UNIVERSIDAD PONTIFICIA
ICAI ICADE
COMILLAS
M A D R I D
ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA
INSTITUTO DE INVESTIGACIÓN TECNOLÓGICA

ANÁLISIS DE LA CAPACIDAD DE PREDICCIÓN DE LOS MODELOS DE CORTO PLAZO UTILIZANDO DOS PARQUES PILOTO

INFORME DE RESULTADOS

Fecha: 25-JUN-2004
Rev.: 1.2

Índice del documento

0 RESUMEN EJECUTIVO 3

1 INTRODUCCIÓN 4

2 ANÁLSIS DEL PARQUE 1 5

2.1 ANÁLISIS EXPLORATORIO DE LOS DATOS DE PARTIDA 5
2.1.1 Producciones 5
2.1.2 Predicciones realizadas con el modelo Casandra 8
2.2 IDENTIFICACIÓN Y AJUSTE DE LOS MODELOS DE CORTO PLAZO 14
2.3 RESULTADOS 17

3 ANÁLSIS DEL PARQUE 2 20

3.1 ANÁLISIS EXPLORATORIO DE LOS DATOS DE PARTIDA 20
3.1.1 Producciones 20
3.1.2 Predicciones realizadas con el modelo Casandra 22
3.2 IDENTIFICACIÓN Y AJUSTE DE LOS MODELOS DE CORTO PLAZO 28
3.3 RESULTADOS 29

4 ANÁLSIS DE LA AGREGACIÓN DE LOS PARQUES 1 Y 2 32

4.1 ANÁLISIS EXPLORATORIO DE LOS DATOS DE PARTIDA 32
4.1.1 Producciones 32
4.1.2 Predicciones realizadas con el modelo Casandra 35
4.2 IDENTIFICACIÓN Y AJUSTE DE LOS MODELOS DE CORTO PLAZO 41
4.3 RESULTADOS 42

5 BIBLIOGRAFÍA 45

6 APÉNDICE 46

6.1 DETALLE DE LOS MODELOS DEL PARQUE 1 46
6.2 DETALLE DE LOS MODELOS DEL PARQUE 2 51
6.3 DETALLE DE LOS MODELOS DE LA AGREGACIÓN DE LOS PARQUES 1 Y 2 56

0 Resumen ejecutivo

En este documento se presentan los resultados obtenidos de la aplicación de modelos de corto plazo, basados en redes neuronales tipo perceptrón multicapa, a la predicción de la producción de dos parques piloto seleccionados por Gamesa.

El objetivo de este análisis es cuantificar la disminución de los errores de predicción que se obtiene al combinar los modelos de corto plazo con las predicciones realizadas con el modelo meteorológico Casandra, con el fin de evaluar su posible aplicación en la gestión de la energía eólica en los mercados intradiarios.

Los resultados obtenidos pueden resumirse en los siguientes puntos:

- Los modelos de corto plazo ajustados para el **Parque 1** presentan un **error absoluto medio del 29.2%** en el horizonte de interés para los mercados intradiarios, lo que supone una **reducción media del 16.2%** del error cometido por el modelo Casandra

- Los modelos de corto plazo ajustados para el **Parque 2** presentan un **error absoluto medio del 37.7%** en el horizonte de interés para los mercados intradiarios, lo que supone una **reducción media del 17.0%** del error cometido por el modelo Casandra.

- Los modelos de corto plazo ajustados para la **agregación de los parques 1 y 2 presentan un error absoluto medio del 25.7%** en el horizonte de interés para los mercados intradiarios, lo que supone una **reducción media del 9.0%** del error cometido por el modelo Casandra y un nivel de error inferior al mejor de los obtenidos con los parques agregados.

Estos resultados se han obtenido aplicando una estructura común en todos los modelos de corto plazo, haciendo que compartan las mismas variables de entrada y la misma estructura de aproximador funcional, con objeto de facilitar la puesta en explotación del sistema de predicción propuesto.

1 Introducción

En este documento se presentan los resultados obtenidos de la aplicación de modelos de corto plazo, basados en redes neuronales tipo perceptrón multicapa, a la predicción de la producción de dos parques piloto seleccionados por Gamesa.

El objetivo de este análisis es cuantificar la disminución de los errores de predicción que se obtiene al combinar los modelos de corto plazo con las predicciones realizadas con el modelo meteorológico Casandra, con el fin de evaluar su posible aplicación en la gestión de la energía eólica en los mercados intradiarios.

En la Figura 1 se presenta el horario de las distintas convocatorias de los mercados intradiarios. En verde se han señalado los intervalos comprendidos entre la apertura y cierre de cada sesión (plazo de presentación de ofertas) y en rojo se han enmarcado las horas del horizonte de programación que no vuelven a quedar cubiertas por otra sesión del mercado. De este modo, la segunda sesión del mercado intradiario, que se abre a las 21:00h y se cierra a las 21:45h, es la última oportunidad para modificar el programa de las horas 1 a 4.

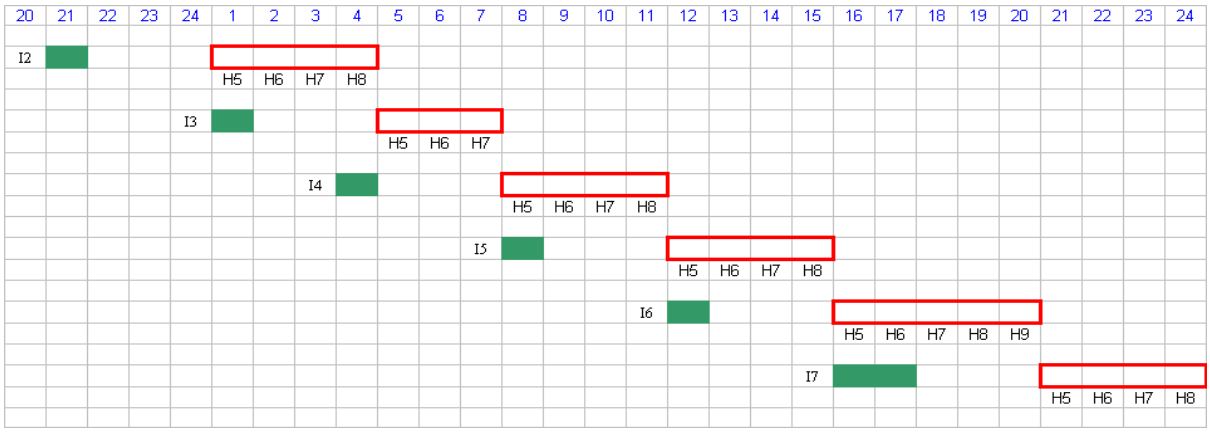


Figura 1: Horario de los mercados intradiarios

Desde el punto de vista de la predicción a corto plazo, puede concluirse de la figura anterior que el horizonte de predicción necesario para gestionar la energía de la hora *h* en la última convocatoria de los mercados intradiarios cuyo horizonte de programación incluya la hora *h*, es de 5 a 8 horas, salvo para la hora 20, que requeriría un horizonte de predicción de 9 horas.

Así pues este estudio se va a centrar en los horizontes de predicción de 5 a 8 horas.

2 Análsis del Parque 1

2.1 Análisis exploratorio de los datos de partida

Como punto de partida se cuenta con la siguiente información:

- Parque 1 (en adelante P1): datos del 01/03/2003 al 31/07/2003
    - E1: Producciones horarias medidas (kWh)
    - E1Cas24: Predicciones horarias de producción realizadas con el modelo Casandra con horizonte de 1 a 24h (kWh)
    - E1Cas48: Predicciones horarias de producción realizadas con el modelo Casandra con horizonte de 25 a 48h (kWh)

2.1.1 Producciones

En las siguientes figuras se representa gráficamente la producción en P1 durante el período de estudio. En ellas puede apreciarse cómo la producción máxima del parque ronda los 25MWh, habiéndose alcanzado estos niveles de producción de forma persistente en el período 27/04/2003 al 04/05/2004.

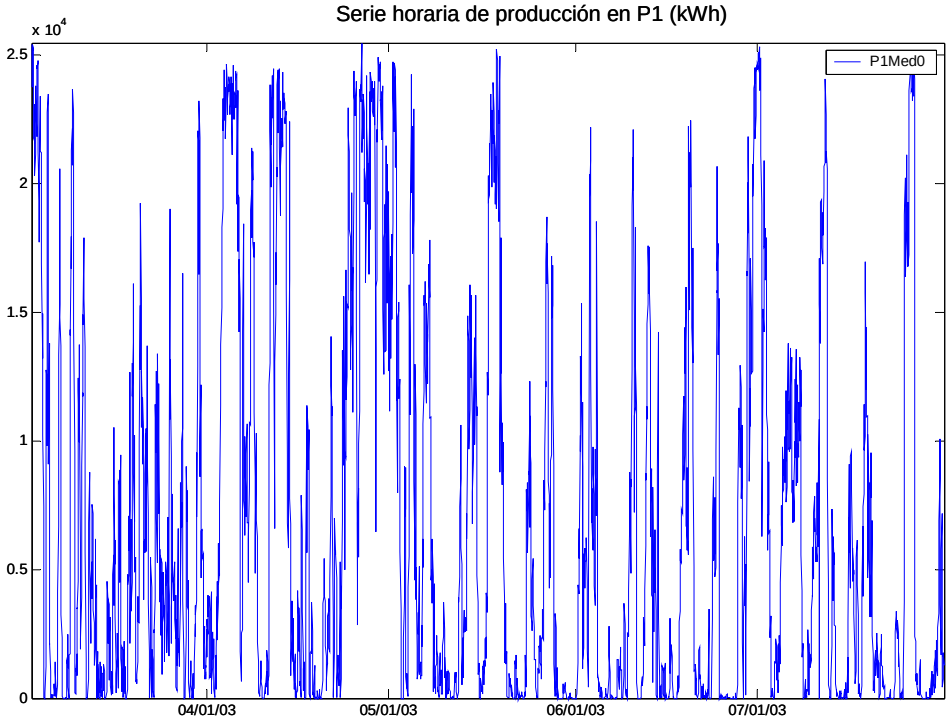


Figura 2: Serie de producción horaria en P1 (kWh)

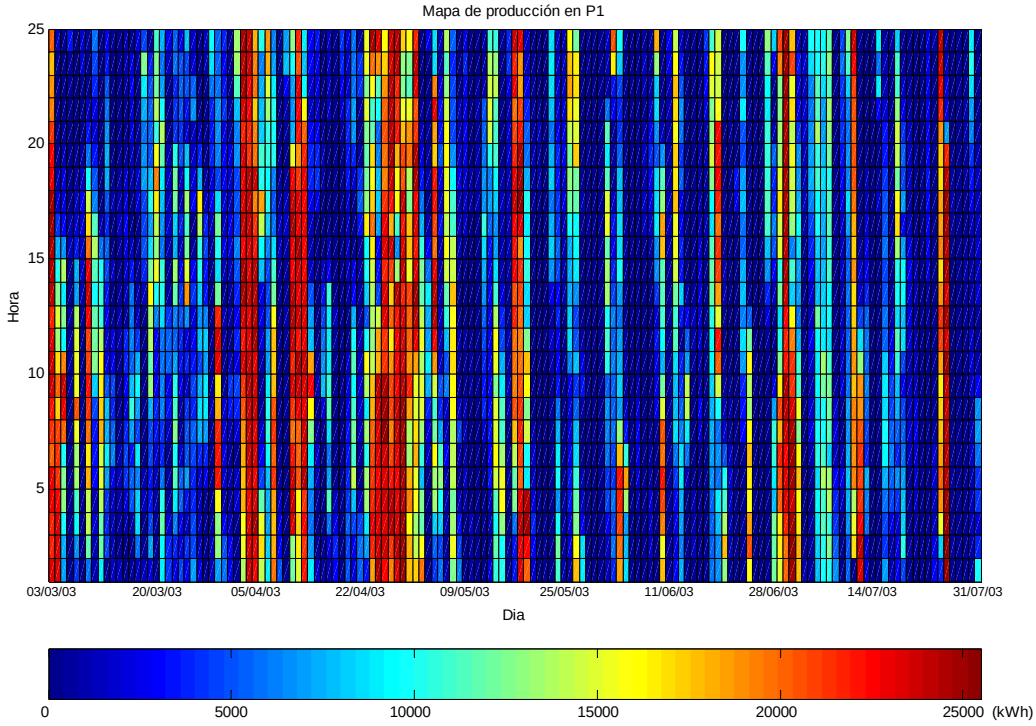


Figura 3: Mapa de producción diaria en P1 (kWh)

En la Figura 4 se muestra un análisis de agrupamiento (“clustering”) de los perfiles diarios de producción en P1. En azul se representa el representante de cada grupo, en amarillo los perfiles diarios de producción asociados en cada grupo y en rojo los intervalos de dispersión. De esta forma puede observarse que el patrón nº2 corresponde a un patrón de plena carga sostenida las 24 horas, mientras que el patrón nº4 representa los días de muy baja producción.

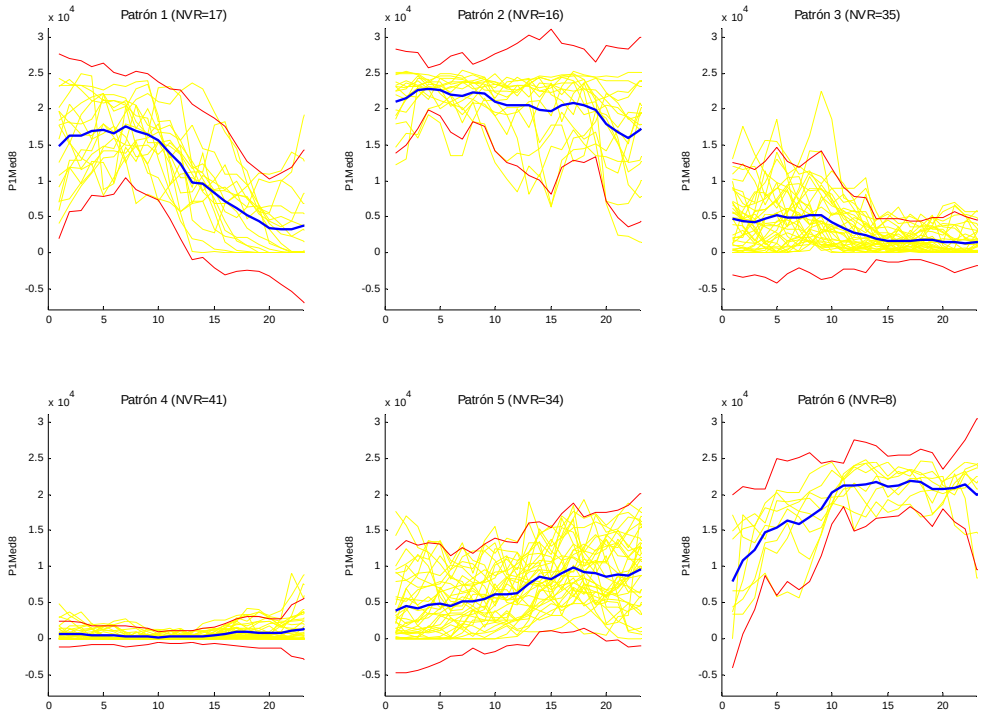


Figura 4: Patrones diarios de producción en P1 (kWh)

A partir de estos patrones diarios de producción se ha realizado una selección de los conjuntos de entrenamiento, test y validación utilizados en el ajuste y posterior validación de los modelos, de tal forma que queden bien representados los distintos comportamientos observados en cada uno de ellos.

El procedimiento utilizado ha consistido en formar cada uno de estos conjuntos seleccionando de cada patrón un porcentaje fijo de perfiles diarios asociados a ese patrón. Los porcentajes utilizados han sido 60% para el conjunto de entrenamiento utilizado para definir la función de error, 15% para el conjunto de test utilizado para monitorizar la capacidad de generalización del modelo durante el entrenamiento y 25% para el conjunto de validación, cuyos datos no han sido utilizados durante el ajuste de los parámetros.

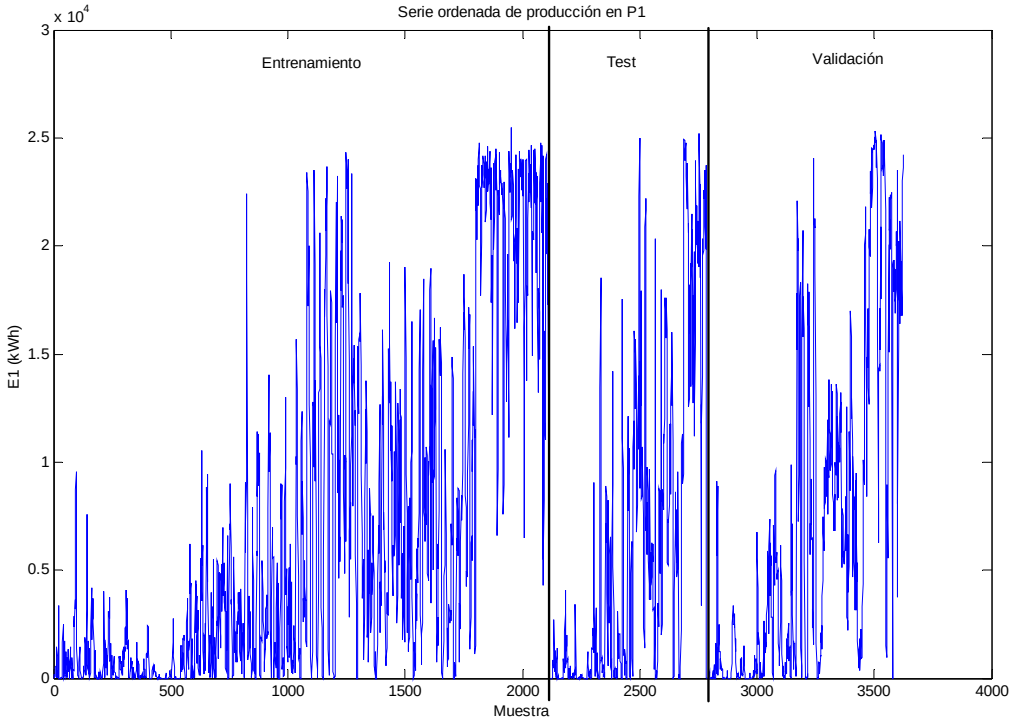


Figura 5: Series de producción en P1 correspondientes a los conjuntos de entrenamiento, test y validación

2.1.2 Predicciones realizadas con el modelo Casandra

En las siguientes figuras se representa los errores absolutos medios cometidos por el modelo Casandra con los dos rangos de horizontes de predicción (1 a 24 y 25 a 48 horas). En ellas puede apreciarse que la predicción realizada con el horizonte 1 a 24 horas es en promedio siempre más precisa que la realizada con horizonte 25 a 48 horas.

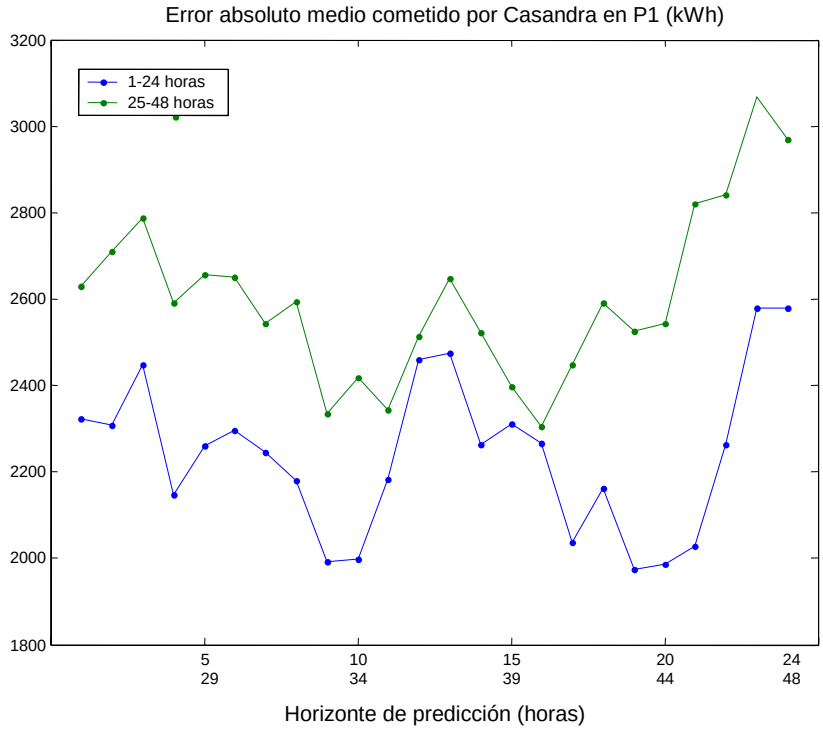


Figura 6: Errores absolutos medios cometidos por Casandra en función de su horizonte de predicción (kWh)

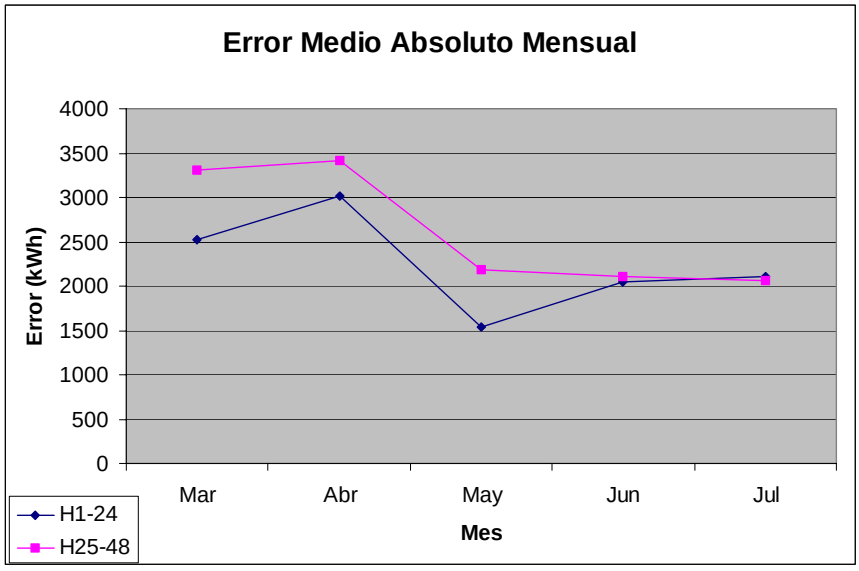


Figura 7: Errores absolutos medios cometidos por Casandra en P1 (kWh)

El análisis de la Figura 8 pone de manifiesto que los mayores errores de predicción corresponden al mes de mayor producción, pero que no existe una correlación clara entre nivel de producción y error.

