579
2017-W27	75.498	73.622	78.513	2018-W27	55.546	78.234	70.130
2017-W28	84.787	79.374	46.088	2018-W28	59.324	77.633	53.688
2017-W29	82.487	71.783	56.039	2018-W29	57.124	66.763	56.518
2017-W30	83.280	80.256	61.110	2018-W30	54.370	67.020	62.279
2017-W31	78.498	86.036	71.354	2018-W31	57.107	58.121	65.864
2017-W32	81.038	75.380	81.546	2018-W32	58.647	57.719	71.990
2017-W33	82.137	87.444	85.668	2018-W33	58.529	56.957	74.142
2017-W34	87.385	85.052	90.741	2018-W34	51.885	59.181	68.051
2017-W35	91.384	80.181	81.932	2018-W35	51.818	55.743	60.086
2017-W36	87.050	80.428	89.268	2018-W36	50.269	61.646	63.975
2017-W37	86.843	77.809	82.369	2018-W37	50.594	54.981	59.929
2017-W38	82.232	77.922	73.255	2018-W38	48.812	53.842	61.387
2017-W39	82.453	77.753	80.042	2018-W39	50.618	55.382	60.182
2017-W40	83.357	80.527	72.279	2018-W40	48.335	59.466	59.317
2017-W41	77.320	84.690	93.158	2018-W41	44.467	56.918	57.399
2017-W42	69.636	90.156	102.866	2018-W42	43.118	50.710	46.180
2017-W43	64.428	87.787	85.265	2018-W43	43.860	52.208	51.518
2017-W44	57.956	80.579	99.437	2018-W44	40.023	52.756	53.244
2017-W45	53.309	80.112	88.208	2018-W45	34.175	51.027	47.417
2017-W46	47.349	79.462	81.955	2018-W46	32.288	49.912	45.000
2017-W47	41.788	81.722	100.218	2018-W47	28.825	51.579	47.315
2017-W48	34.312	83.600	98.183	2018-W48	28.987	49.799	44.986
2017-W49	30.248	80.184	88.934	2018-W49	27.587	48.600	44.552
2017-W50	35.705	76.474	53.843	2018-W50	29.886	44.476	46.754
2017-W51	34.768	66.687	57.401	2018-W51	27.797	46.184	42.750
2017-W52	34.628	60.909	66.402	2018-W52	28.828	41.209	38.315

Tabla C-27: Datos de la gráfica de la Figura 5-2.