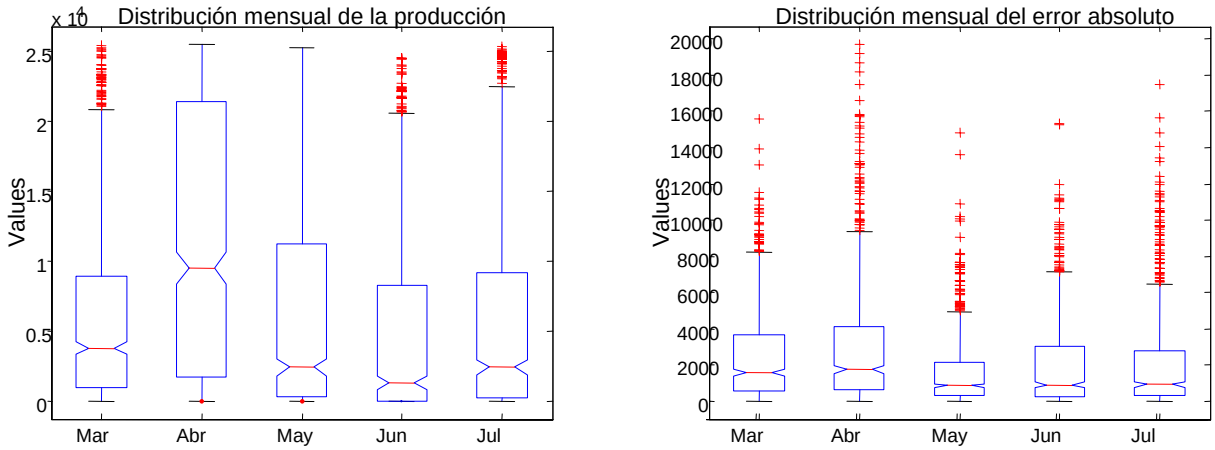


Figura 8: Distribuciones mensuales de las producciones y errores de predicción en P1 (kWh)

Una vez analizadas de forma individual las series de producción por un lado y los errores de predicción por otro, es interesante analizar las relaciones entre estas series para seleccionar el conjunto de variables de entrada del modelo de corto plazo.

La idea fundamental de los modelos de corto plazo es corregir las predicciones del modelo Casandra combinándolas con las últimas medidas de producciones reales. Para ello el vector de regresores del modelo de corto plazo podrá incluir:

- Retardos de la serie de producción medida
- Retardos de la serie de producción estimada con horizonte 1 a 24 horas
- Retardos de la serie de producción estimada con horizonte 25 a 48 horas
- Retardos de los errores cometidos con la predicción de horizonte 1 a 24 horas
- Retardos de los errores cometidos con la predicción de horizonte 25 a 48 horas

En la Figura 9 se muestra la función de autocorrelación simple (FAS) y parcial (FAP) de la serie de producción en P1 ([Box & Jenkins, 1976]). El lento decrecimiento de la FAS pone de manifiesto la no estacionariedad de la serie, por lo que se recurre en la Figura 10 a diferenciar la serie y analizar la serie de incrementos. El análisis de la FAS y FAP deesta nueva serie revela un comportamiento similar al de un paseo aleatorio, pero con una cierta estructura lineal asociada a los retardos 1 y 8.

Por otro lado, para determinar los retardos de las series de estimaciones que deberían ser considerados en el vector de regresores de un modelo lineal, se utiliza la función de correlación cruzada entre la serie de producción medida y las estimaciones (ver Figura 11 y Figura 12).

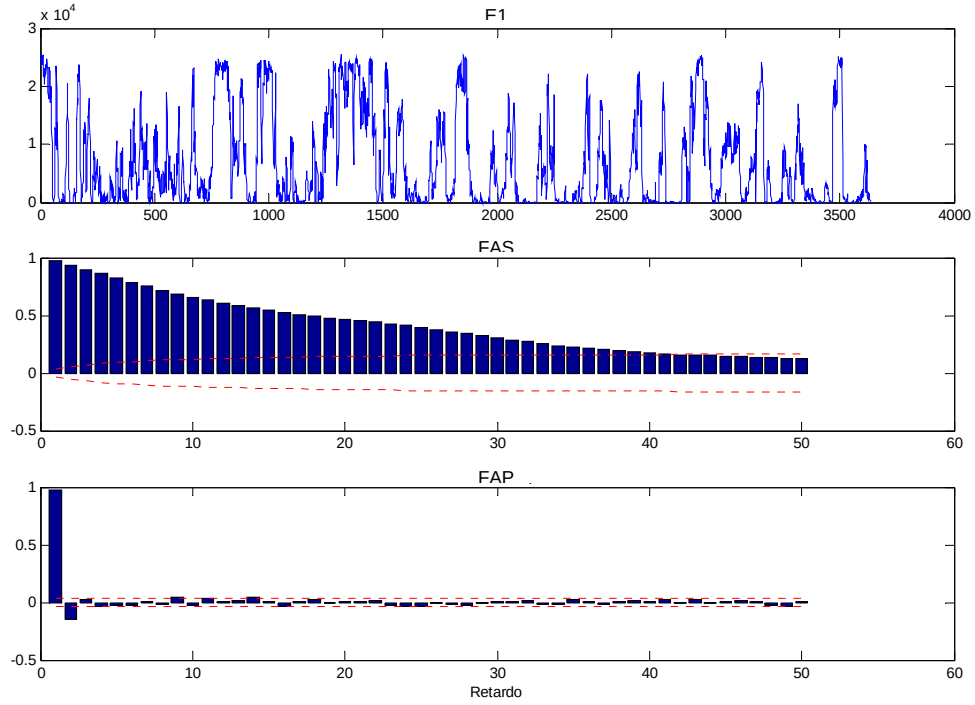


Figura 9: Funciones de Autocorrelación Simple y Parcial de la serie de producción en P1

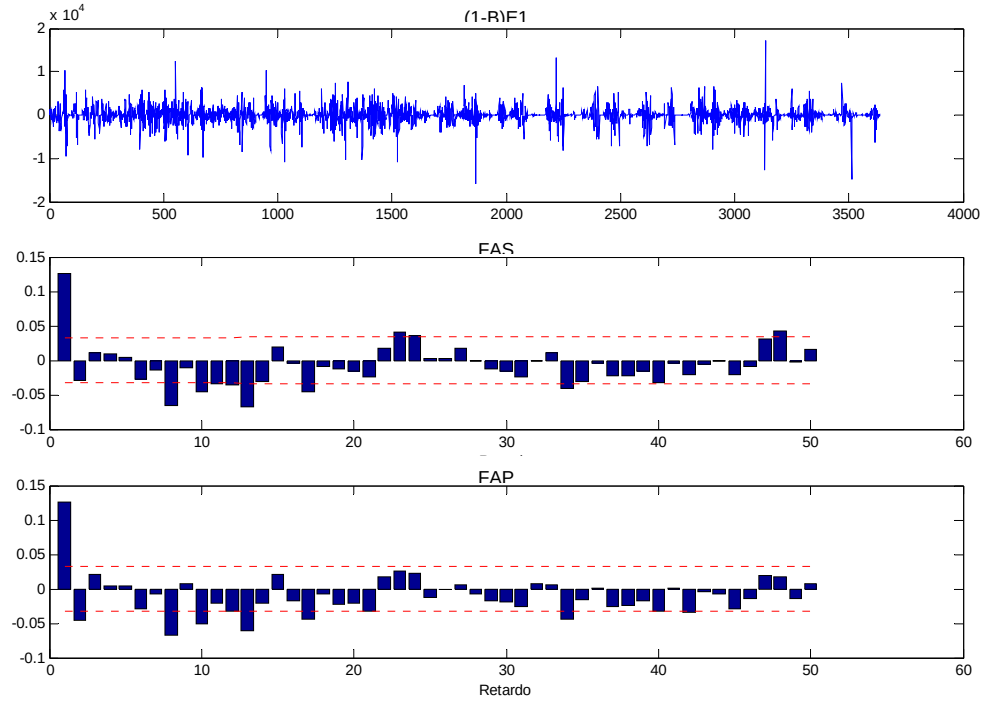


Figura 10: Funciones de Autocorrelación Simple y Parcial de la serie de incrementos de producción en P1

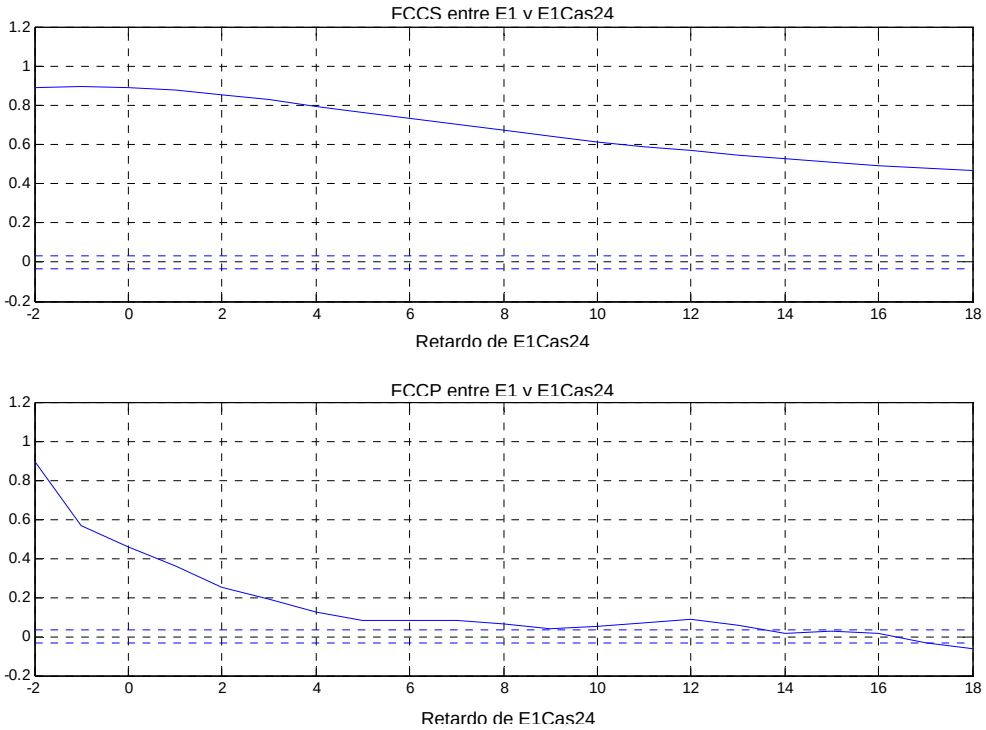


Figura 11: Funciones de correlación cruzada entre la producción en P1 y la estimación con horizonte 1 a 24 horas

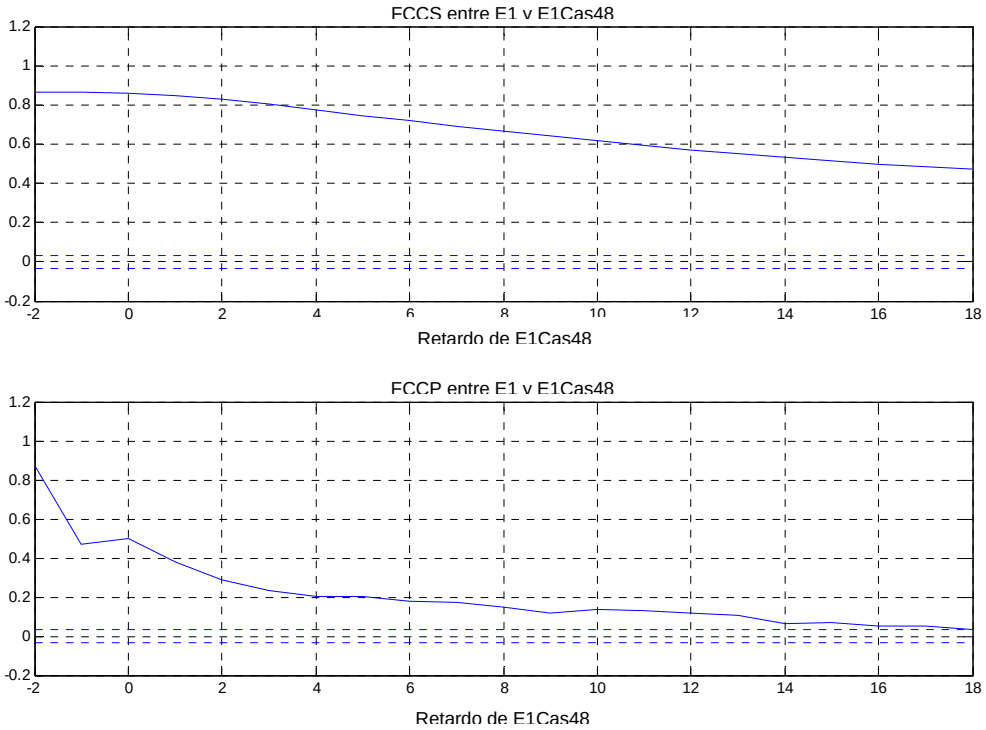


Figura 12: Funciones de correlación cruzada entre la producción en P1 y la estimación con horizonte 25 a 48 horas

El análisis de la Figura 11 permite concluir que la producción en la hora *h* está más correlada, desde el punto de vista lineal, con la predicción H1 realizada para la hora *h+1* que con la predicción realizada para la hora *h*, mientras que en la Figura 12 se pone de manifiesto que las estimaciones de horizonte H2 realizadas para las horas *h+2* y *h+1* están más correladas con la producción que las realizadas para la hora *h*.

Por otro lado, el análisis de las funciones de correlación cruzada parcial permite concluir que sería conveniente incluir en el vector de regresores del modelo de producción de la hora *h*, las estimaciones correspondientes a las horas *h-2, h-1, h, h+1 y h+2.*

2.2 Identificación y ajuste de los modelos de corto plazo

Los modelos utilizados en este estudio para la realizar la predicción a corto plazo de la producción de parques eólicos son modelos del tipo NARX (“Nonlinear AutoRegressive models whith eXogenous input variables”, [Ljung & Sjöberg, 1992] , [Sjöberg, 1995]) que utilizan Perceptrones Multicapa ([Haykin, 1994]) de una única capa oculta como aproximadores funcionales. La ventaja de estos modelos es que no son modelos recurrentes, lo que simplifica y acelera el ajuste de sus parámetros.

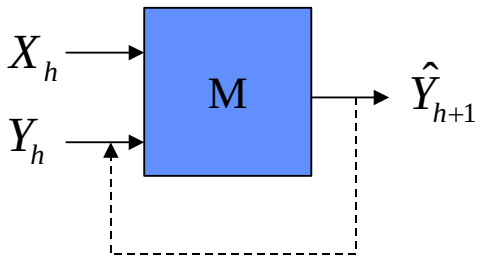
Dado que la penalización de los desvíos en el mercado eléctrico se realiza sobre el valor absoluto de los mismos ([RD 436]), los parámetros de los modelos se han ajustado para minimizar la siguiente función de coste:

$$F = \frac{1}{N_{ej}} \sum_{i=1}^{N_{ej}} \left| \hat{E}_{h+k} - E_{h+k} \right| + \lambda \sum_{j=1}^{N_w} w_j^2$$

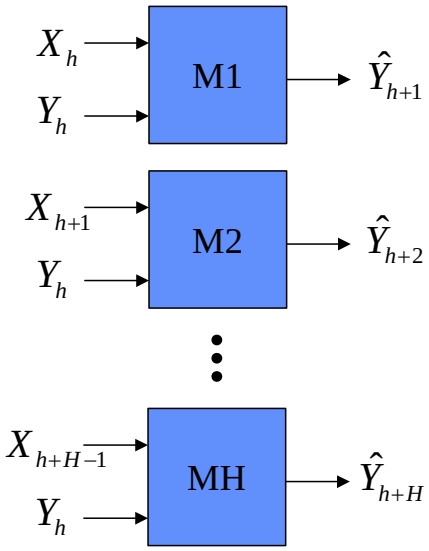
donde el primer término corresponde al error absoluto medio y el segundo es un término de regularización que favorece la capacidad de generalización del modelo ([Vapnik, 1992]).

Finalmente es importante considerar que existen distintas estrategias para construir modelos de predicción a corto plazo de horizonte múltiple:

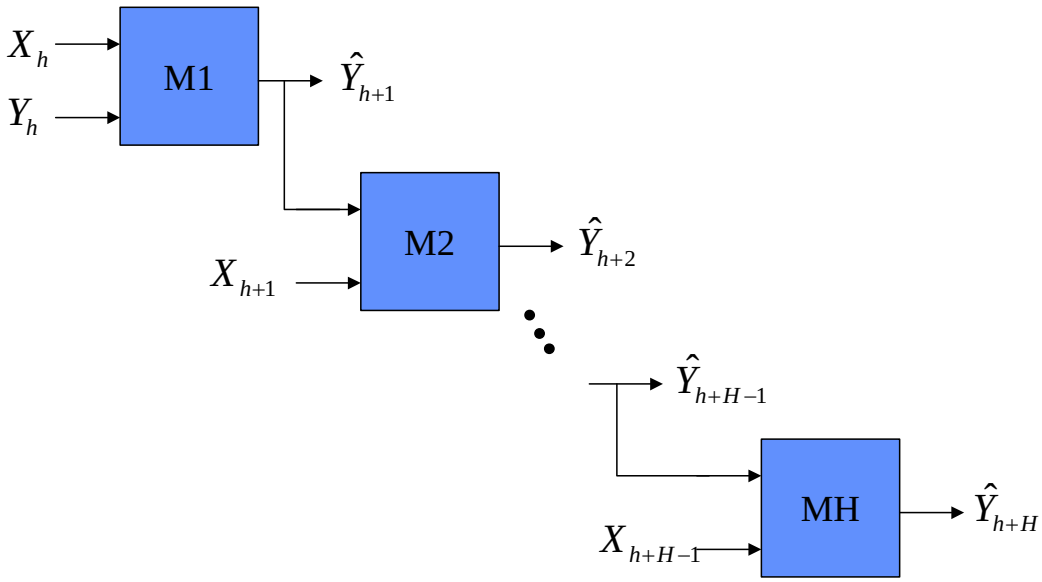
a) La opción más sencilla es ajustar un único modelo para predecir la hora siguiente y generar las predicciones de los distintos horizontes realimentando las propias predicciones. El inconveniente de esta estrategia es que el procedimiento de ajuste de los parámetros no asegura en el caso general la estabilidad de las predicciones a medida que crece el horizonte de predicción.



b) La segunda opción consiste en ajustar un modelo independiente para cada horizonte de predicción, sin utilizar las salidas de unos como entradas para otros.



c) La tercera opción consiste en ajustar un modelo para horizonte de predicción, pero utilizando las salidas de unos como entradas para otros. La primera alternativa es equivalente a ésta si se hacen coincidir los modelos M1, M2, ..., MH.



En el presente trabajo se ha optado por la segunda opción, de tal forma que cada horizonte de predicción se trata con un modelo independiente. Con esta alternativa se simplifica la operación y mantenimiento de los modelos, ya que en caso de tener que reajustar los parámetros de uno de los modelos el resto no se vería afectado.

Por otro lado no se ha tenido en cuenta que de cara a la operación en los mercados intradiarios cada horizonte de predicción podría limitarse a un subconjunto de horas. Así por ejemplo el modelo de predicción del horizonte *h+5* podría limitarse a la predicción de las horas 1, 5, 8, 12, 16 y 21, que corresponden con el inicio del

periodo de programación de cada una de las seis sesiones del mercado intradiario. Al no considerar esta limitación, todas las horas del día pueden ser predichas con los distintos horizontes de predicción, lo que puede resultar útil en condiciones reales de operación.

Partiendo de los análisis realizados en el apartado anterior, y optando por una solución homogénea para todos los horizontes de predicción, se ha utilizado la siguiente estructura para cada uno de los modelos de corto plazo:

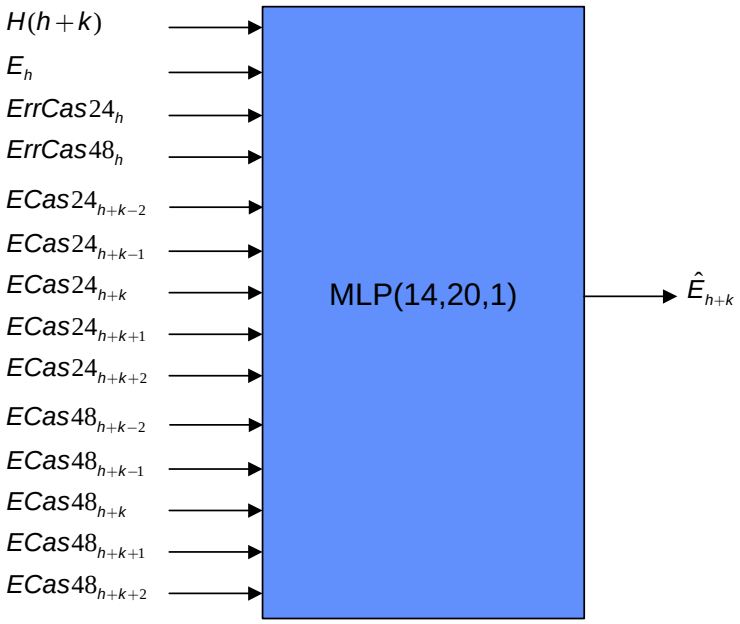


Figura 13: Estructura de los modelos de corto plazo

De esta forma el modelo de horizonte *k* es un perceptrón multicapa con una capa oculta de 20 neuronas con función de activación hiperbólica, una neurona de salida con la misma función de activación[1] y 14 entradas correspondientes a:

- *H(h+k)*: horizonte correspondiente a la predicción de Casandra para la hora *h+k*
- E_h: última medida disponible de la producción del parque
- $ErrCas24_h$ *y* $ErrCas48_h$: últimos errores de predicción cometidos por Casandra con sus dos horizontes de predicción
- *ECas24 y Ecas48*: estimaciones de Casandra para las horas *h+k-2 a h+k+2* con sus dos horizonrtes de predicción

[1] Se ha utilizado una función de activación hiperbólica en la capa de salida, en lugar de una lineal, para facilitar la reproducción de las saturaciones correspondientes a carga nula y máxima.

2.3 Resultados

Para cuantificar los resultados obtenidos con lo modelos de predicción a corto plazo se han utilizado los siguientes índices:

- MAPE: Error absoluto medio porcentual calculado como el cociente entre la media de los valores absolutos de los errores y la media de la producción.
- MEJORA: porcentaje de mejora del error absoluto medio respecto a las estimaciones obtenidas con el modelo Casandra con horizonte 1 a 24 horas.

A continuación se muestran los resultados obtenidos con el modelo propuesto (MLP), el modelo Casandra con horizonte 1 a 24 horas (Cas24), el modelo Casandra con horizonte 25 a 48 horas (Cas48) y el modelo ingenuo, correspondiente a dar como estimación la última medida de producción disponible, utilizando como banco de pruebas el conjunto completo de datos y el conjunto de validación. Se ha incluido, además de los horizontes de 5 a 8 horas, el horizonte de predicción de 1 hora.

HORIZONTE	1	5	6	7	8	Promedio (5 a 8)
MAPE(Cas24)	32.7%	32.9%	32.9%	32.9%	33.0%	**32.9%**
MAPE(Cas48)	37.9%	38.0%	38.1%	38.1%	38.2%	**38.1%**
MAPE(MLP)	16.2%	25.8%	27.1%	27.1%	26.6%	**26.6%**
MAPE(Ingenuo)	16.4%	42.4%	47.3%	51.6%	55.6%	**49.2%**
MEJORA(Cas48)	-15.8%	-15.7%	-15.8%	-15.8%	-15.9%	**-15.8%**
MEJORA(MLP)	50.5%	21.5%	17.7%	17.8%	19.3%	**19.1%**
MEJORA(Ingenuo)	50.0%	-29.0%	-43.6%	-56.6%	-68.8%	**-49.5%**

Tabla 1: Resultados obtenidos sobre el conjunto completo en P1

HORIZONTE	1	5	6	7	8	Promedio (5 a 8)
MAPE(Cas24)	34.8%	34.6%	34.8%	34.8%	34.8%	**34.8%**
MAPE(Cas48)	33.8%	33.6%	33.5%	33.4%	33.3%	**33.4%**
MAPE(MLP)	15.9%	28.0%	29.0%	29.0%	30.6%	**29.2%**
MAPE(Ingenuo)	15.1%	37.5%	42.0%	46.3%	50.4%	**44.1%**
MEJORA(Cas48)	2.7%	3.1%	3.6%	4.0%	4.5%	**3.8%**
MEJORA(MLP)	54.3%	19.1%	16.6%	16.8%	12.2%	**16.2%**
MEJORA(Ingenuo)	56.6%	-8.2%	-20.9%	-33.0%	-44.7%	**-26.7%**

Tabla 2: Resultados obtenidos sobre el conjunto de validación en P1

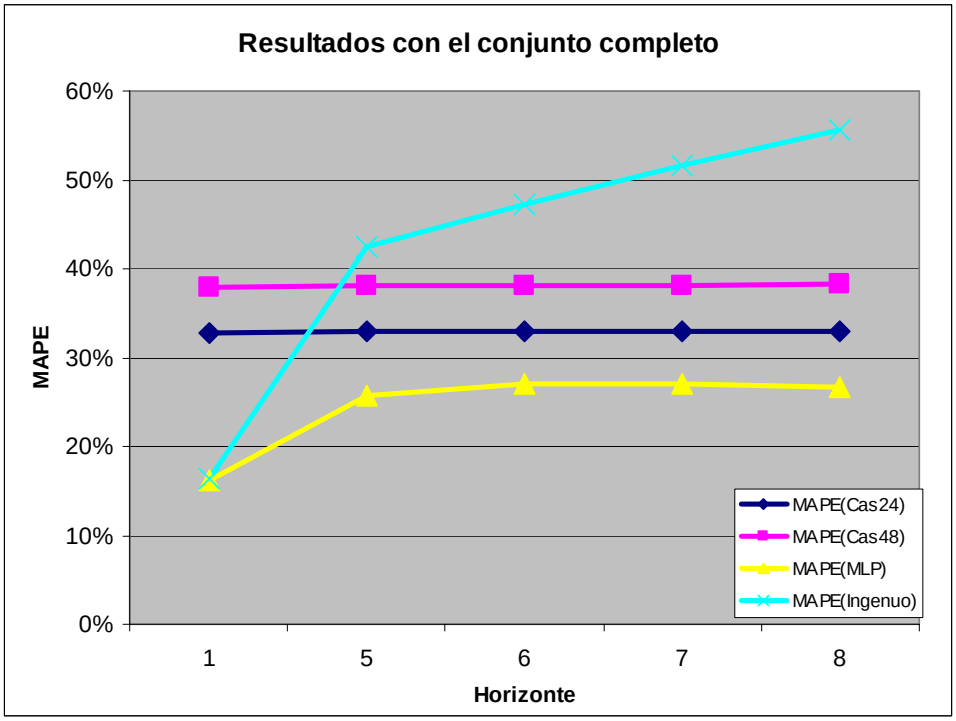


Figura 14: Niveles de error obtenidos sobre el conjunto completo en P1

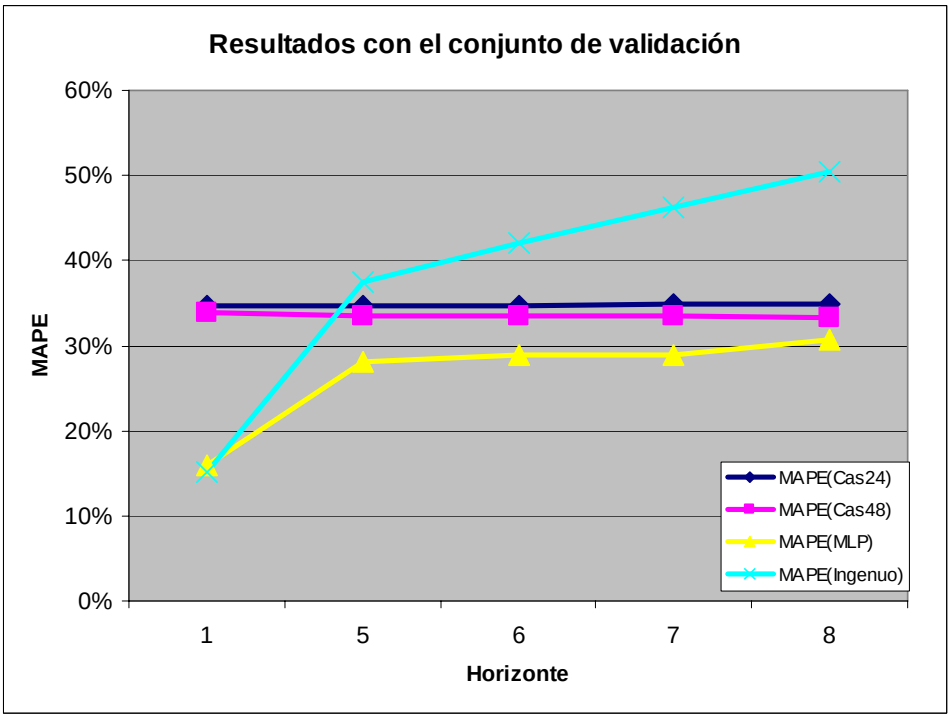


Figura 15: Niveles de error obtenidos sobre el conjunto de validación en P1

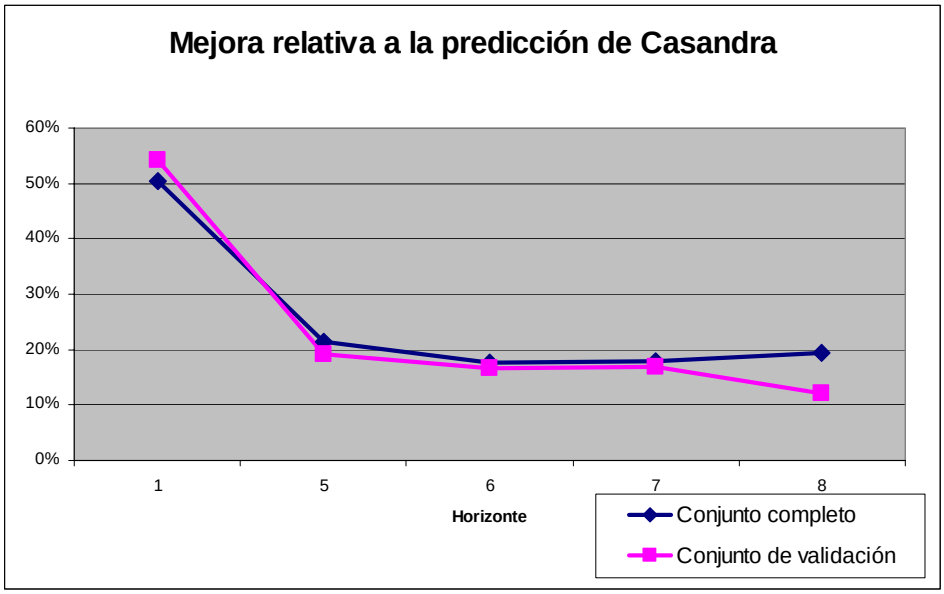


Figura 16: Mejoras relativas a la predicción de Casandra en P1

En todos los horizontes de predicción el modelo de corto plazo mejora significativamente las predicciones de Casandra, que a su vez son más precisas que las del estimador ingenuo a partir del horizonte 5. Con horizonte 1 los niveles de error del modelo propuesto coinciden con los del estimador ingenuo. Para mejorar este resultado sería necesario incluir una componente de media móvil, obteniendo un modelo recurrente. Este análisis no se ha realizado ya que el horizonte 1 no es de utilidad de cara a la gestión de la energía en los mercados intradiarios.

Como conclusión puede establecerse que el modelo MLP **presenta un error absoluto medio del 29.2%** en el horizonte de interés para los mercados intradiarios, lo que supone una **reducción media del 16.2%** del error cometido por el modelo Casandra.

En el apéndice se ha incluido el análisis de los residuos de estos modelos.

3 Análisis del Parque 2

3.1 Análisis exploratorio de los datos de partida

Como punto de partida se cuenta con la siguiente información:

- Parque 2 (en adelante P2): datos del 01/03/2002 al 30/06/2003

    - E2: Producciones horarias medidas (kWh)

    - E2Cas24: Predicciones horarias de producción realizadas con el modelo Casandra con horizonte de 1 a 24h (kWh)

    - E2Cas48: Predicciones horarias de producción realizadas con el modelo Casandra con horizonte de 25 a 48h (kWh)

3.1.1 Producciones

En las siguientes figuras se representa gráficamente la producción en P2 durante el período de estudio. En ellas puede apreciarse cómo la producción máxima del parque ronda los 17MWh.

Dado el elevado número de muestras disponible en este parque, no ha sido necesario realizar una extracción selectiva de los conjuntos de entrenamiento, test y validación, habiendo sido seleccionados de forma secuencial tal y como se muestra en la siguiente figura.

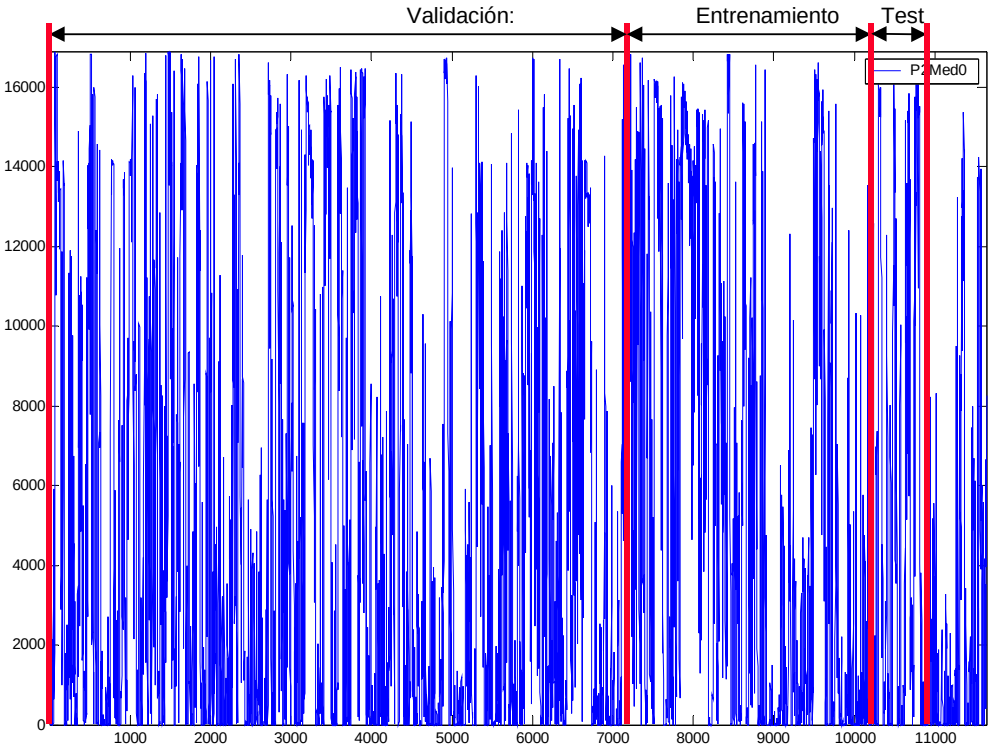


Figura 17: Serie de producción horaria en P2 (kWh)

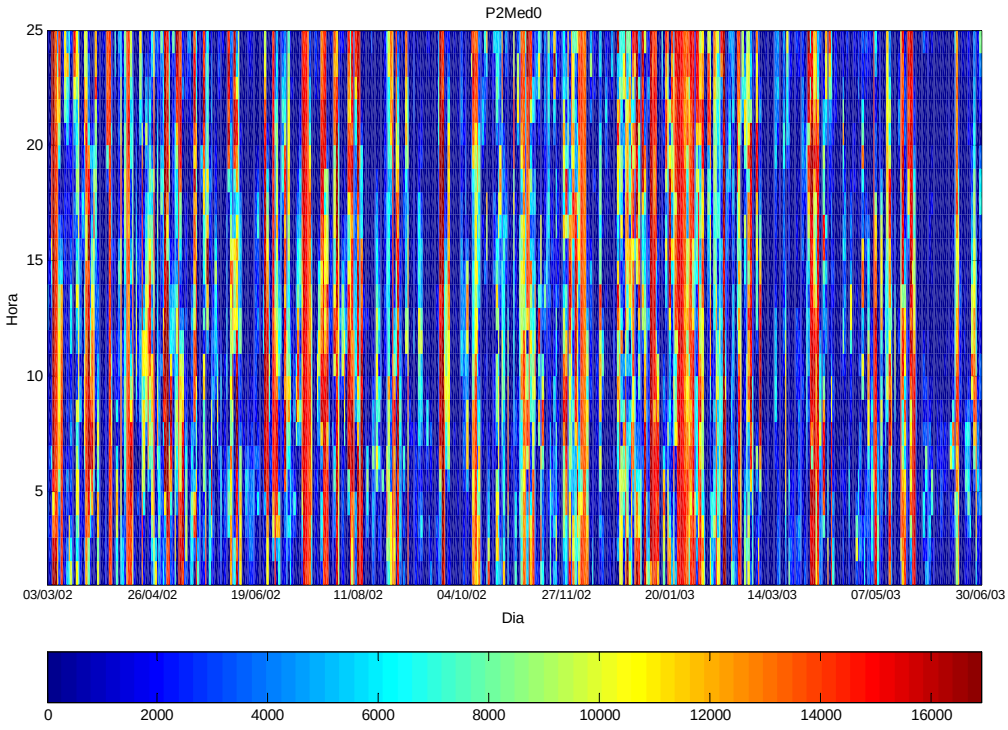


Figura 18: Mapa de producción diaria en P2 (kWh)

En la Figura 19 se muestra un análisis de agrupamiento (“clustering”) de los perfiles diarios de producción en P2. En azul se representa el representante de cada grupo, en amarillo los perfiles diarios de producción asociados en cada grupo y en rojo los intervalos de dispersión.

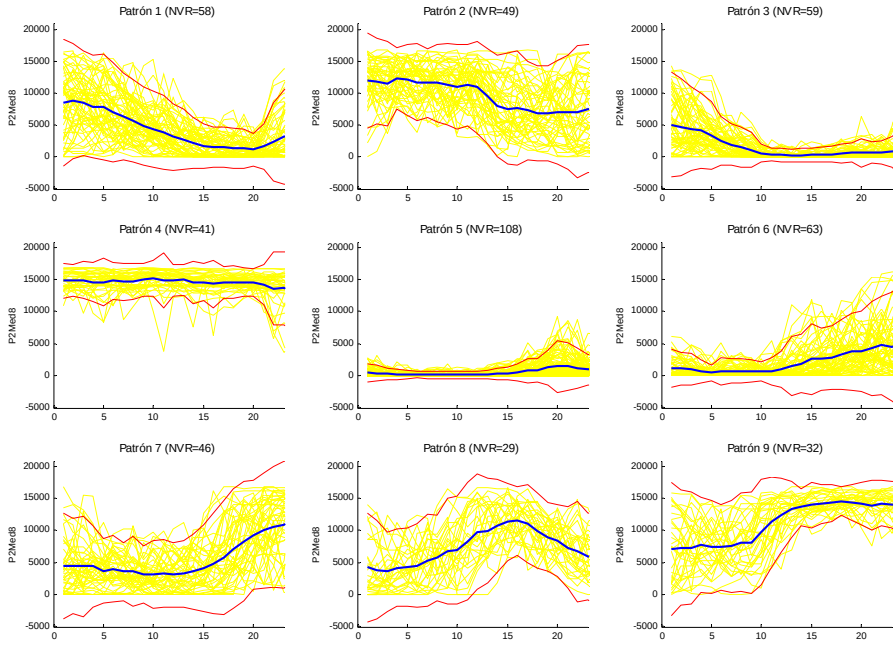


Figura 19: Patrones diarios de producción en P2 (kWh)

3.1.2 Predicciones realizadas con el modelo Casandra

En las siguientes figuras se representa los errores absolutos medios cometidos por el modelo Casandra con los dos rangos de horizontes de predicción (1 a 24 y 25 a 48 horas). En ellas puede apreciarse el hecho inesperado que la predicción realizada con el horizonte 1 a 24 horas no es en promedio siempre más precisa que la realizada con horizonte 25 a 48 horas, ya que para las primeras horas del horizonte la segunda resulta ser más precisa.

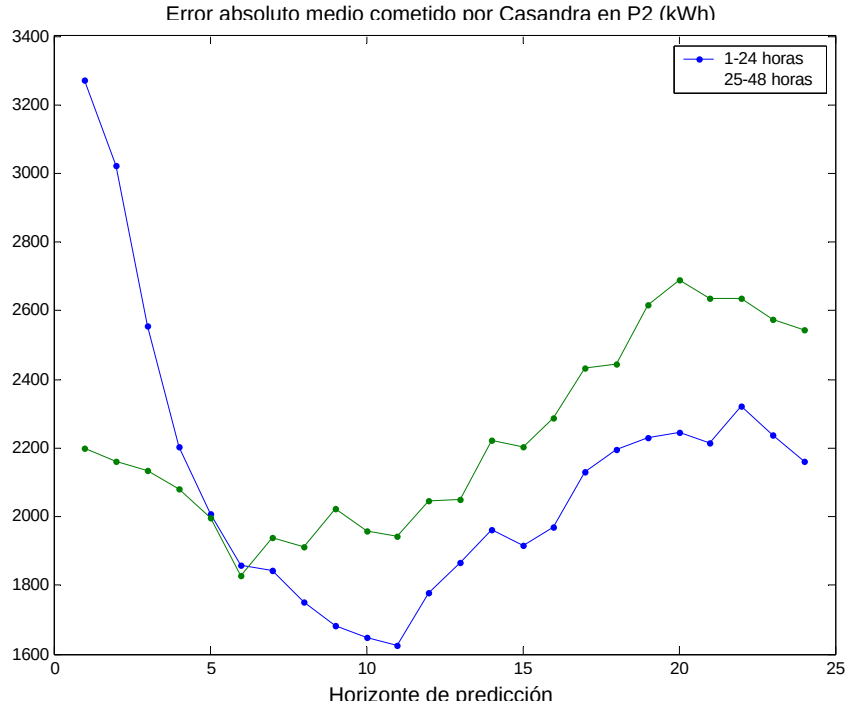


Figura 20: Errores absolutos medios cometidos por Casandra en P2 en función de su horizonte de predicción (kWh)

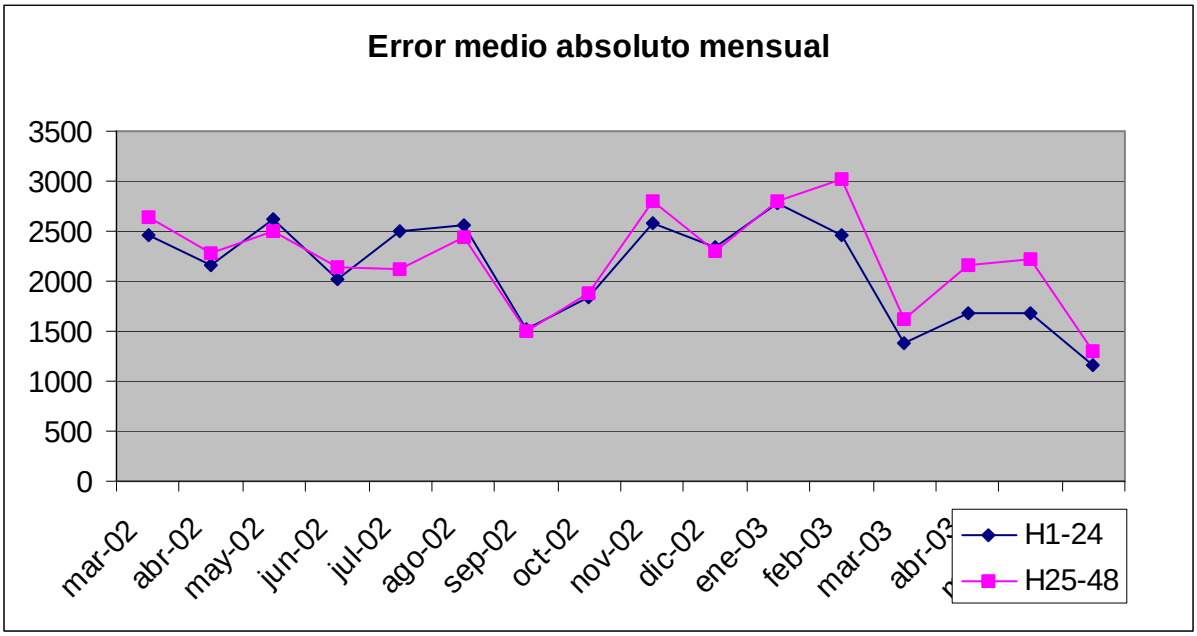


Figura 21: Errores absolutos medios cometidos por Casandra en P2 (kWh)

El análisis de la Figura 22 pone de manifiesto nuevamente que aunque los mayores errores de predicción suelen darse los meses de mayor producción, no existe una correlación perfecta entre nivel de producción y error.