SEMANA	Futuro8W	Mét. Actual	IA	SEMANA	Futuro8W	Mét. Actual	IA
2017-W01	44.248	49.571	58.430	2018-W01	40.688	57.606	1.372
2017-W02	44.977	45.675	58.174	2018-W02	50.230	51.467	65.539
2017-W03	52.597	41.098	26.417	2018-W03	55.750	46.408	71.888
2017-W04	60.071	36.817	23.253	2018-W04	57.843	42.990	20.750
2017-W05	75.180	33.335	50.160	2018-W05	65.088	41.073	1.632
2017-W06	84.549	32.629	31.690	2018-W06	60.466	42.520	68.997
2017-W07	83.806	34.821	41.425	2018-W07	65.298	39.240	32.079
2017-W08	77.344	36.591	45.181	2018-W08	68.226	37.620	45.866
2017-W09	77.463	36.839	53.182	2018-W09	74.523	39.100	49.970
2017-W10	73.670	38.493	56.967	2018-W10	73.201	40.294	45.257
2017-W11	74.545	45.844	57.876	2018-W11	67.828	44.101	54.270
2017-W12	68.996	57.819	77.722	2018-W12	66.614	54.503	41.172
2017-W13	63.555	62.156	54.241	2018-W13	68.546	63.325	62.711
2017-W14	56.180	75.355	48.971	2018-W14	75.786	61.467	46.204
2017-W15	64.631	74.717	54.573	2018-W15	79.109	65.303	62.019
2017-W16	78.958	72.137	51.332	2018-W16	77.199	67.882	88.732
2017-W17	73.719	74.110	48.078	2018-W17	71.379	72.683	59.108
2017-W18	83.031	71.626	32.419	2018-W18	70.448	71.692	47.152
2017-W19	76.367	74.326	70.218	2018-W19	75.125	67.734	56.256
2017-W20	78.540	74.326	68.809	2018-W20	72.793	66.721	60.172
2017-W21	75.248	67.789	39.625	2018-W21	67.786	70.301	59.709
2017-W22	79.028	66.275	70.020	2018-W22	63.999	77.403	84.881
2017-W23	78.180	69.890	62.649	2018-W23	55.819	79.661	86.144
2017-W24	68.601	74.281	81.624	2018-W24	55.183	79.182	85.230
2017-W25	76.874	71.548	56.423	2018-W25	55.524	73.614	63.858
2017-W26	72.756	79.157	50.032	2018-W26	58.091	75.345	53.348
2017-W27	75.498	73.622	56.974	2018-W27	55.546	78.234	58.194
2017-W28	84.787	79.374	56.641	2018-W28	59.324	77.633	58.171
2017-W29	82.487	71.783	125.754	2018-W29	57.124	66.763	58.024
2017-W30	83.280	80.256	57.965	2018-W30	54.370	67.020	31.467
2017-W31	78.498	86.036	56.594	2018-W31	57.107	58.121	58.145
2017-W32	81.038	75.380	60.193	2018-W32	58.647	57.719	85.315
2017-W33	82.137	87.444	65.867	2018-W33	58.529	56.957	64.095
2017-W34	87.385	85.052	62.381	2018-W34	51.885	59.181	77.841
2017-W35	91.384	80.181	63.398	2018-W35	51.818	55.743	48.405
2017-W36	87.050	80.428	64.382	2018-W36	50.269	61.646	60.639
2017-W37	86.843	77.809	65.363	2018-W37	50.594	54.981	61.106
2017-W38	82.232	77.922	73.297	2018-W38	48.812	53.842	61.554
2017-W39	82.453	77.753	91.323	2018-W39	50.618	55.382	70.946
2017-W40	83.357	80.527	80.153	2018-W40	48.335	59.466	62.121
2017-W41	77.320	84.690	64.610	2018-W41	44.467	56.918	60.581
2017-W42	69.636	90.156	72.175	2018-W42	43.118	50.710	53.697
2017-W43	64.428	87.787	95.709	2018-W43	43.860	52.208	63.734
2017-W44	57.956	80.579	73.954	2018-W44	40.023	52.756	40.368
2017-W45	53.309	80.112	74.422	2018-W45	34.175	51.027	32.757

2017-W46	47.349	79.462	75.109	2018-W46	32.288	49.912	41.534
2017-W47	41.788	81.722	75.428	2018-W47	28.825	51.579	33.044
2017-W48	34.312	83.600	75.708	2018-W48	28.987	49.799	45.764
2017-W49	30.248	80.184	75.971	2018-W49	27.587	48.600	43.651
2017-W50	35.705	76.474	92.798	2018-W50	29.886	44.476	41.938
2017-W51	34.768	66.687	83.342	2018-W51	27.797	46.184	41.387
2017-W52	34.628	60.909	75.193	2018-W52	28.828	41.209	31.584

Tabla C-28: Datos de la gráfica de la Figura 5-3.