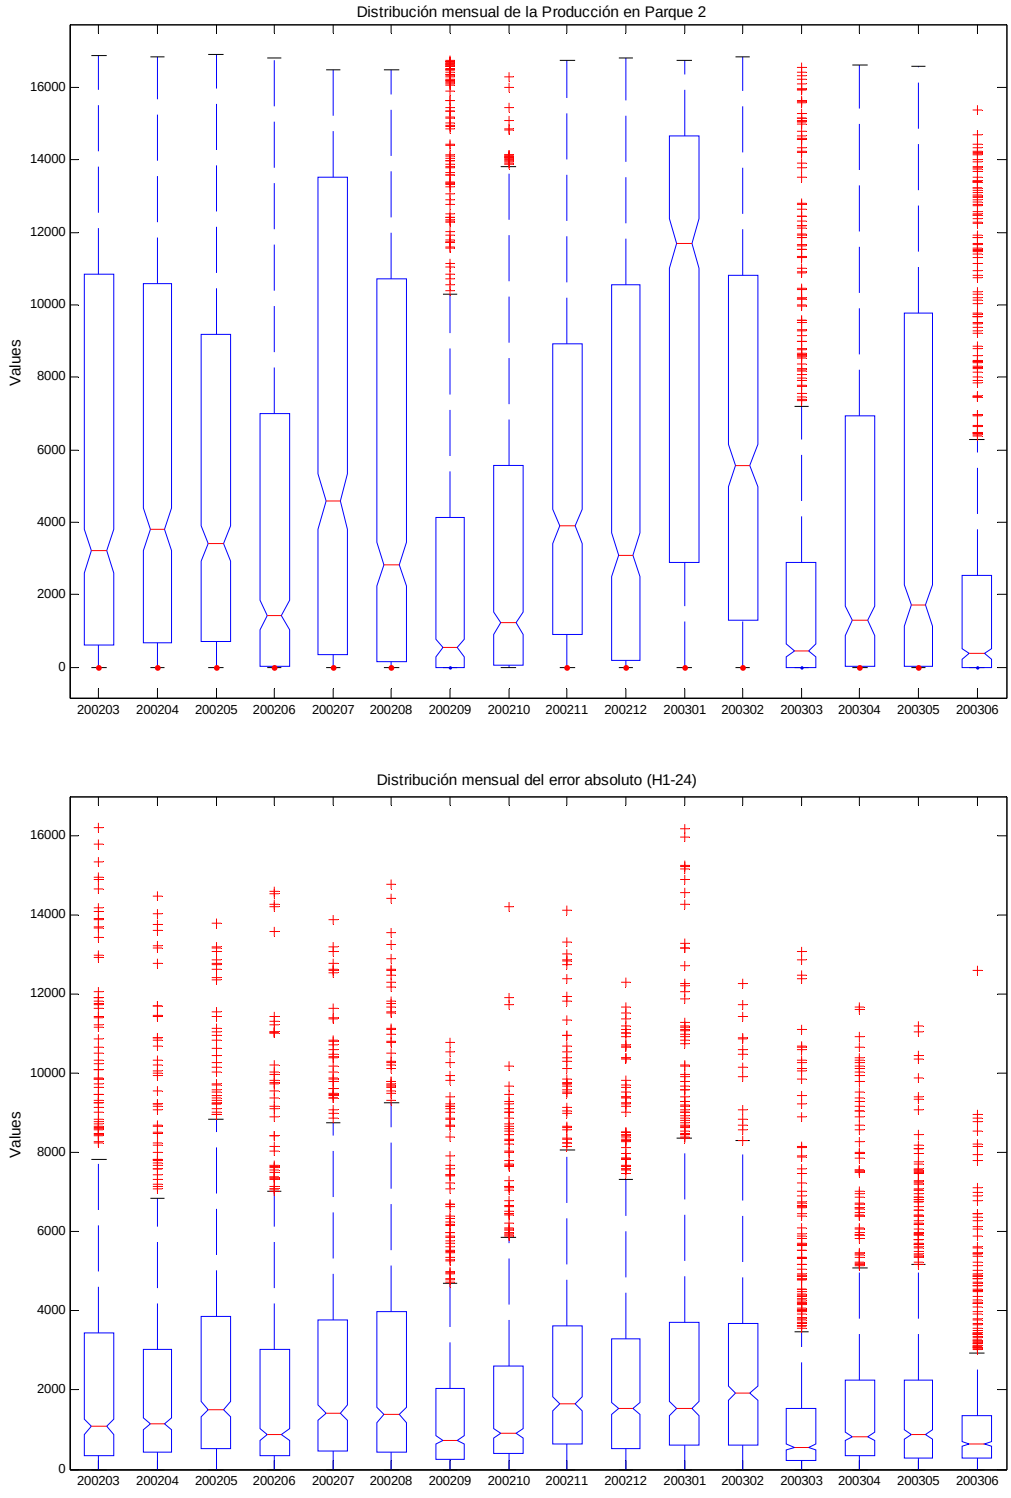


Figura 22: Distribuciones mensuales de las producciones y errores de predicción en P2 (kWh)

Una vez analizadas de forma individual las series de producción por un lado y los errores de predicción por otro, es interesante analizar las relaciones entre estas series para seleccionar el conjunto de variables de entrada del modelo de corto plazo.

En la Figura 23 se muestra la función de autocorrelación simple (FAS) y parcial (FAP) de la serie de producción en P2 ([Box & Jenkins, 1976]). El lento decrecimiento de la FAS pone de manifiesto la no estacionariedad de la serie, por lo que se recurre en la Figura 24 a diferenciar la serie y analizar la serie de incrementos. El análisis de la FAS y FAP de esta nueva serie revela un comportamiento completamente distinto al del parque 1, al aparecer coeficientes significativos en los órdenes 2 y 9. No obstante los niveles de correlación son muy bajos, por lo que su comportamiento sigue siendo similar al de un paseo aleatorio.

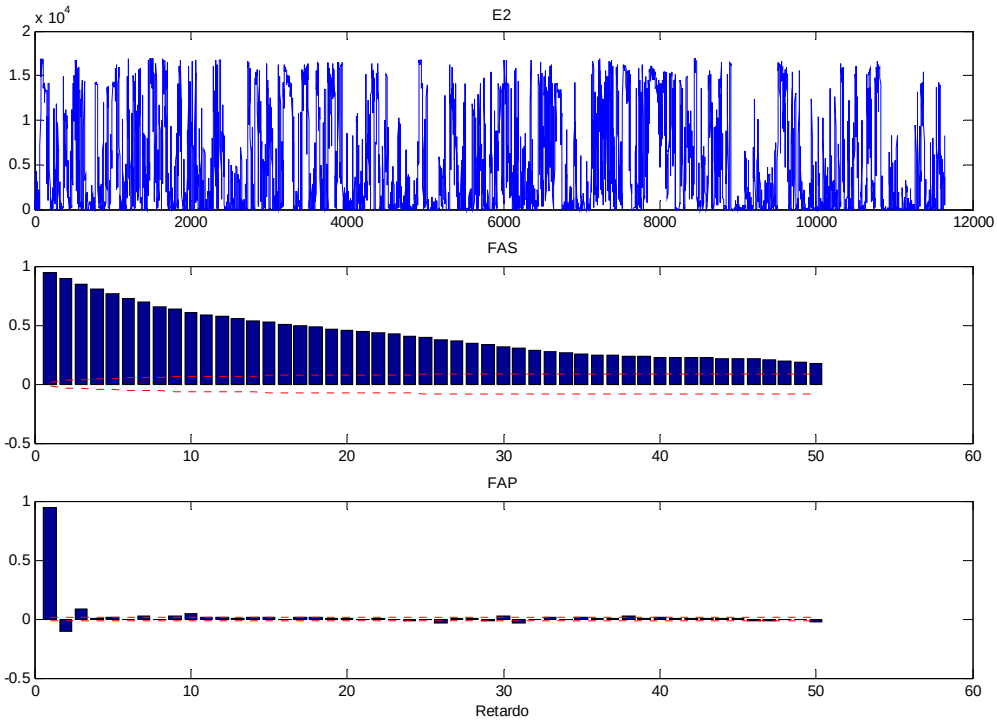


Figura 23: Funciones de Autocorrelación Simple y Parcial de la serie de producción en P2

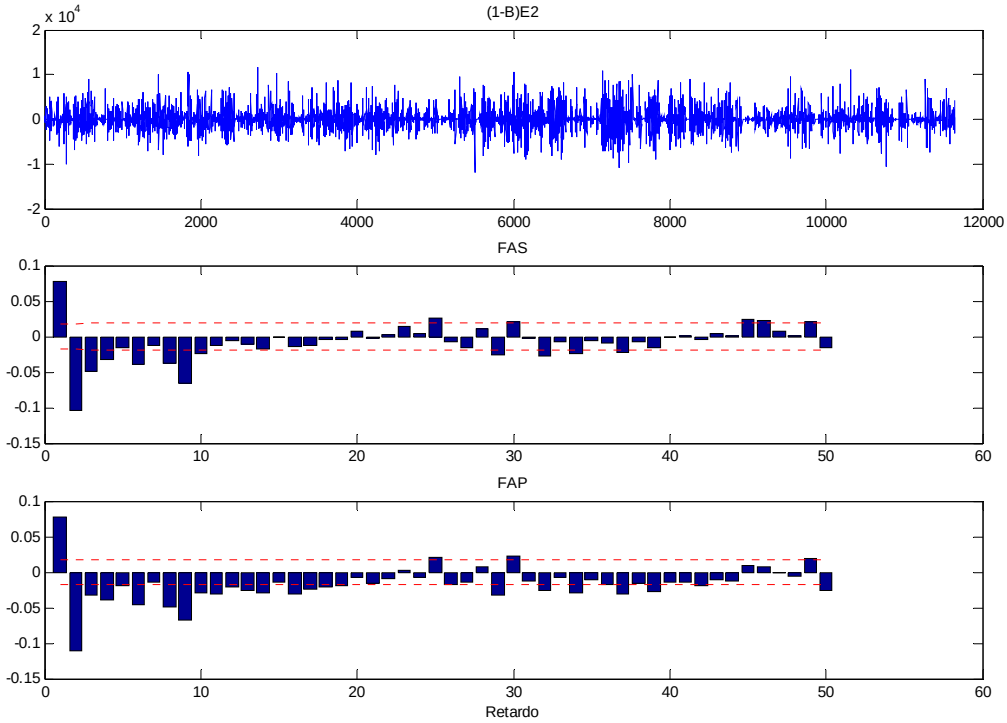


Figura 24: Funciones de Autocorrelación Simple y Parcial de la serie de incrementos de producción en P2

Por otro lado, para determinar los retardos de las series de estimaciones que deberían ser considerados en el vector de regresores de un modelo lineal, se utiliza la función de correlación cruzada entre la serie de producción medida y las estimaciones (ver Figura 25 y Figura 26).

El análisis de la Figura 25 permite concluir que la producción en la hora *h* presenta máxima correlación lineal con la predicción H1 realizada para esa misma hora *h*, mientras que en la Figura 26 se pone de manifiesto que las estimaciones de horizonte H2 realizadas para la hora *h+1* está más correlada con la producción que las realizadas para la hora *h*.

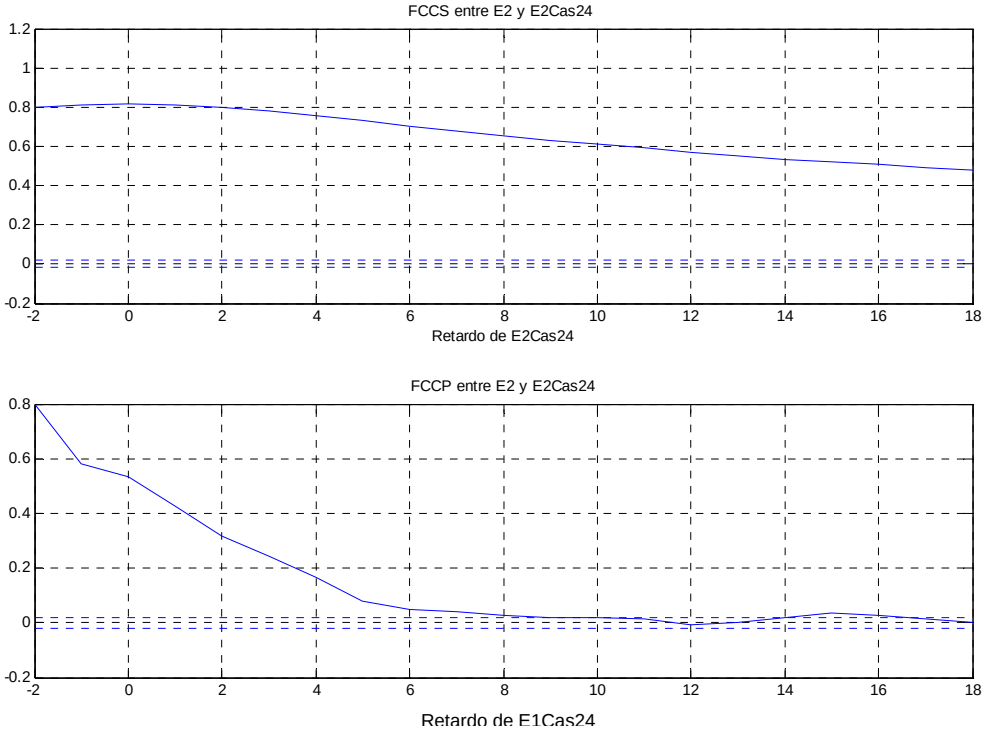


Figura 25: Funciones de correlación cruzada entre la producción en P2 y la estimación con horizonte 1 a 24 horas

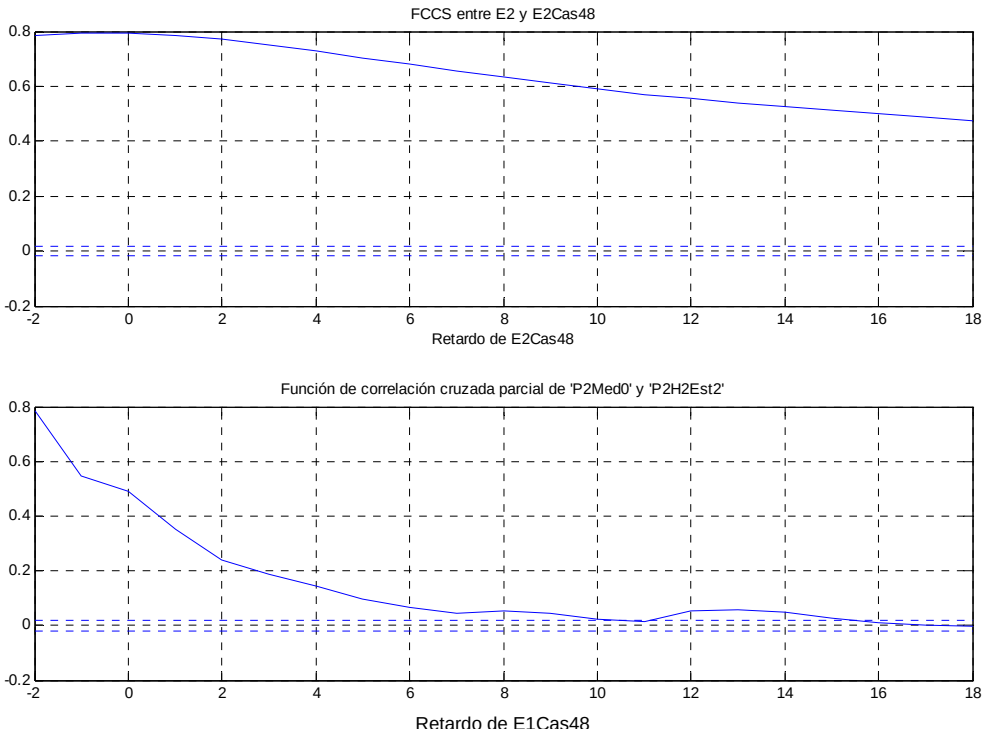


Figura 26: Funciones de correlación cruzada entre la producción en P2 y la estimación con horizonte 25 a 48 horas

3.2 Identificación y ajuste de los modelos de corto plazo

Partiendo de los análisis realizados en el apartado anterior, y optando nuevamente por una solución homogénea para todos los horizontes de predicción, se ha utilizado la siguiente estructura para cada uno de los modelos de corto plazo:

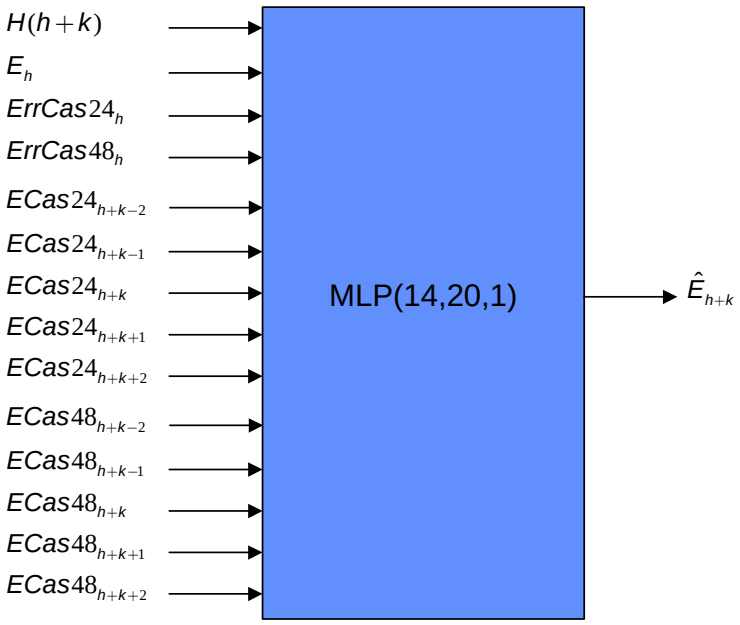


Figura 27: Estructura de los modelos de corto plazo

De esta forma el modelo de horizonte *k* es un perceptrón multicapa con una capa oculta de 20 neuronas con función de activación hiperbólica, una neurona de salida con la misma función de activación[2] y 14 entradas correspondientes a:

- *H(h+k)*: horizonte correspondiente a la predicción de Casandra para la hora *h+k*
- E_h: última medida disponible de la producción del parque
- $ErrCas24_h$ *y* $ErrCas48_h$: últimos errores de predicción cometidos por Casandra con sus dos horizontes de predicción
- *ECas24 y Ecas48*: estimaciones de Casandra para las horas *h+k-2 a h+k+2* con sus dos horizonrtes de predicción

[2] Se ha utilizado una función de activación hiperbólica en la capa de salida, en lugar de una lineal, para facilitar la reproducción de las saturaciones correspondientes a carga nula y máxima.

3.3 Resultados

Para cuantificar los resultados obtenidos con lo modelos de predicción a corto plazo se han utilizado los siguientes índices:

- MAPE: Error absoluto medio porcentual calculado como el cociente entre la media de los valores absolutos de los errores y la media de la producción.
- MEJORA: porcentaje de mejora del error absoluto medio respecto a las estimaciones obtenidas con el modelo Casandra con horizonte 1 a 24 horas.

A continuación se muestran los resultados obtenidos con el modelo propuesto (MLP), el modelo Casandra con horizonte 1 a 24 horas (Cas24), el modelo Casandra con horizonte 25 a 48 horas (Cas48) y el modelo ingenuo, correspondiente a dar como estimación la última medida de producción disponible, utilizando como banco de pruebas el conjunto completo de datos y el conjunto de validación. Se ha incluido, además de los horizontes de 5 a 8 horas, el horizonte de predicción de 1 hora.

HORIZONTE	1	5	6	7	8	Promedio (5 a 8)
MAPE(Cas24)	42.7%	42.7%	42.7%	42.7%	42.7%	**42.7%**
MAPE(Cas48)	45.1%	45.0%	45.0%	45.0%	45.0%	**45.0%**
MAPE(MLP)	20.9%	34.1%	34.8%	37.3%	37.8%	**36.0%**
MAPE(Ingenuo)	20.6%	49.2%	53.6%	57.3%	60.8%	**55.2%**
MEJORA(Cas48)	-5.6%	-5.6%	-5.6%	-5.6%	-5.6%	**-5.6%**
MEJORA(MLP)	50.9%	20.1%	18.4%	12.5%	11.3%	**15.6%**
MEJORA(Ingenuo)	51.7%	-15.4%	-25.6%	-34.3%	-42.5%	**-29.4%**

Tabla 3: Resultados obtenidos sobre el conjunto completo en P2

HORIZONTE	1	5	6	7	8	Promedio (5 a 8)
MAPE(Cas24)	45.4%	45.4%	45.4%	45.4%	45.4%	**45.4%**
MAPE(Cas48)	45.3%	45.3%	45.3%	45.3%	45.2%	**45.3%**
MAPE(MLP)	21.7%	34.8%	35.4%	40.1%	40.4%	**37.7%**
MAPE(Ingenuo)	21.1%	51.1%	55.8%	59.4%	62.9%	**57.3%**
MEJORA(Cas48)	0.2%	0.3%	0.3%	0.3%	0.3%	**0.3%**
MEJORA(MLP)	52.3%	23.5%	22.0%	11.6%	11.0%	**17.0%**
MEJORA(Ingenuo)	53.5%	-12.6%	-22.8%	-30.8%	-38.6%	**-26.2%**

Tabla 4: Resultados obtenidos sobre el conjunto de validación en P2

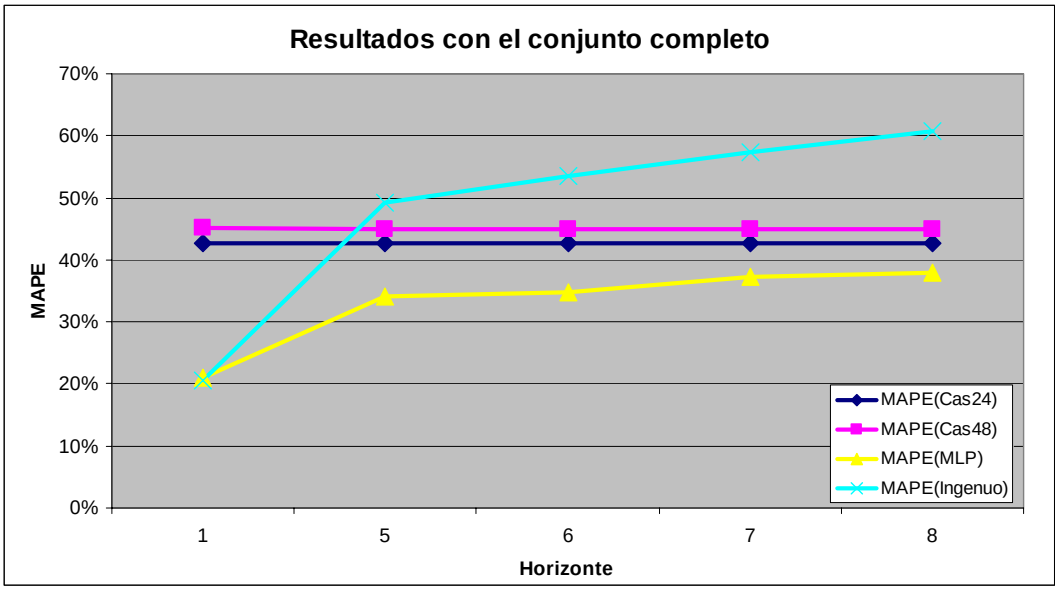


Figura 28: Niveles de error obtenidos sobre el conjunto completo en P2

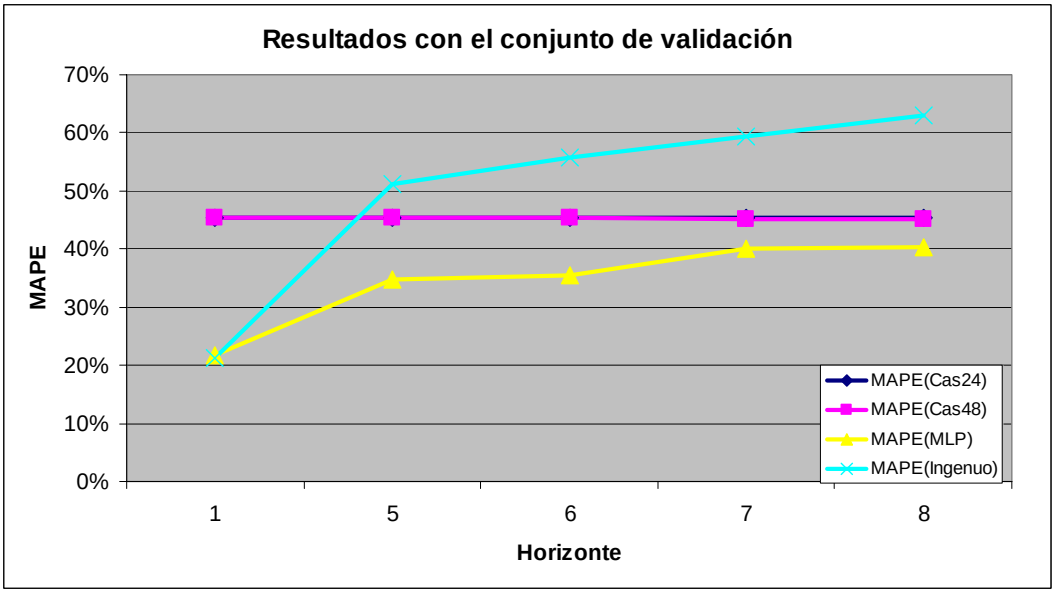


Figura 29: Niveles de error obtenidos sobre el conjunto de validación en P2

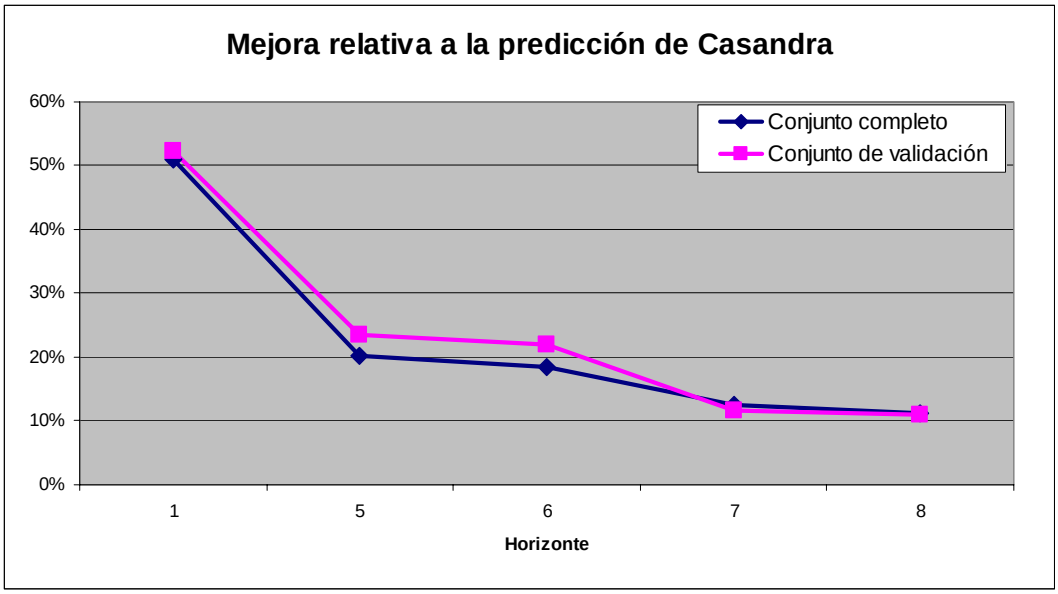


Figura 30: Mejoras relativas al modelo Casandra en P2

En el caso del parque 2 los niveles de error alcanzados por el modelo de corto plazo son muy superiores a los obtenidos con el parque 1, como ocurre con el modelo Casandra, debido a la mayor aleatoriedad de la producción en este parque. Sin embargo los niveles de mejora son similares en ambos parques, aunque la mejora en este último decrece más sensiblemente con el horizonte de predicción.

Como conclusión puede establecerse que el modelo MLP **presenta un error absoluto medio del 37.7%** en el horizonte de interés para los mercados intradiarios, lo que supone una **reducción media del 17.0%** del error cometido por el modelo Casandra.

En el apéndice se ha incluido el análsis de los residuos de estos modelos.

4 Análsis de la agregación de los parques 1 y 2

4.1 Análisis exploratorio de los datos de partida

En este apartado se analiza la agragación de los dos parques anteriores, por lo que el período de datos disponible coincide con la intersección de los dos anteriores:

- Parque 1 + Parque 2 (en adelante P12): datos del 01/03/2003 al 30/06/2003

    - E12: suma de las producciones horarias medidas (kWh)

    - E12Cas24: suma de las predicciones horarias de producción realizadas con el modelo Casandra con horizonte de 1 a 24h (kWh)

    - E12Cas48: suma de las predicciones horarias de producción realizadas con el modelo Casandra con horizonte de 25 a 48h (kWh)

El análisis se ha realizado considerando la agregación como un nuevo parque, sin utilizar la información individual de cada uno de ellos. La razón de esta decisión radica en que el solape de los datos de los dos parques es relativamente corto (sólo 4 meses), lo que limita la complejidad de los modelos que se podrían ajustar con estos datos. No obstante se ha observado que la incorporación en los modelos de información desagregada mejoraba ligeramente los resultados obtenidos, a costa de incrementar su complejidad.

4.1.1 Producciones

En las siguientes figuras se representa gráficamente la producción en P12 durante el período de estudio. En ellas puede apreciarse cómo la producción máxima del parque equivalente ronda los 40MWh, habiéndose alcanzado estos niveles de producción en sólo tres intervalos del período completo de análisis.

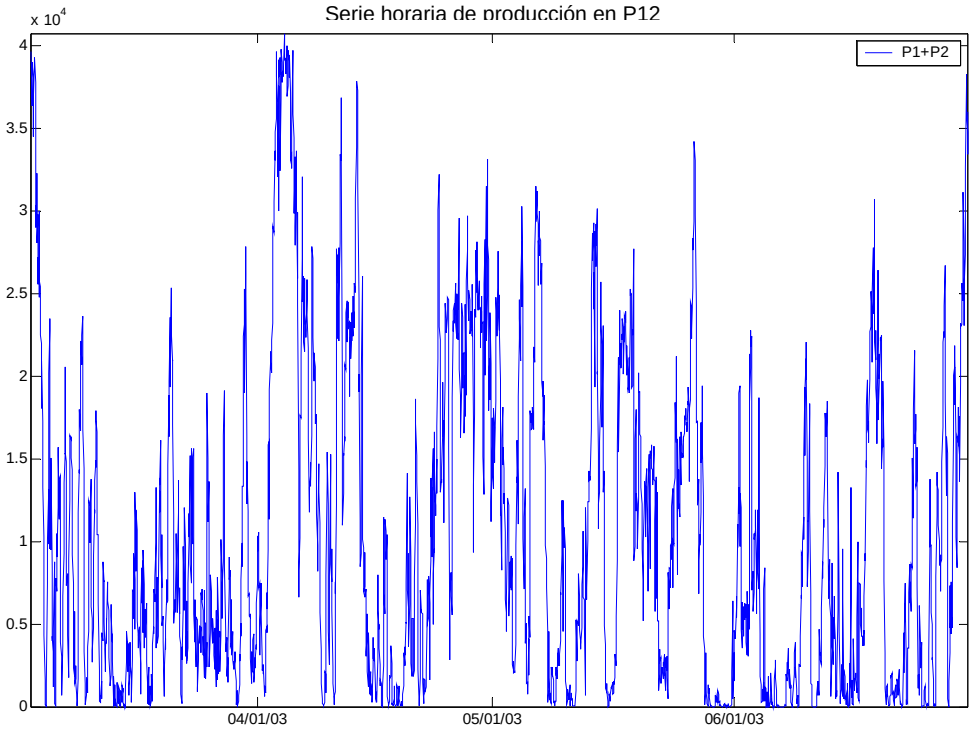


Figura 31: Serie de producción horaria en P12 (kWh)

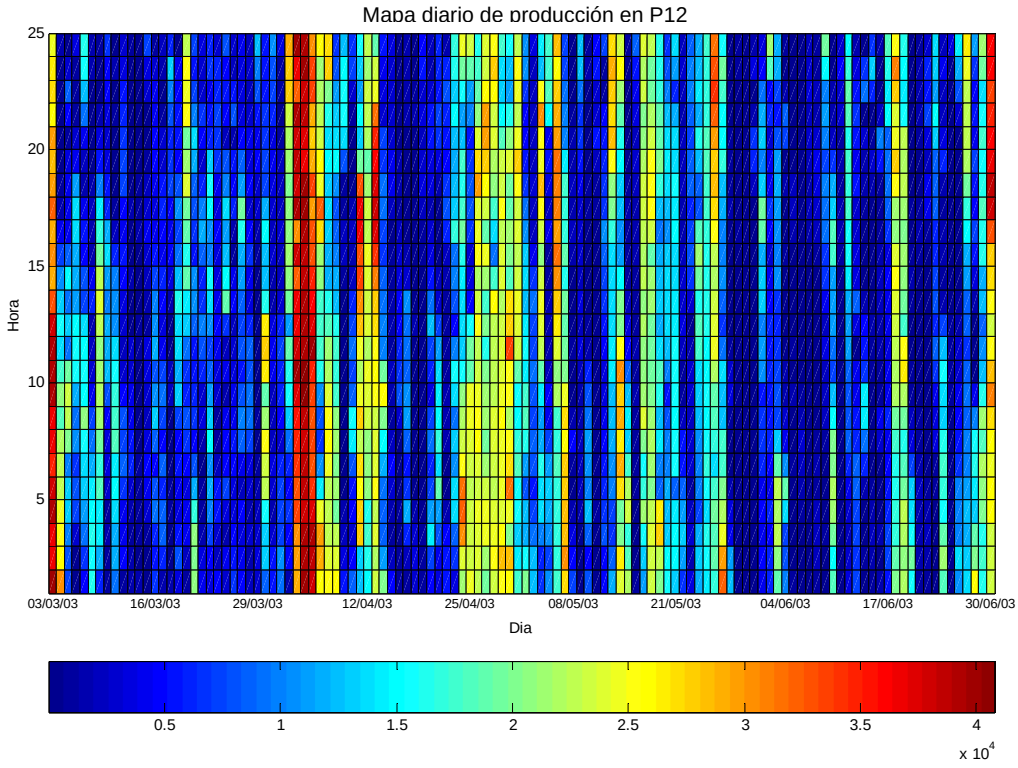


Figura 32: Mapa de producción diaria en P12 (kWh)

En la Figura 33 se muestra un análisis de agrupamiento (“clustering”) de los perfiles diarios de producción en P12. En azul se representa el representante de cada grupo, en amarillo los perfiles diarios de producción asociados en cada grupo y en rojo los intervalos de dispersión.

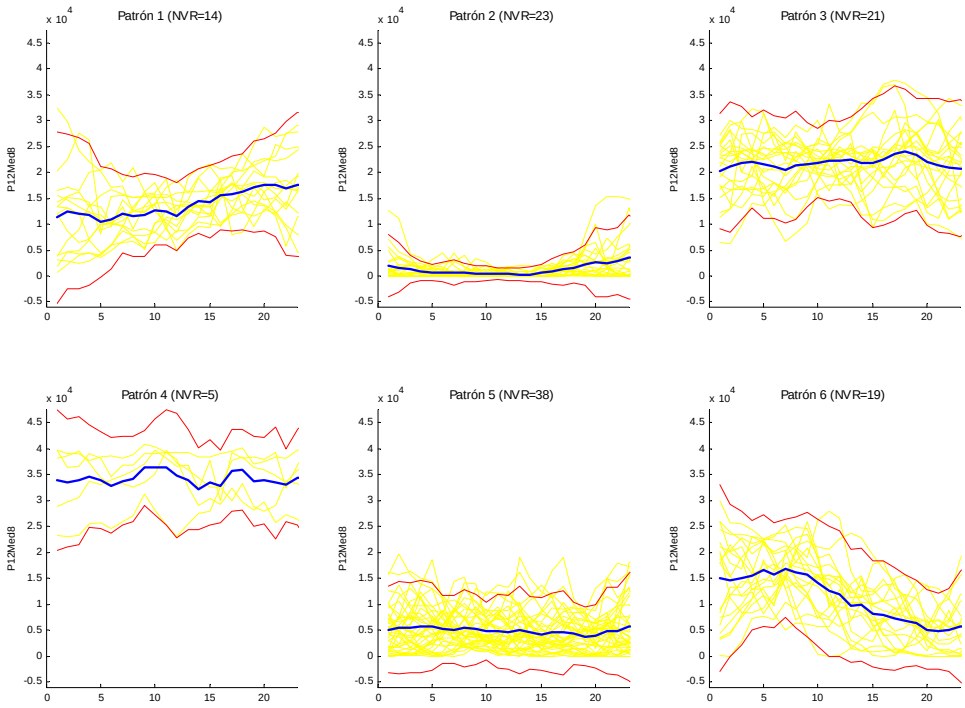


Figura 33: Patrones diarios de producción en P12 (kWh)

A partir de estos patrones diarios de producción se ha realizado una selección de los conjuntos de entrenamiento, test y validación utilizados en el ajuste y posterior validación de los modelos, de tal forma que queden bien representados los distintos comportamientos observados en cada uno de ellos.

El procedimiento utilizado ha consistido en formar cada uno de estos conjuntos seleccionando de cada patrón un porcentaje fijo de perfiles diarios asociados a ese patrón. Los porcentajes utilizados han sido 60% para el conjunto de entrenamiento utilizado para definir la función de error, 15% para el conjunto de test utilizado para monitorizar la capacidad de generalización del modelo durante el entrenamiento y 25% para el conjunto de validación, cuyos datos no han sido utilizados durante el ajuste de los parámetros.

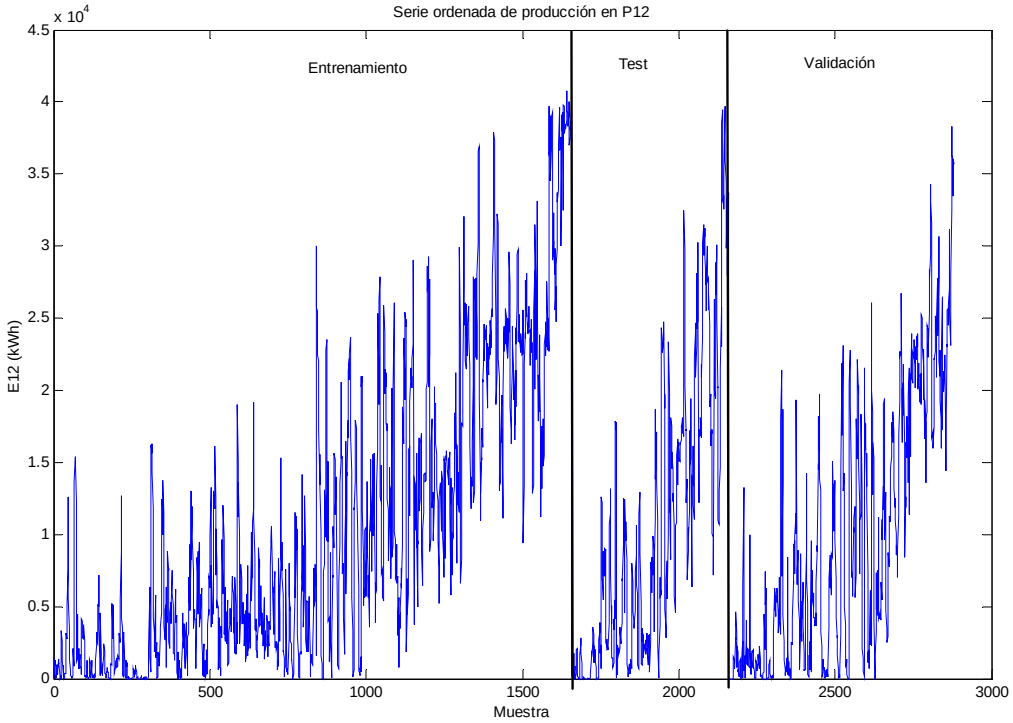


Figura 34: Series de producción en P12 correspondientes a los conjuntos de entrenamiento, test y validación

4.1.2 Predicciones realizadas con el modelo Casandra

En las siguientes figuras se representa los errores absolutos medios cometidos por el modelo Casandra con los dos rangos de horizontes de predicción (1 a 24 y 25 a 48 horas). En ellas puede apreciarse que, al igual que ocurría en P1, la predicción realizada con el horizonte 1 a 24 horas es en promedio siempre más precisa que la realizada con horizonte 25 a 48 horas.

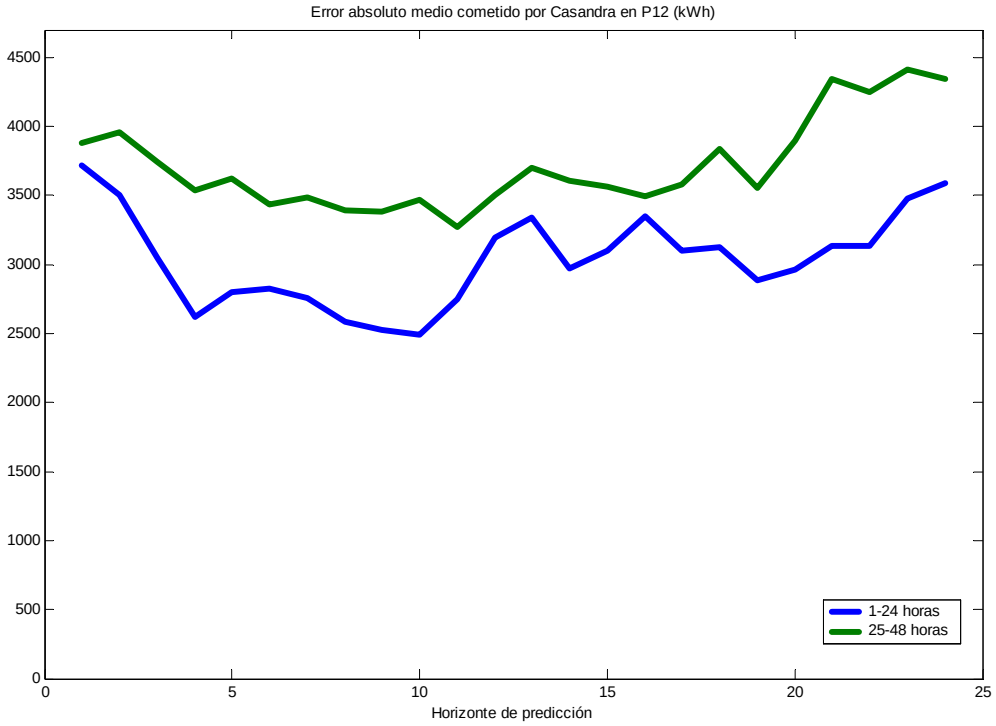


Figura 35: Errores absolutos medios cometidos por Casandra en P12 en función de su horizonte de predicción (kWh)

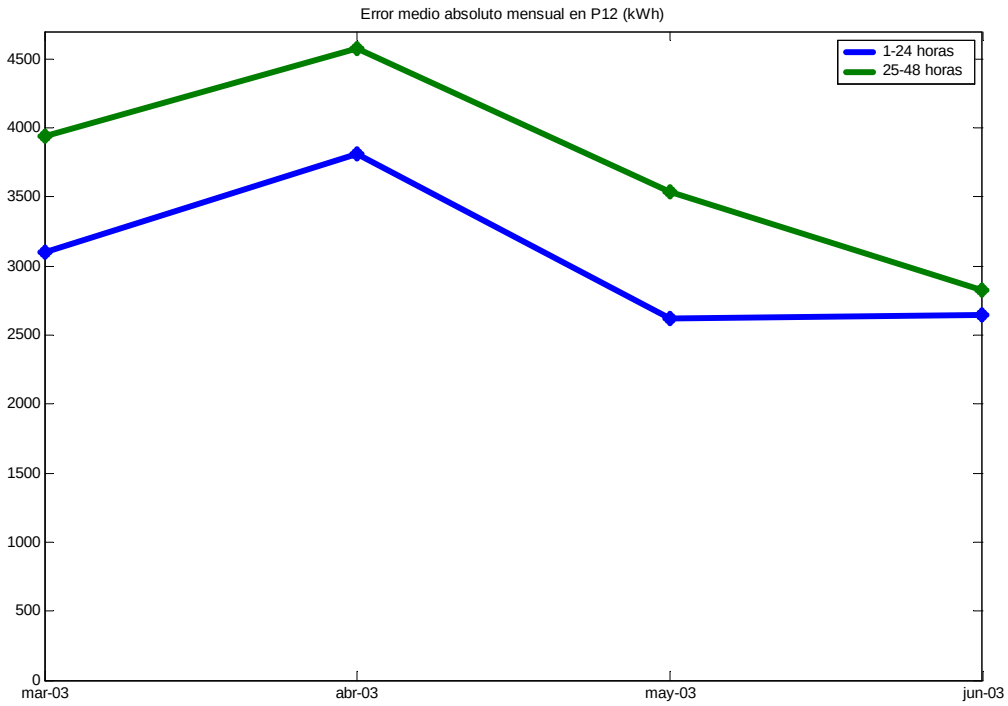


Figura 36: Errores absolutos medios cometidos por Casandra en P12 (kWh)

El análisis de la Figura 37 pone de manifiesto nuevamente que aunque los mayores errores de predicción suelen darse los meses de mayor producción, no existe una correlación perfecta entre nivel de producción y error.