SEMANA	Dif. Mét.		Dif. Mét. Act. N.	Dif. IA N.	Área Actual	Área IA
	Act.	Dif. IA				
2017-W01	28.334.329	36.650.916	0,01037	0,01342	14410766,5	24290516
2017-W02	487204	11930116	0,00018	0,00437	66357102,5	17061818,5
2017-W03	132227001	22193521	0,04840	0,00812	336487758,5	154697165
2017-W04	540748516	287200809	0,19795	0,10513	1145876271	769472604,5
2017-W05	1751004025	1251744400	0,64099	0,45822	2223345213	1731876712
2017-W06	2695686400	2212009024	0,98680	0,80975	2547608313	2199908050
2017-W07	2399530225	2187807076	0,87839	0,80089	2030168617	1849069923
2017-W08	1660807009	1510332769	0,60797	0,55288	1655558193	1410857069
2017-W09	1650309376	1311381369	0,60413	0,48005	1443865353	1100754297
2017-W10	1237421329	890127225	0,45298	0,32585	1030584365	726999870,5
2017-W11	823747401	563872516	0,30155	0,20642	474336365	346154702,5
2017-W12	124925329	128436889	0,04573	0,04702	63441265	83345557
2017-W13	1957201	38254225	0,00072	0,01400	184818913	23645130,5
2017-W14	367680625	9036036	0,13460	0,00331	234704010,5	51031030,5
2017-W15	101727396	93026025	0,03724	0,03405	74126718,5	340229097
2017-W16	46526041	587432169	0,01703	0,21504	23339461	435138646,5
2017-W17	152881	282845124	0,00006	0,10354	65113453	550116612
2017-W18	130074025	817388100	0,04762	0,29922	67119853	426069562,5
2017-W19	4165681	34751025	0,00152	0,01272	10961738,5	102631194,5
2017-W20	17757796	170511364	0,00650	0,06242	36697238,5	130352186,5
2017-W21	55636681	90193009	0,02037	0,03302	109137845	131505162,5
2017-W22	162639009	172817316	0,05954	0,06326	115681554,5	139938862,5
2017-W23	68724100	107060409	0,02516	0,03919	50493250	77218049
2017-W24	32262400	47375689	0,01181	0,01734	30314338	26372089
2017-W25	28366276	5368489	0,01038	0,00197	34669538,5	10672249
2017-W26	40972801	15976009	0,01500	0,00585	22246088,5	103387489
2017-W27	3519376	190798969	0,00129	0,06985	16409972,5	200003132,5
2017-W28	29300569	209207296	0,01073	0,07658	71938092,5	156145352,5
2017-W29	114575616	103083409	0,04194	0,03774	61860096	89971849
2017-W30	9144576	76860289	0,00335	0,02814	32983010	38556146,5
2017-W31	56821444	252004	0,02080	0,00009	44417204	2379566,5
2017-W32	32012964	4507129	0,01172	0,00165	30088606,5	4342532,5
2017-W33	28164249	4177936	0,01031	0,00153	16803569	42534986
2017-W34	5442889	80892036	0,00199	0,02961	65475049	175467762,5

2017-W35	125507209	270043489	0,04594	0,09885	84679046,5	224440309
2017-W36	43850884	178837129	0,01605	0,06547	62732020	161035076,5
2017-W37	81613156	143233024	0,02988	0,05243	50094628	79327176,5
2017-W38	18576100	15421329	0,00680	0,00565	20333050	24276432,5
2017-W39	22090000	33131536	0,00809	0,01213	15049450	37684268,5
2017-W40	8008900	42237001	0,00293	0,01546	31162900	26367300,5
2017-W41	54316900	10497600	0,01988	0,00384	237693650	155586600
2017-W42	421070400	300675600	0,15414	0,11007	483356640,5	394542800
2017-W43	545642881	488410000	0,19974	0,17879	528721505	421772012,5
2017-W44	511800129	355134025	0,18735	0,13000	615100469	379049750,5
2017-W45	718400809	402965476	0,26298	0,14751	874822789	1041285883
2017-W46	1031244769	1679606289	0,37751	0,61485	1312984563	1991275205
2017-W47	1594724356	2302944121	0,58378	0,84303	2012015650	2517339439
2017-W48	2429306944	2731734756	0,88929	1,00000	2461455520	2608229083
2017-W49	2493604096	2484723409	0,91283	0,90958	2077857729	1717297905
2017-W50	1662111361	949872400	0,60845	0,34772	1340466961	729052168
2017-W51	1018822561	508231936	0,37296	0,18605	854756761	482454418
2017-W52	690690961	456676900	0,25284	0,16717		

Tabla C-29: Primera parte de los datos usados para la representación y el cálculo del área bajo la curva y las diferencias al cuadrado entre las predicciones actuales y de GaussianProcesses respecto a la demanda real para el cable CB01, usando el input ajustado 2 durante 2017 y 2018.

SEMANA	Dif. Mét.		Dif. Mét. Act. N.	Dif. IA N.	Área Actual	Área IA
	Act.	Dif. IA				
2018-W01	286.218.724	364.886.404	0,10478	0,13357	143874447	184878627
2018-W02	1530169	4870849	0,00056	0,00178	44401566,5	8757992,5
2018-W03	87272964	12645136	0,03195	0,00463	153942287	34290288,5
2018-W04	220611609	55935441	0,08076	0,02048	398665917	246811841
2018-W05	576720225	437688241	0,21112	0,16022	449389571	353997361
2018-W06	322058916	270306481	0,11790	0,09895	500539140	364518603
2018-W07	679019364	458730724	0,24857	0,16793	807873300	448628103
2018-W08	936727236	438525481	0,34291	0,16053	1095758083	567505181
2018-W09	1254788929	696484881	0,45934	0,25496	1168829789	587084809
2018-W10	1082870649	477684736	0,39640	0,17486	822920589	334933753
2018-W11	562970529	192182769	0,20609	0,07035	354823425	190334105
2018-W12	146676321	188485441	0,05369	0,06900	86967581	146518033
2018-W13	27258841	104550625	0,00998	0,03827	116146301	121541763
2018-W14	205033761	138532900	0,07506	0,05071	197819699	182021595
2018-W15	190605636	225510289	0,06977	0,08255	138706063	166658489
2018-W16	86806489	107806689	0,03178	0,03946	44253452,5	63058265
2018-W17	1700416	18309841	0,00062	0,00670	1623976	40891465
2018-W18	1547536	63473089	0,00057	0,02324	28087208,5	83827969
2018-W19	54626881	104182849	0,02000	0,03814	45748032,5	54323809