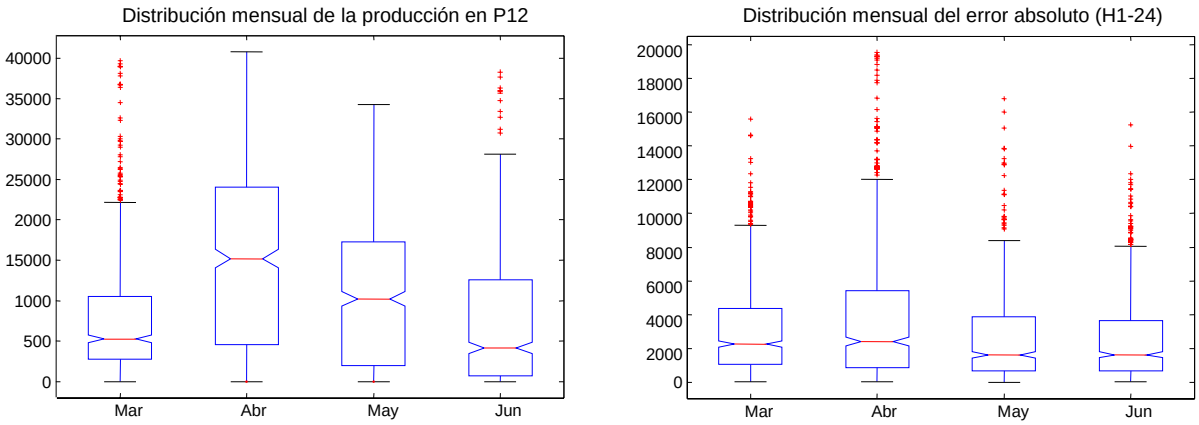


Figura 37: Distribuciones mensuales de las producciones y errores de predicción en P12 (kWh)

Una vez analizadas de forma individual las series de producción por un lado y los errores de predicción por otro, es interesante analizar las relaciones entre estas series para seleccionar el conjunto de variables de entrada del modelo de corto plazo.

En la Figura 38 se muestra la función de autocorrelación simple (FAS) y parcial (FAP) de la serie de producción en P12 ([Box & Jenkins, 1976]). El lento decrecimiento de la FAS pone de manifiesto la no estacionariedad de la serie, por lo que se recurre en la Figura 39 a diferenciar la serie y analizar la serie de incrementos. El análisis de la FAS y FAP de esta nueva serie revela un comportamiento intermedio entre los parques 1 y 2, por lo que su comportamiento sigue siendo similar al de un paseo aleatorio pero con una cierta estructura lineal asociada a los retardos 1 y 2.

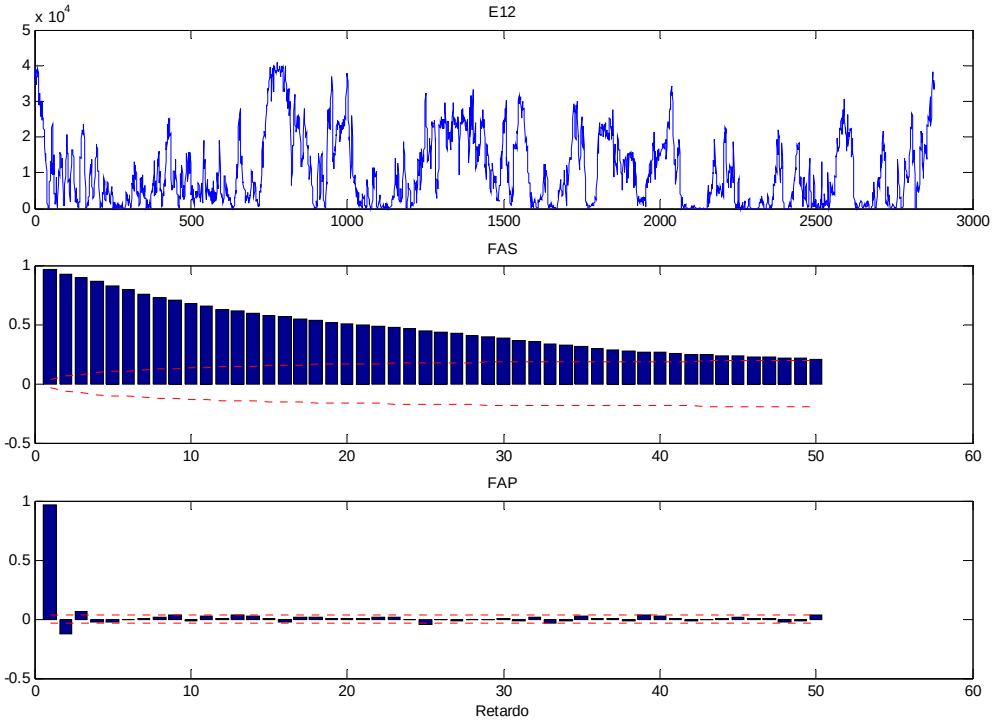


Figura 38: Funciones de Autocorrelación Simple y Parcial de la serie de producción en P12

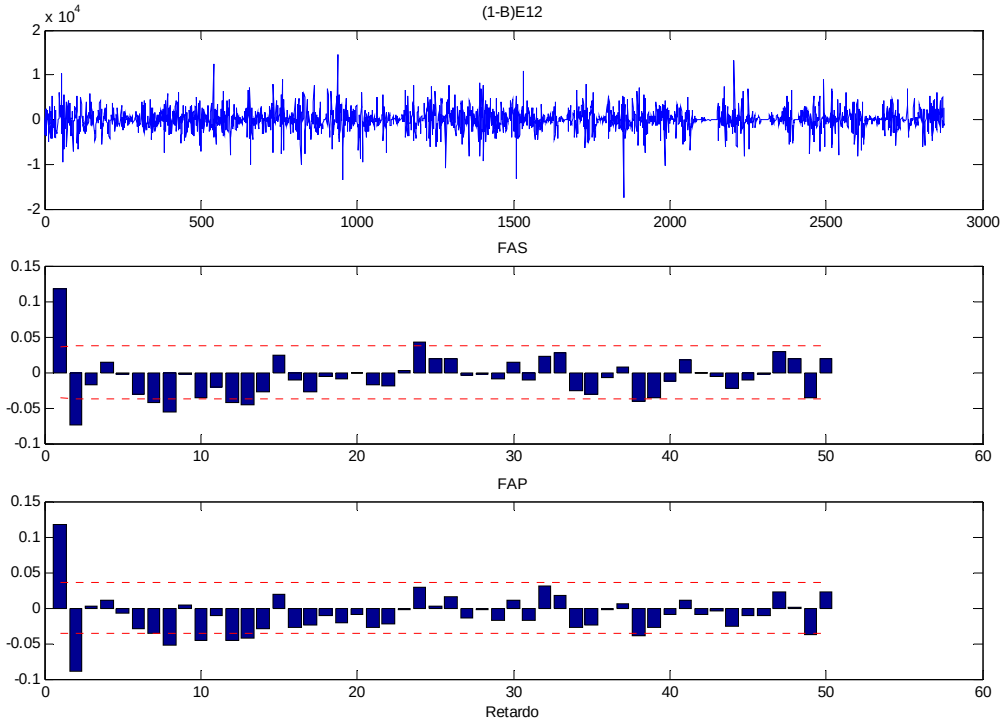


Figura 39: Funciones de Autocorrelación Simple y Parcial de la serie de incrementos de producción en P12

Por otro lado, para determinar los retardos de las series de estimaciones que deberían ser considerados en el vector de regresores de un modelo lineal, se utiliza la función de correlación cruzada entre la serie de producción medida y las estimaciones (ver Figura 40 y Figura 41).

El análisis de la Figura 40 permite concluir que la producción en la hora *h* presenta máxima correlación lineal con la predicción H1 realizada para la hora *h+1*, mientras que en la Figura 41 se pone de manifiesto que las estimaciones de horizonte H2 realizadas para las hora *h+1* y *h+2* están más correladas con la producción que las realizadas para la hora *h*.

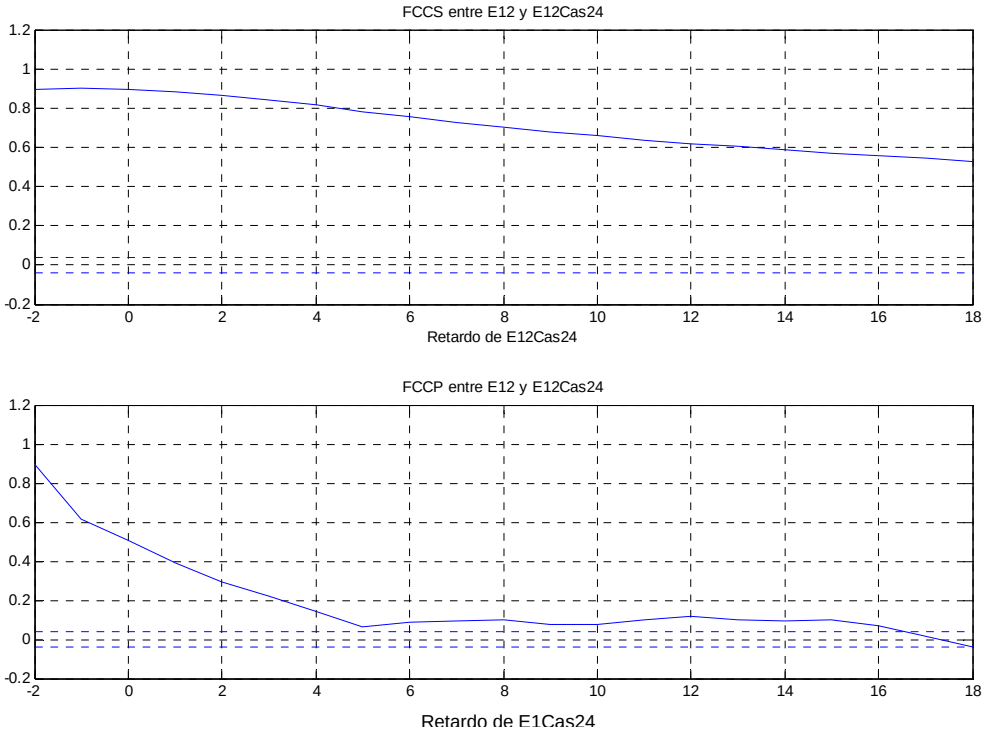


Figura 40: Funciones de correlación cruzada entre la producción en P12 y la estimación con horizonte 1 a 24 horas

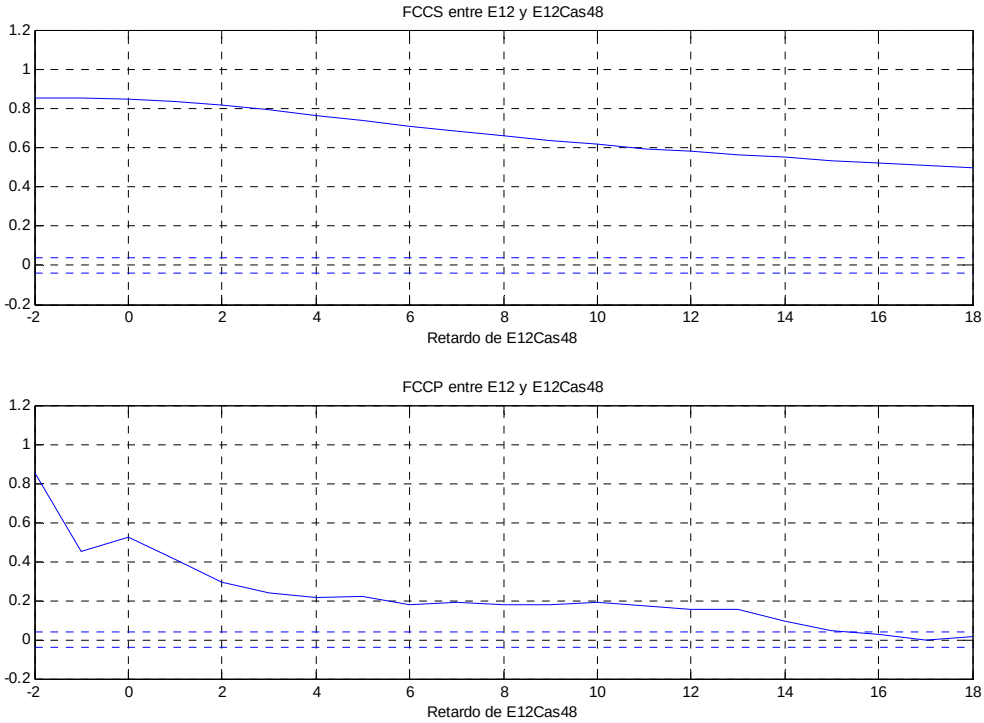


Figura 41: Funciones de correlación cruzada entre la producción en P12 y la estimación con horizonte 25 a 48 horas

4.2 Identificación y ajuste de los modelos de corto plazo

Partiendo de los análisis realizados en el apartado anterior, y optando nuevamente por una solución homogénea para todos los horizontes de predicción, se ha utilizado la siguiente estructura para cada uno de los modelos de corto plazo:

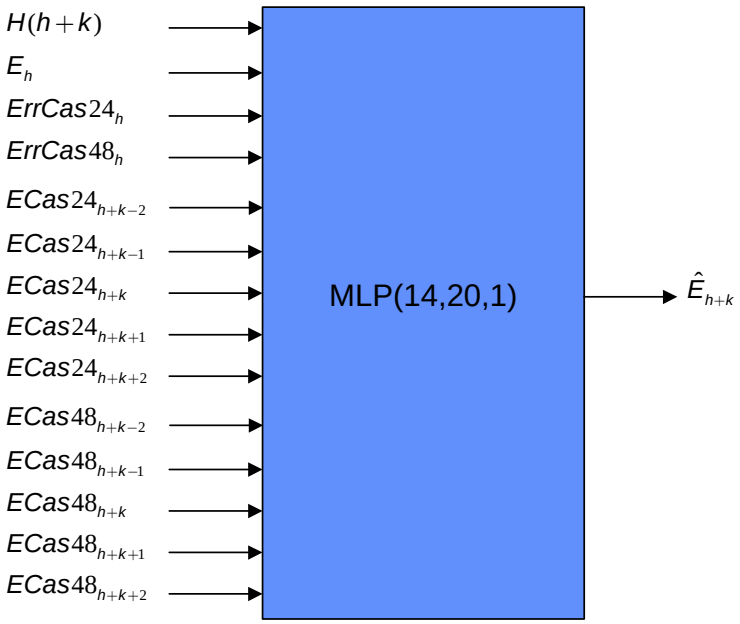


Figura 42: Estructura de los modelos de corto plazo

De esta forma el modelo de horizonte *k* es un perceptrón multicapa con una capa oculta de 20 neuronas con función de activación hiperbólica, una neurona de salida con la misma función de activación[3] y 14 entradas correspondientes a:

- *H(h+k)*: horizonte correspondiente a la predicción de Casandra para la hora *h+k*
- E_h: última medida disponible de la producción del parque
- $ErrCas24_h$ *y* $ErrCas48_h$: últimos errores de predicción cometidos por Casandra con sus dos horizontes de predicción
- *ECas24 y Ecas48*: estimaciones de Casandra para las horas *h+k-2 a h+k+2* con sus dos horizonrtes de predicción

[3] Se ha utilizado una función de activación hiperbólica en la capa de salida, en lugar de una lineal, para facilitar la reproducción de las saturaciones correspondientes a carga nula y máxima.

4.3 Resultados

Para cuantificar los resultados obtenidos con lo modelos de predicción a corto plazo se han utilizado los siguientes índices:

- MAPE: Error absoluto medio porcentual calculado como el cociente entre la media de los valores absolutos de los errores y la media de la producción.
- MEJORA: porcentaje de mejora del error absoluto medio respecto a las estimaciones obtenidas con el modelo Casandra con horizonte 1 a 24 horas.

A continuación se muestran los resultados obtenidos con el modelo propuesto (MLP), el modelo Casandra con horizonte 1 a 24 horas (Cas24), el modelo Casandra con horizonte 25 a 48 horas (Cas48) y el modelo ingenuo, correspondiente a dar como estimación la última medida de producción disponible, utilizando como banco de pruebas el conjunto completo de datos y el conjunto de validación. Se ha incluido, además de los horizontes de 5 a 8 horas, el horizonte de predicción de 1 hora.

HORIZONTE	1	5	6	7	8	Promedio 1 a 5
MAPE(Cas24)	29%	29.2%	29.2%	29.1%	29.1%	**29.2%**
MAPE(Cas48)	35.6%	35.6%	35.6%	35.6%	35.6%	**35.6%**
MAPE(MLP)	15.8%	24.3%	25.0%	25.8%	25.4%	**25.2%**
MAPE(Ingenuo)	15.7%	38.2%	42.1%	45.6%	48.7%	**43.6%**
MEJORA(Cas48)	-22.0%	-22.1%	-22.2%	-22.2%	-22.3%	**-22.2%**
MEJORA(MLP)	46.0%	16.6%	14.2%	11.5%	12.7%	**13.7%**
MEJORA(Ingenuo)	46.3%	-30.8%	-44.4%	-56.4%	-67.2%	**-49.7%**

Tabla 5: Resultados obtenidos sobre el conjunto completo en P12

HORIZONTE	1	5	6	7	8	Promedio 1 a 5
MAPE(Cas24)	29.1%	28.6%	28.4%	28.2%	27.9%	**28.3%**
MAPE(Cas48)	31.1%	30.4%	30.4%	30.3%	30.0%	**30.3%**
MAPE(MLP)	16.3%	24.6%	26.2%	25.7%	26.4%	**25.7%**
MAPE(Ingenuo)	16.0%	39.2%	43.6%	47.5%	50.8%	**45.3%**
MEJORA(Cas48)	-7.1%	-6.3%	-7.0%	-7.7%	-7.5%	**-7.1%**
MEJORA(MLP)	43.9%	13.9%	7.9%	8.8%	5.5%	**9.0%**
MEJORA(Ingenuo)	44.8%	-37.1%	-53.3%	-68.9%	-82.0%	**-60.3%**

Tabla 6: Resultados obtenidos sobre el conjunto de validación en P12

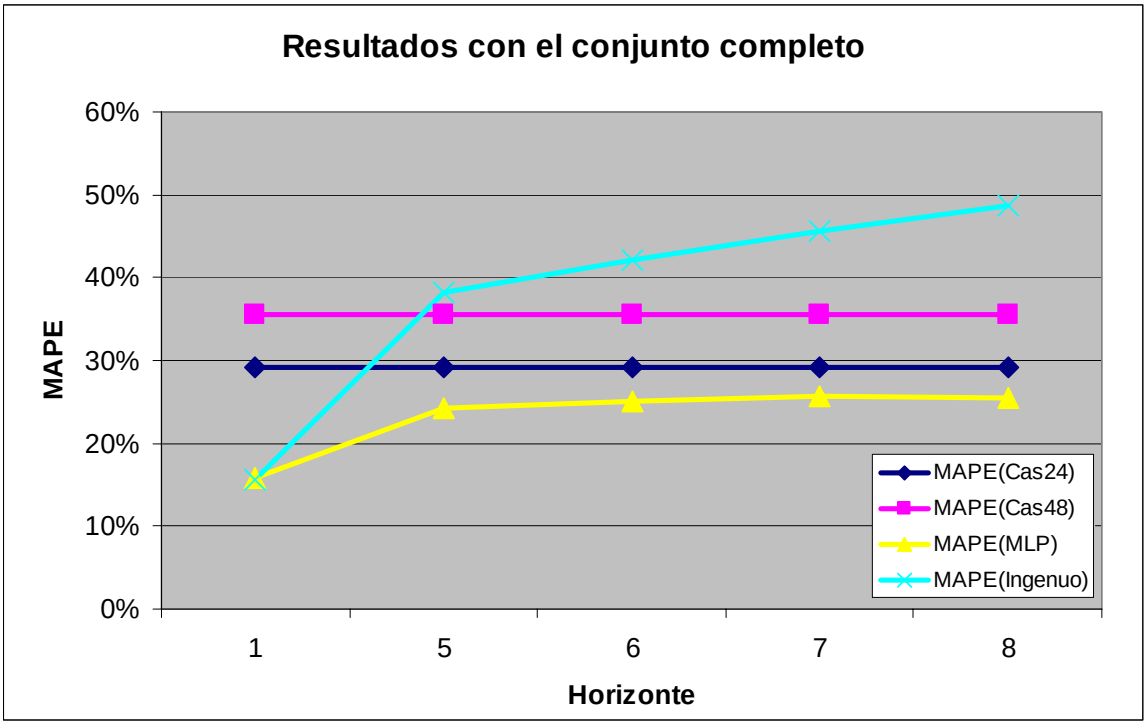


Figura 43: Niveles de error obtenidos sobre el conjunto completo en P12

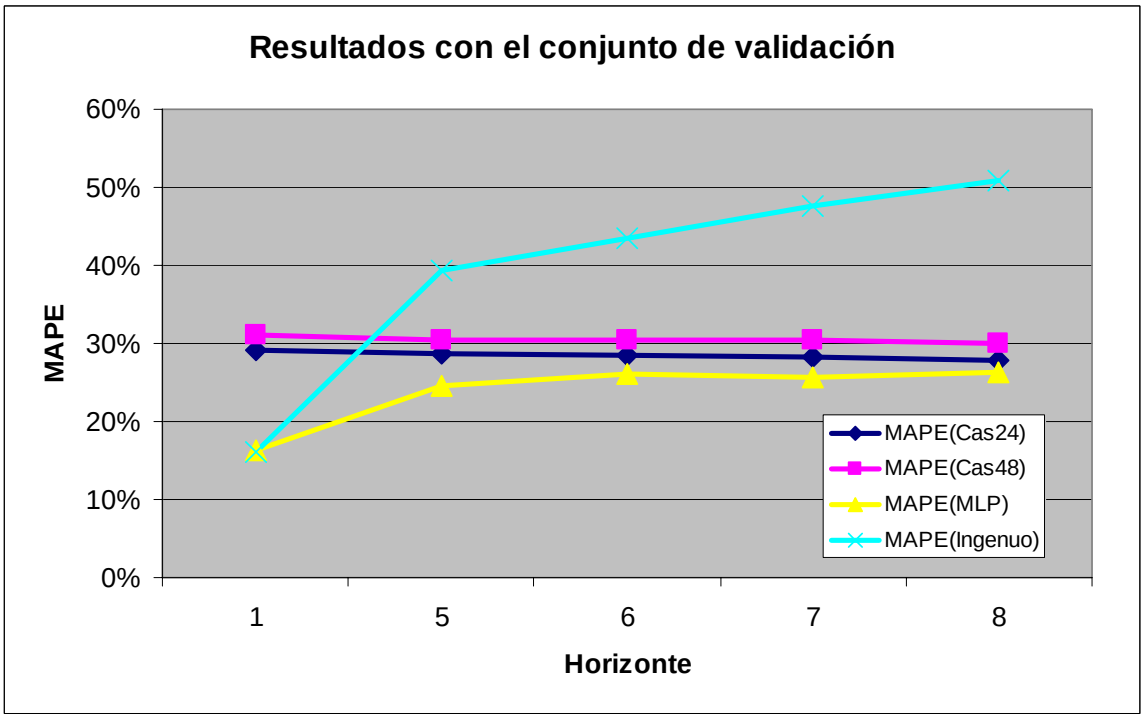


Figura 44: Niveles de error obtenidos sobre el conjunto de validación en P12

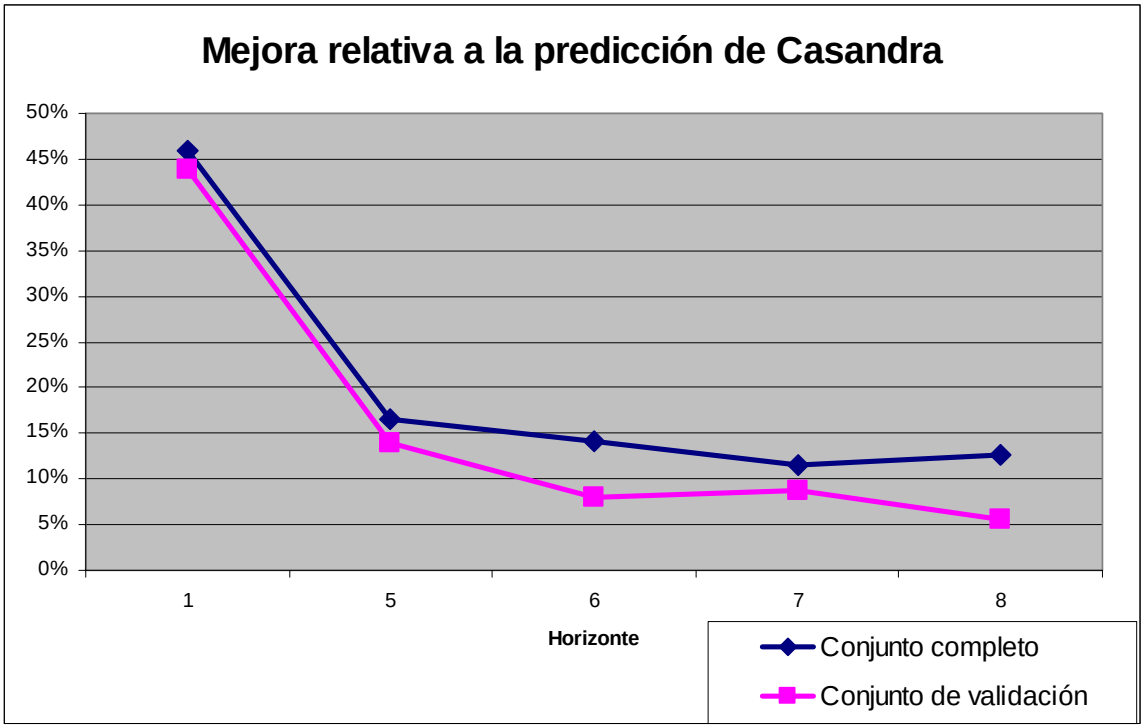


Figura 45: Mejoras relativas al modelo Casandra en P12

Los niveles de error alcanzados por los modelos de corto plazo en la agregación de los dos parques son inferiores incluso a los niveles obtenidos con el parque 1. Sin embargo la mejora de las predicciones de Casandra es menos significativa en este caso que en los anteriores, debido a la fuerte reducción de los errores del modelo Casandra que se produce al agregar ambos parques.

Como conclusión puede establecerse que el modelo MLP **presenta un error absoluto medio del 25.7%** en el horizonte de interés para los mercados intradiarios, lo que supone una **reducción media del 9.0%** del error cometido por el modelo Casandra.

En el apéndice se ha incluido el análsis de los residuos de estos modelos.

5 Bibliografía

[Box & Jenkins, 1976] "Time series analysis: forecasting and control"
George E.P. Box, Gwilym M. Jenkins
Holden-Day Inc., CA, (Revised Edition) 1976

[Haykin, 1994] "Neural Networks, A Comprehensive Foundation"
S. Haykin
Macmillan College Publishing Company, Inc., IEEE Press, 1994

[Ljung & Sjöberg, 1992] "A system identification perspective on neural nets"
L. Ljung, J. Sjöberg
1992 IEEE Workshop on Neural Networks for Signal Processing. IEEE Service Center, 445 Hoes Lane, Piscataway, NJ 08854-4150. 1992

[Muñoz, 1996] "Aplicación de técnicas de redes neuronales artificiales al diagnóstico de procesos industriales"
Antonio Muñoz
Tesis Doctoral. Escuela Técnica Superior de Ingenieros Industriales Universidad Pontificia Comillas. Madrid 1996

[Muñoz, 1998] "Variable selection using feedforward and recurrent neural nets"
Antonio Muñoz San Roque, Thomas Czernichow
International Journal of Engineering Intelligent Systems. Vol 2, p. 91-102, 1998

[RD 436/2004] "Real Decreto 436/2004 de 12 de marzo, por el que se establece la metodología para la actualización y sistematización del régimen jurídico y económico de la actividad de producción de energía eléctrica en régimen especial"
Ministerio de Economía.

[Sjöberg, 1995] "Non-Linear System Identification with Neural Networks"
Jonas Sjöberg
Ph. D. Thesis, Linköping University, Sweden, 1995

[Vapnik, 1992] "Principles of risk minimization for learning theory"
V.N. Vapnik
Advances in Neural Information Processing Systems 4
p.831-838. San Mateo, CA:Morgan Kaufmann, 1992

[Weigend & Gershenfeld , 1994] "Time Series Prediction: Forecasting the Future and Understanding the Past"
A. S. Weigend, N.A. Gershenfeld
MA: Addison-Wesley, 1994.