2018-W20	36869184	4464769	0,01350	0,00163	21597204,5	9747949
2018-W21	6325225	15031129	0,00232	0,00550	92996220,5	34969614,5
2018-W22	179667216	54908100	0,06577	0,02010	374054090	146867108
2018-W23	568440964	238826116	0,20809	0,08743	572196483	268194308
2018-W24	575952001	297562500	0,21084	0,10893	451600051	201929300
2018-W25	327248100	106296100	0,11979	0,03891	312474308	53148250
2018-W26	297700516	400	0,10898	0,00000	406222930	512,5
2018-W27	514745344	625	0,18843	0,00000	424982413	3713125
2018-W28	335219481	7425625	0,12271	0,00272	214064901	5932537
2018-W29	92910321	4439449	0,03401	0,00163	126466411	3549805
2018-W30	160022500	2660161	0,05858	0,00097	80525348	1444322,5
2018-W31	1028196	228484	0,00038	0,00008	944690	938570
2018-W32	861184	1648656	0,00032	0,00060	1666184	1971940,5
2018-W33	2471184	2295225	0,00090	0,00084	27851400	55009433
2018-W34	53231616	107723641	0,01949	0,03943	34318620,5	110711605
2018-W35	15405625	113699569	0,00564	0,04162	72420877	117978409
2018-W36	129436129	122257249	0,04738	0,04475	74340949	72462185
2018-W37	19245769	22667121	0,00705	0,00830	22273334,5	42499073
2018-W38	25300900	62331025	0,00926	0,02282	23998298	45761717
2018-W39	22695696	29192409	0,00831	0,01069	73297428,5	37675422,5
2018-W40	123899161	46158436	0,04536	0,01690	139463281	45316998,5
2018-W41	155027401	44475561	0,05675	0,01628	106332933	44395605
2018-W42	57638464	44315649	0,02110	0,01622	63663784	34803245
2018-W43	69689104	25290841	0,02551	0,00926	115909197	37391033
2018-W44	162129289	49491225	0,05935	0,01812	223059597	108648671
2018-W45	283989904	167806116	0,10396	0,06143	297297640	177624799
2018-W46	310605376	187443481	0,11370	0,06862	414174946	215713941
2018-W47	517744516	243984400	0,18953	0,08931	475441930	218931088
2018-W48	433139344	193877776	0,15856	0,07097	437342757	213647530
2018-W49	441546169	233417284	0,16164	0,08545	327207135	166578727
2018-W50	212868100	99740169	0,07792	0,03651	275474935	125872205
2018-W51	338081769	152004241	0,12376	0,05564	245685465	133044001
2018-W52	153289161	114083761	0,05611	0,04176		

Tabla C-30: Segunda parte de los datos usados para la representación y el cálculo del área bajo la curva y las diferencias al cuadrado entre las predicciones actuales y de GaussianProcesses respecto a la demanda real para el cable CB01, usando el input ajustado 2 durante 2017 y 2018.

SEMANA	Dif. Mét.		Dif. Mét. Act. N.	Dif. IA N.	Área Actual	Área IA
	Act.	Dif. IA				
2017-W01	28.334.329	97.397.161	0,00695	0,02387	14410766,5	49161302,5
2017-W02	487204	925444	0,00012	0,00023	66357102,5	11578334,5
2017-W03	132227001	22231225	0,03241	0,00545	336487758,5	158691812,5
2017-W04	540748516	295152400	0,13255	0,07235	1145876271	425113000
2017-W05	1751004025	555073600	0,42922	0,13606	2223345213	828158912,5
2017-W06	2695686400	1101244225	0,66079	0,26995	2547608313	1263946333
2017-W07	2399530225	1426648441	0,58819	0,34971	2030168617	1653672565
2017-W08	1660807009	1880696689	0,40711	0,46101	1655558193	1847174629
2017-W09	1650309376	1813652569	0,40454	0,44458	1443865353	1400623023
2017-W10	1237421329	987593476	0,30333	0,24209	1030584365	867999462,5
2017-W11	823747401	748405449	0,20192	0,18345	474336365	602199382,5
2017-W12	124925329	455993316	0,03062	0,11178	63441265	329556410
2017-W13	1957201	203119504	0,00048	0,04979	184818913	151890296,5
2017-W14	367680625	100661089	0,09013	0,02467	234704010,5	163521602,5
2017-W15	101727396	226382116	0,02494	0,05549	74126718,5	785938938,5
2017-W16	46526041	1345495761	0,01140	0,32982	23339461	768589893
2017-W17	152881	191684025	0,00004	0,04699	65113453	441134933
2017-W18	130074025	690585841	0,03188	0,16928	67119853	347656058,5
2017-W19	4165681	4726276	0,00102	0,00116	10961738,5	238329226
2017-W20	17757796	471932176	0,00435	0,11568	36697238,5	280692970
2017-W21	55636681	89453764	0,01364	0,02193	109137845	132137524
2017-W22	162639009	174821284	0,03987	0,04285	115681554,5	197597654,5
2017-W23	68724100	220374025	0,01685	0,05402	50493250	206972797
2017-W24	32262400	193571569	0,00791	0,04745	30314338	98777792,5
2017-W25	28366276	3984016	0,00695	0,00098	34669538,5	4132388,5
2017-W26	40972801	4280761	0,01004	0,00105	22246088,5	6685493
2017-W27	3519376	9090225	0,00086	0,00223	16409972,5	753351413
2017-W28	29300569	1497612601	0,00718	0,36711	71938092,5	1098554653
2017-W29	114575616	699496704	0,02809	0,17147	61860096	595502802
2017-W30	9144576	491508900	0,00224	0,12048	32983010	271272818
2017-W31	56821444	51036736	0,01393	0,01251	44417204	25647400
2017-W32	32012964	258064	0,00785	0,00006	30088606,5	6363012,5
2017-W33	28164249	12467961	0,00690	0,00306	16803569	11865348,5
2017-W34	5442889	11262736	0,00133	0,00276	65475049	50301520
2017-W35	125507209	89340304	0,03077	0,02190	84679046,5	47129914
2017-W36	43850884	4919524	0,01075	0,00121	62732020	12468100
2017-W37	81613156	20016676	0,02001	0,00491	50094628	50301602,5
2017-W38	18576100	80586529	0,00455	0,01975	20333050	43199725
2017-W39	22090000	5812921	0,00541	0,00142	15049450	64267502,5
2017-W40	8008900	122722084	0,00196	0,03008	31162900	186782164
2017-W41	54316900	250842244	0,01331	0,06149	237693650	677537572
2017-W42	421070400	1104232900	0,10322	0,27068	483356640,5	769206734,5

2017-W43	545642881	434180569	0,13375	0,10643	528721505	1077426965
2017-W44	511800129	1720673361	0,12546	0,42178	615100469	1469306781
2017-W45	718400809	1217940201	0,17610	0,29855	874822789	1207757719
2017-W46	1031244769	1197575236	0,25279	0,29356	1312984563	2305820068
2017-W47	1594724356	3414064900	0,39091	0,83688	2012015650	3746784771
2017-W48	2429306944	4079504641	0,59549	1,00000	2461455520	3761775619
2017-W49	2493604096	3444046596	0,61125	0,84423	2077857729	1886516820
2017-W50	1662111361	328987044	0,40743	0,08064	1340466961	420619866,5
2017-W51	1018822561	512252689	0,24974	0,12557	854756761	760919882,5
2017-W52	690690961	1009587076	0,16931	0,24748		

Tabla C-31: Primera parte de los datos usados para el cálculo del área bajo la curva y las diferencias al cuadrado entre las predicciones actuales y de GaussianProcesses respecto a la demanda real para el cable CB01, usando el input ajustado 1 durante 2017 y 2018.

SEMANA	Dif. Mét.		Dif. Mét. Act. N.	Dif. IA N.	Área Actual	Área IA
	Act.	Dif. IA				
2018-W01	286.218.724	650.352.004	0,07016	0,15942	143874447	332541124
2018-W02	1530169	14730244	0,00038	0,00361	44401566,5	15860564
2018-W03	87272964	16990884	0,02139	0,00416	153942287	22801342,5
2018-W04	220611609	28611801	0,05408	0,00701	398665917	160049565
2018-W05	576720225	291487329	0,14137	0,07145	449389571	287418609
2018-W06	322058916	283349889	0,07895	0,06946	500539140	995470109
2018-W07	679019364	1707590329	0,16645	0,41858	807873300	1564779505
2018-W08	936727236	1421968681	0,22962	0,34856	1095758083	1596053005
2018-W09	1254788929	1770137329	0,30758	0,43391	1168829789	1717592677
2018-W10	1082870649	1665048025	0,26544	0,40815	822920589	1359966733
2018-W11	562970529	1054885441	0,13800	0,25858	354823425	822153363
2018-W12	146676321	589421284	0,03595	0,14448	86967581	501548103
2018-W13	27258841	413674921	0,00668	0,10140	116146301	624269079
2018-W14	205033761	834863236	0,05026	0,20465	197819699	548489668
2018-W15	190605636	262116100	0,04672	0,06425	138706063	295914532
2018-W16	86806489	329712964	0,02128	0,08082	44253452,5	179013003
2018-W17	1700416	28313041	0,00042	0,00694	1623976	22763621
2018-W18	1547536	17214201	0,00038	0,00422	28087208,5	102863551
2018-W19	54626881	188512900	0,01339	0,04621	45748032,5	182634963
2018-W20	36869184	176757025	0,00904	0,04333	21597204,5	93168025
2018-W21	6325225	9579025	0,00155	0,00235	92996220,5	7768753
2018-W22	179667216	5958481	0,04404	0,00146	374054090	100601605
2018-W23	568440964	195244729	0,13934	0,04786	572196483	160219225
2018-W24	575952001	125193721	0,14118	0,03069	451600051	217494461
2018-W25	327248100	309795201	0,08022	0,07594	312474308	259848673
2018-W26	297700516	209902144	0,07297	0,05145	406222930	211297600
2018-W27	514745344	212693056	0,12618	0,05214	424982413	122228776
2018-W28	335219481	31764496	0,08217	0,00779	214064901	16065866
2018-W29	92910321	367236	0,02277	0,00009	126466411	31459758,5

2018-W30	160022500	62552281	0,03923	0,01533	80525348	69618665
2018-W31	1028196	76685049	0,00025	0,01880	944690	127360349
2018-W32	861184	178035649	0,00021	0,04364	1666184	210900709
2018-W33	2471184	243765769	0,00061	0,05975	27851400	252552663
2018-W34	53231616	261339556	0,01305	0,06406	34318620,5	164849690
2018-W35	15405625	68359824	0,00378	0,01676	72420877	128107130
2018-W36	129436129	187854436	0,03173	0,04605	74340949	137498331
2018-W37	19245769	87142225	0,00472	0,02136	22273334,5	122636425
2018-W38	25300900	158130625	0,00620	0,03876	23998298	124800361
2018-W39	22695696	91470096	0,00556	0,02242	73297428,5	106037210
2018-W40	123899161	120604324	0,03037	0,02956	139463281	143920474
2018-W41	155027401	167236624	0,03800	0,04099	106332933	88306234
2018-W42	57638464	9375844	0,01413	0,00230	63663784	34010404
2018-W43	69689104	58644964	0,01708	0,01438	115909197	116719903
2018-W44	162129289	174794841	0,03974	0,04285	223059597	175072703
2018-W45	283989904	175350564	0,06961	0,04298	297297640	168472754
2018-W46	310605376	161594944	0,07614	0,03961	414174946	251737522
2018-W47	517744516	341880100	0,12691	0,08380	475441930	298924051
2018-W48	433139344	255968001	0,10617	0,06274	437342757	271889613
2018-W49	441546169	287811225	0,10824	0,07055	327207135	286170325
2018-W50	212868100	284529424	0,05218	0,06975	275474935	254060817
2018-W51	338081769	223592209	0,08287	0,05481	245685465	156797689
2018-W52	153289161	90003169	0,03758	0,02206		

Tabla C-32: Segunda parte de los datos usados para el cálculo del área bajo la curva y las diferencias al cuadrado entre las predicciones actuales y de GaussianProcesses respecto a la demanda real para el cable CB01, usando el input ajustado 1 durante 2017 y 2018.