6 Apéndice

6.1 Detalle de los modelos del Parque 1

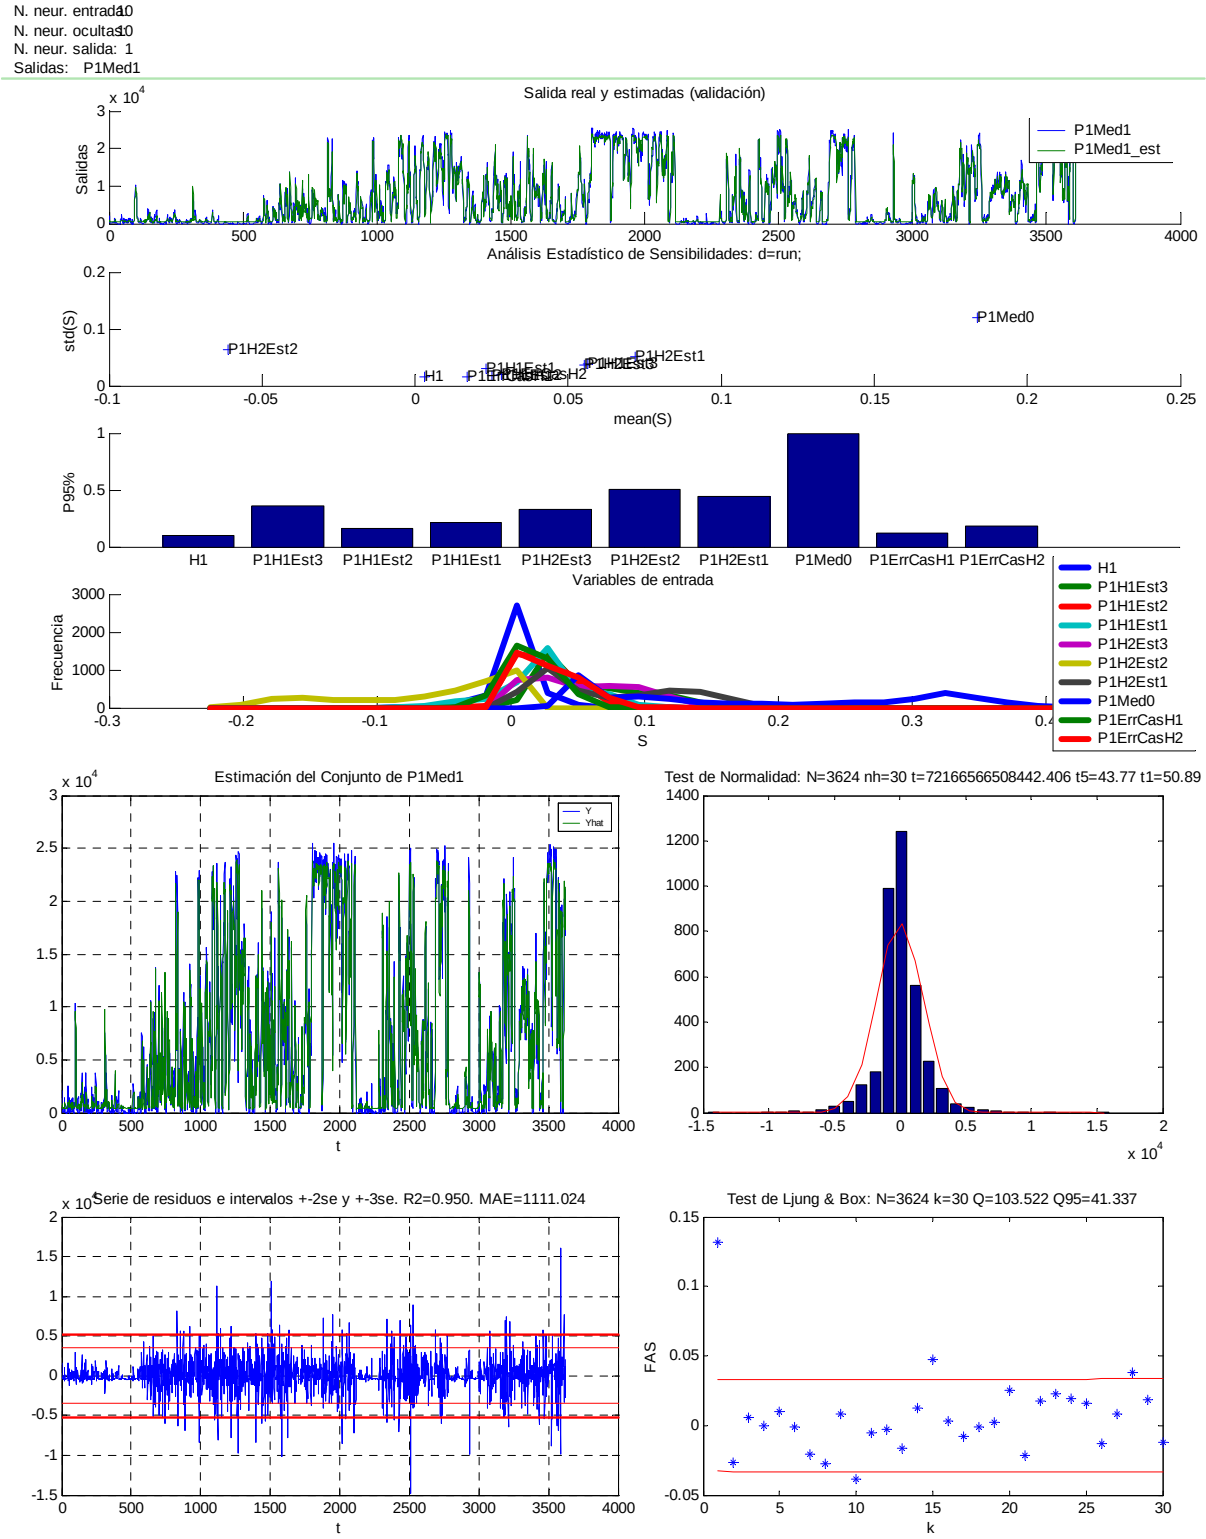


Figura 46: Detalle del modelo de E1 con horizonte de 1 hora

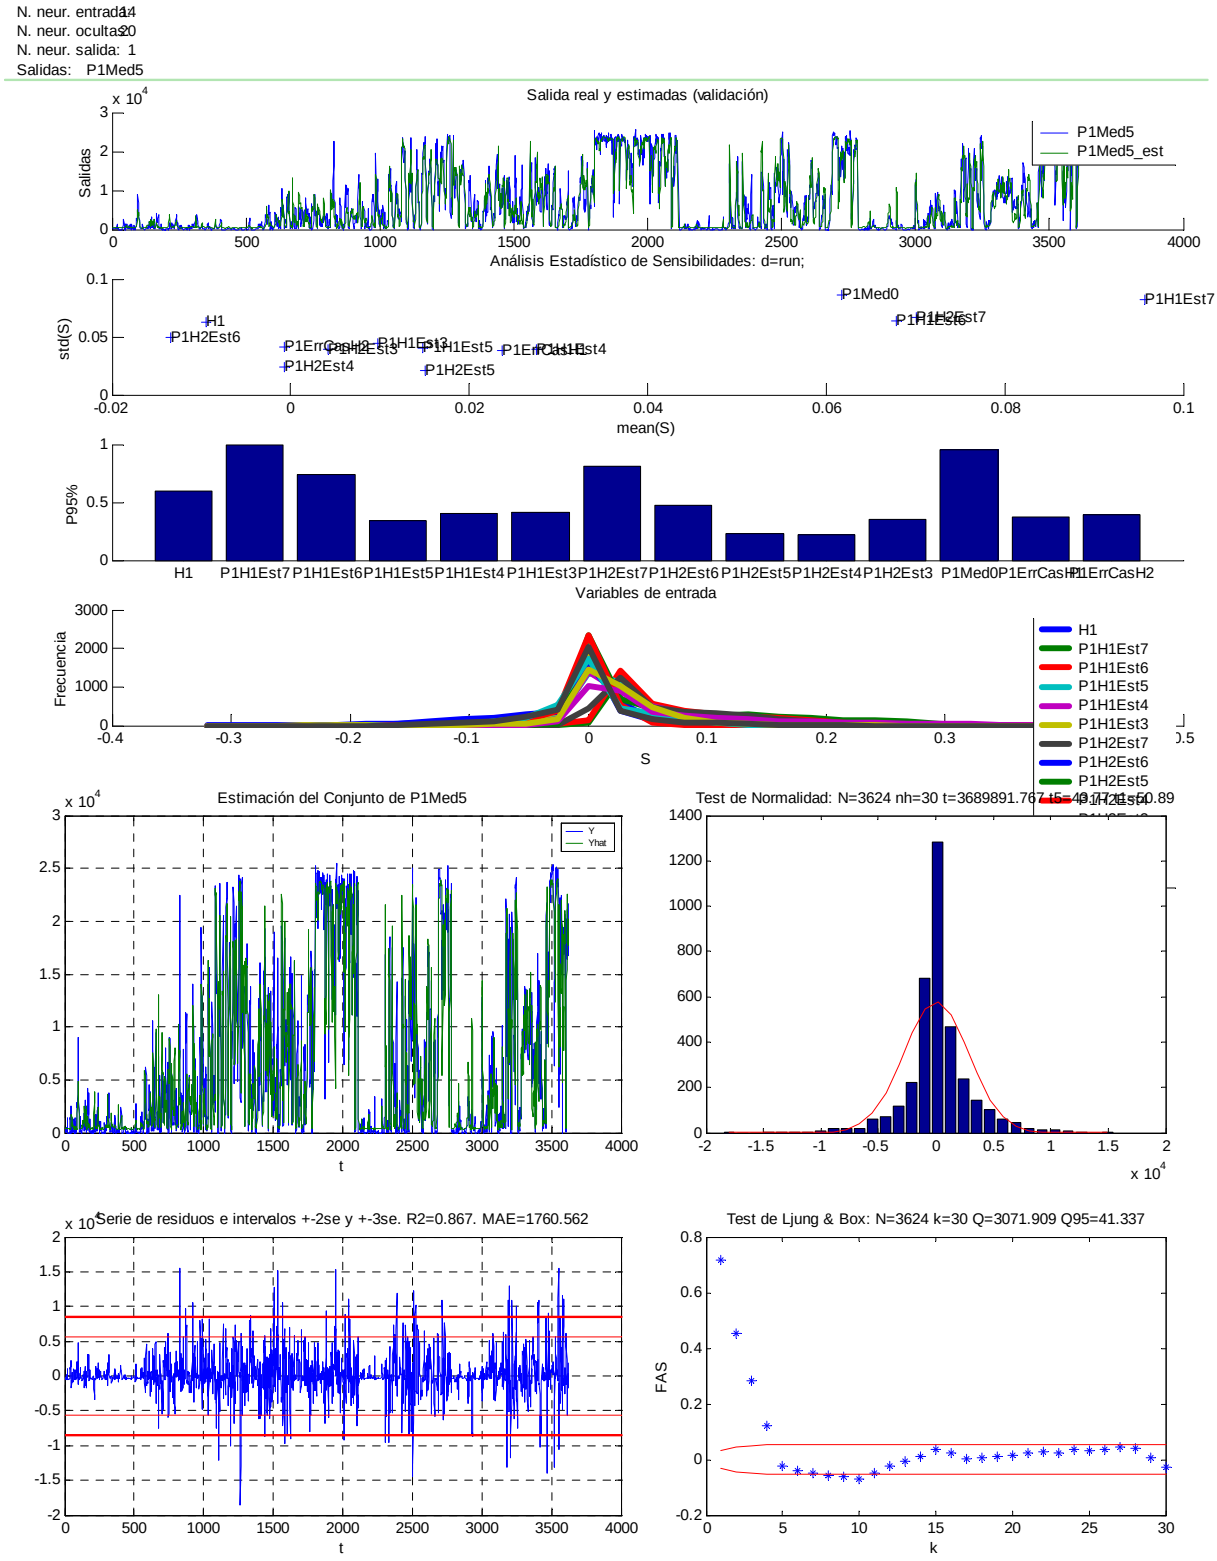


Figura 47: Detalle del modelo de E1 con horizonte de 5 horas

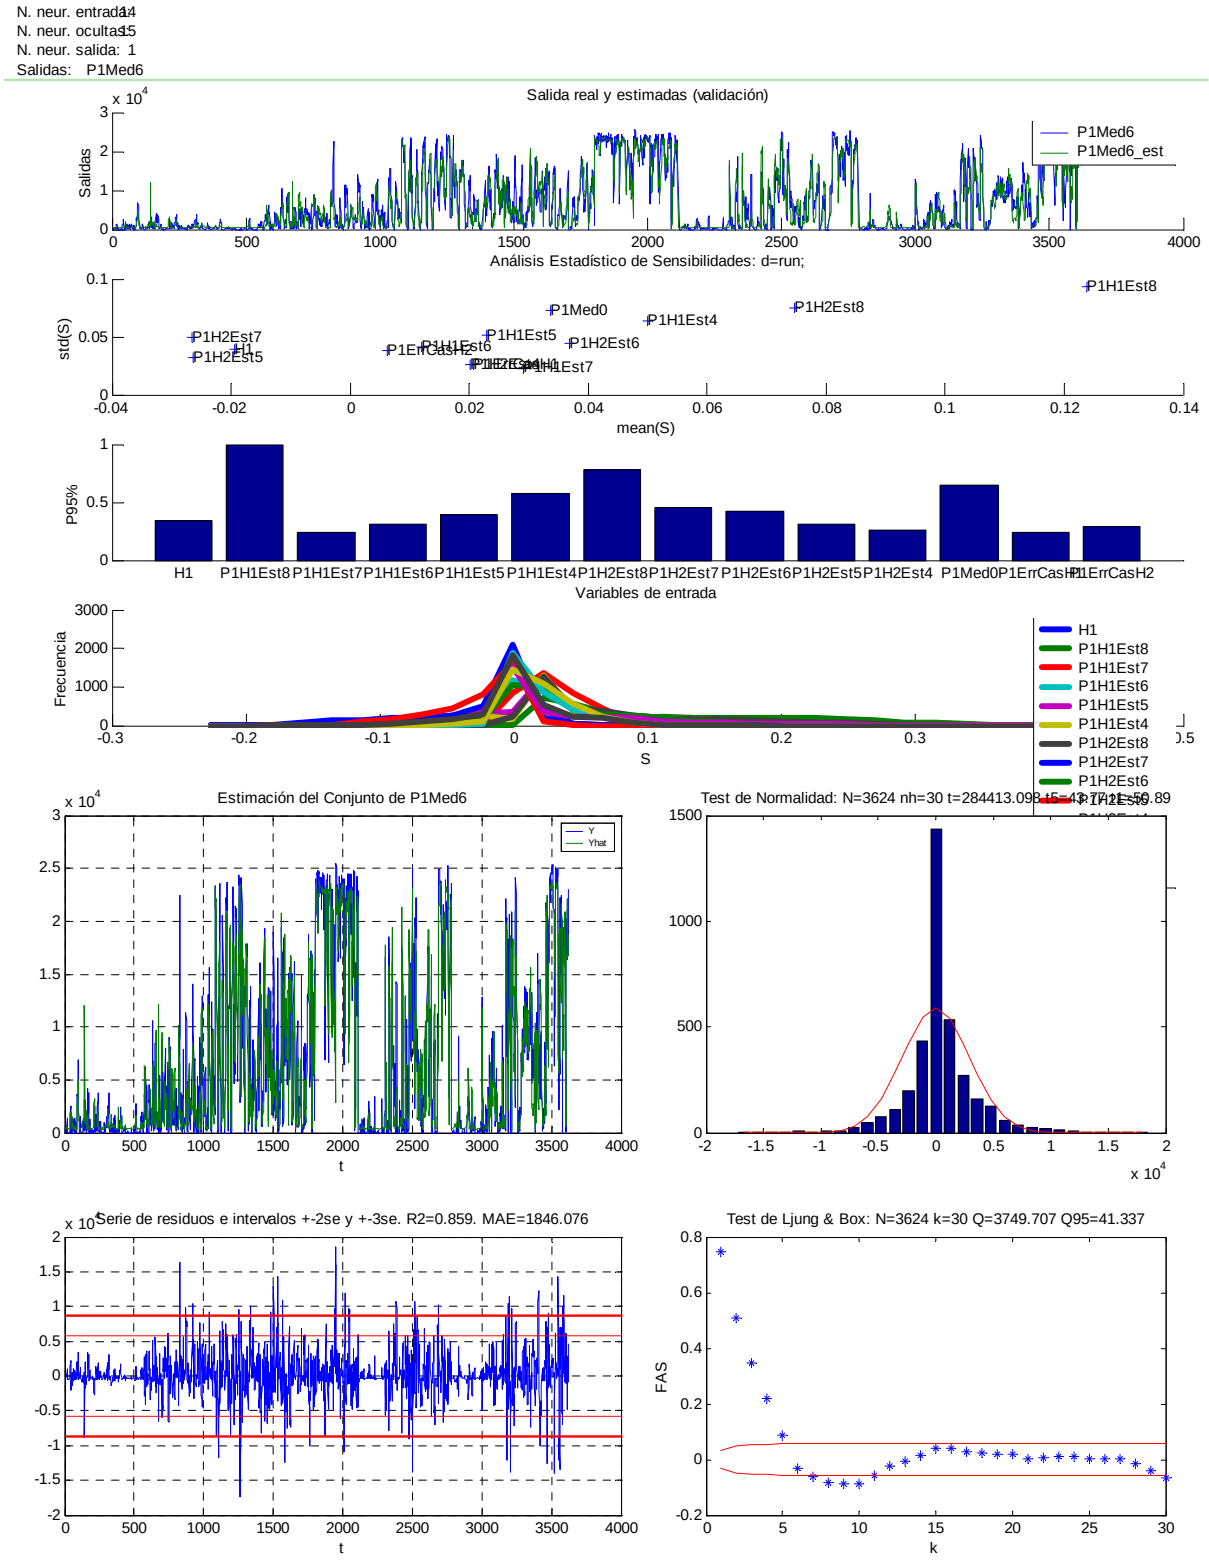


Figura 48: Detalle del modelo de E1 con horizonte de 6 horas

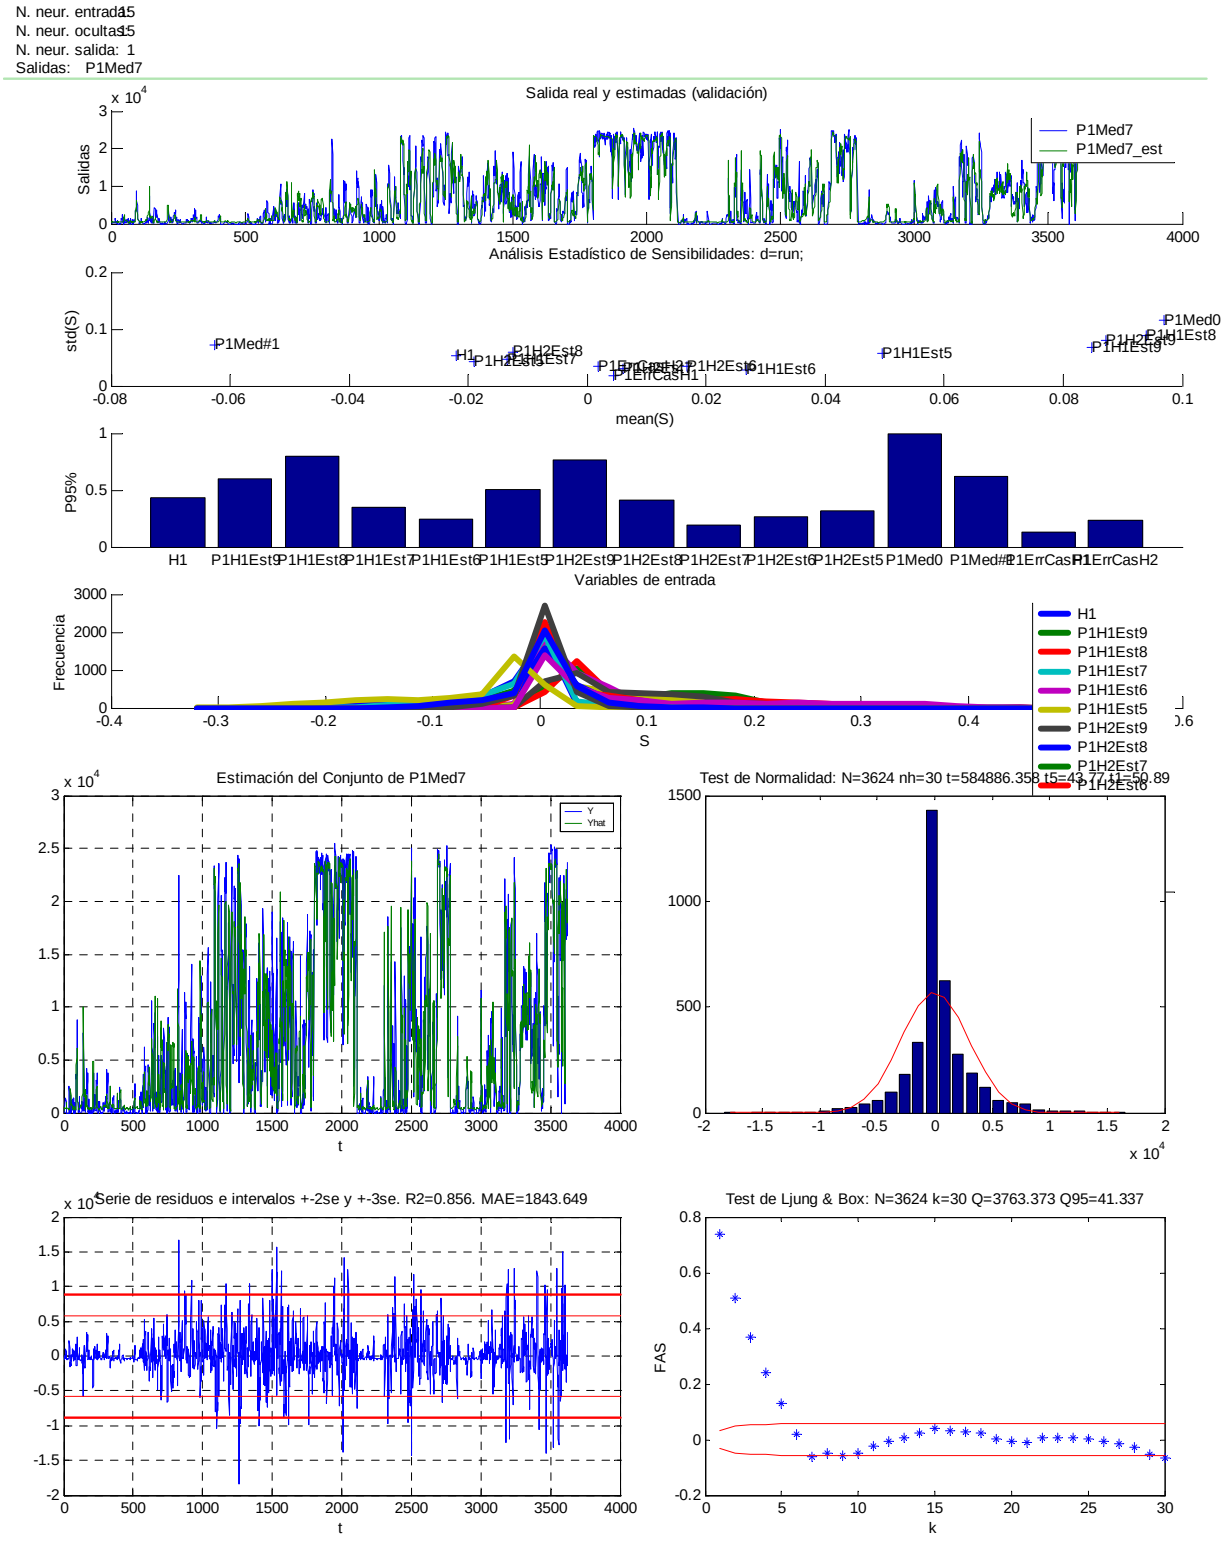


Figura 49: Detalle del modelo de E1 con horizonte de 7 horas

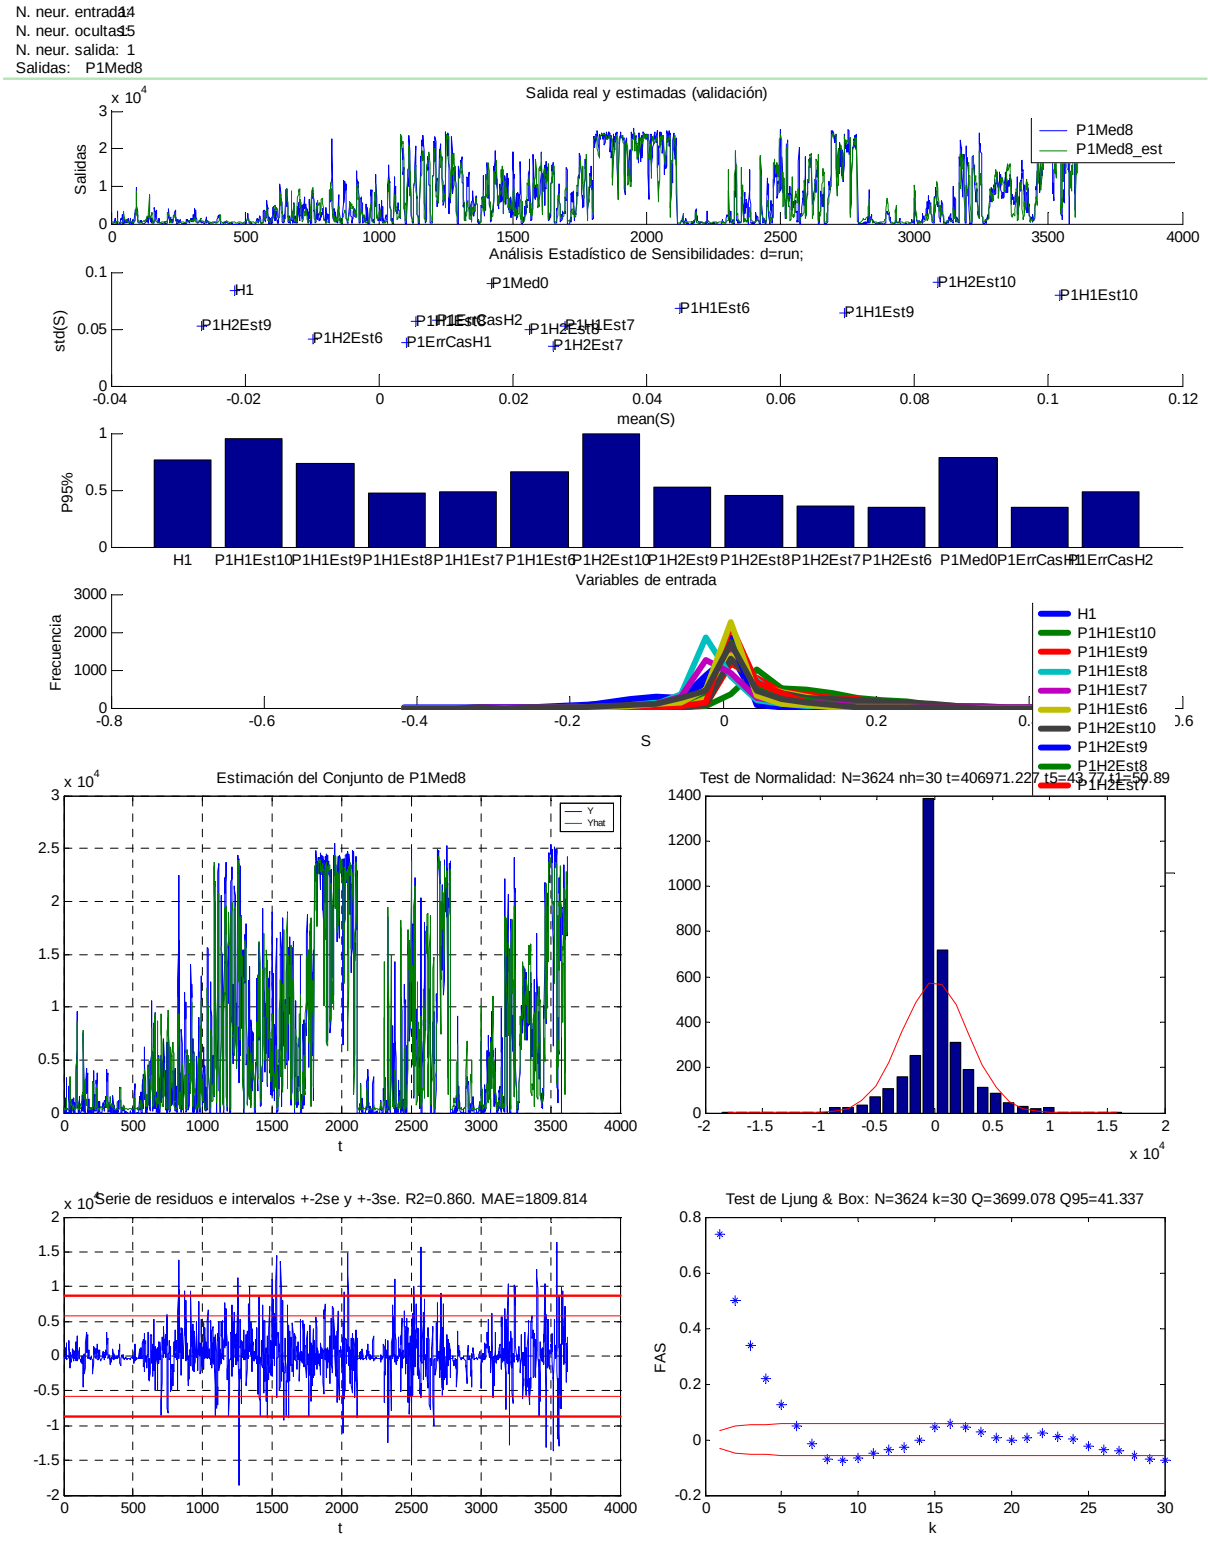


Figura 50: Detalle del modelo de E1 con horizonte de 8 horas

6.2 Detalle de los modelos del Parque 2

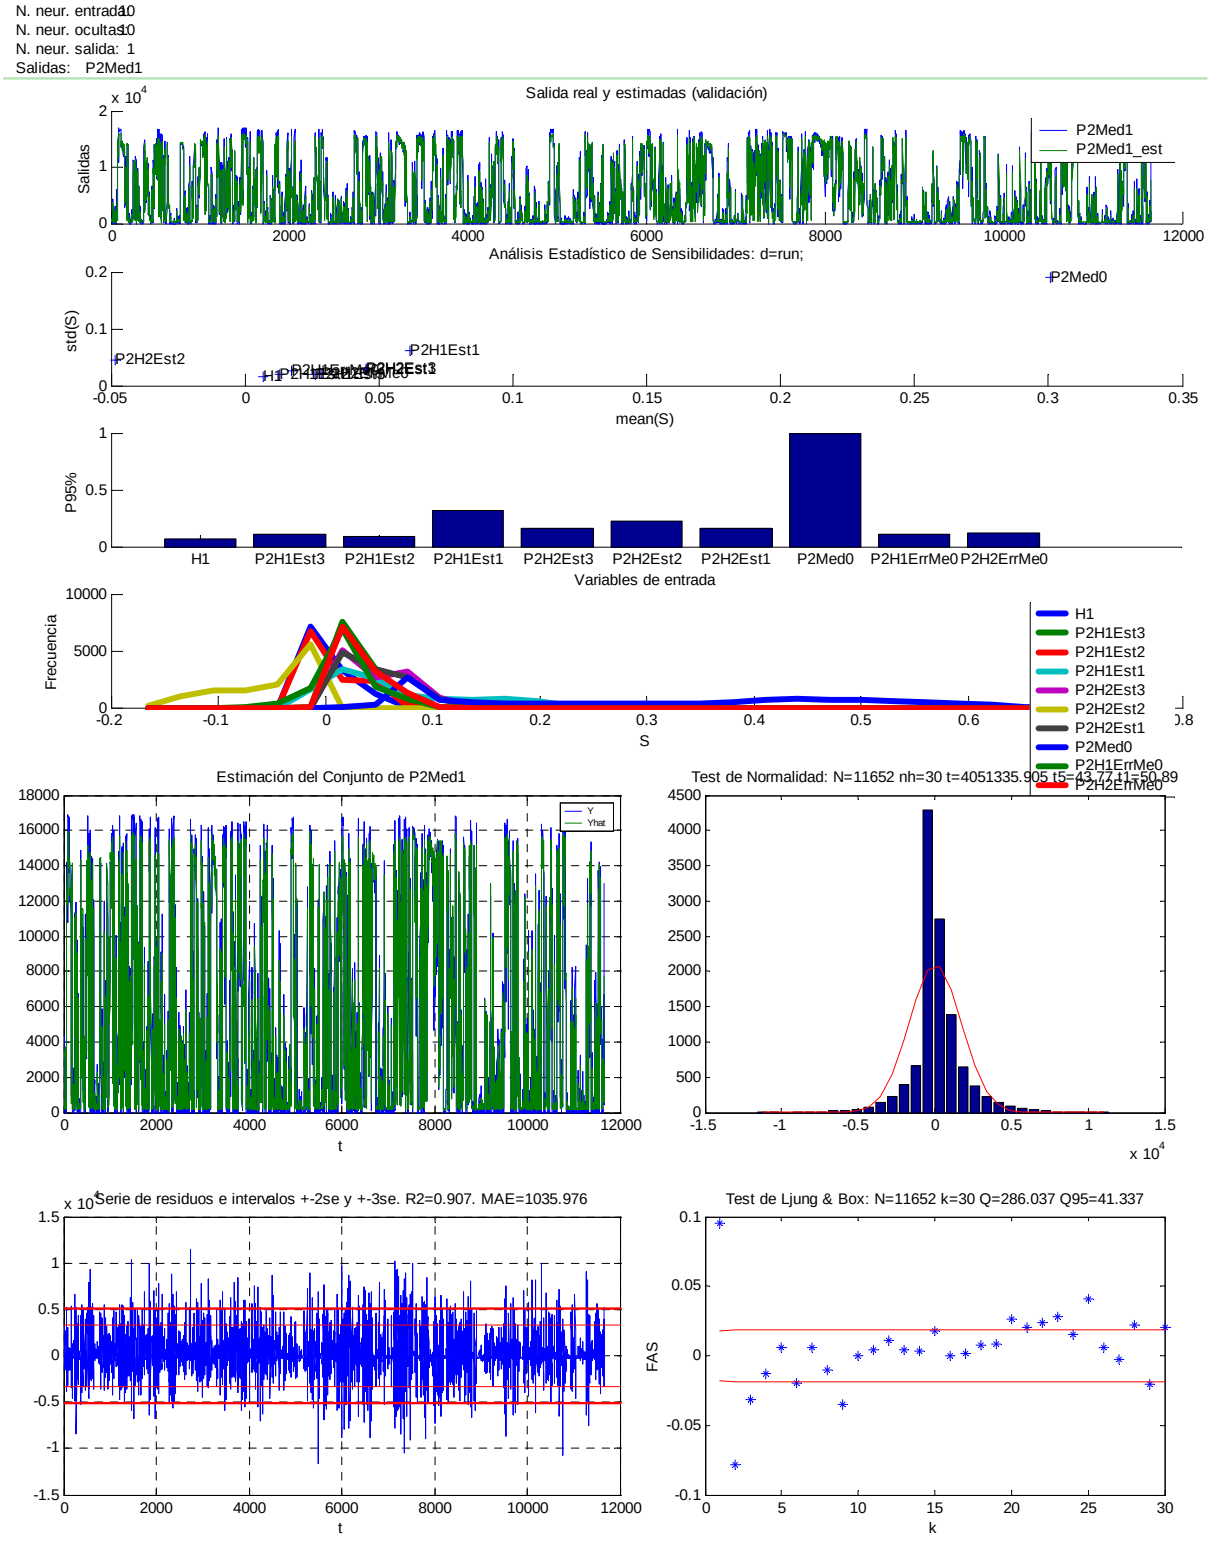


Figura 51: Detalle del modelo de E2 con horizonte de 1 hora

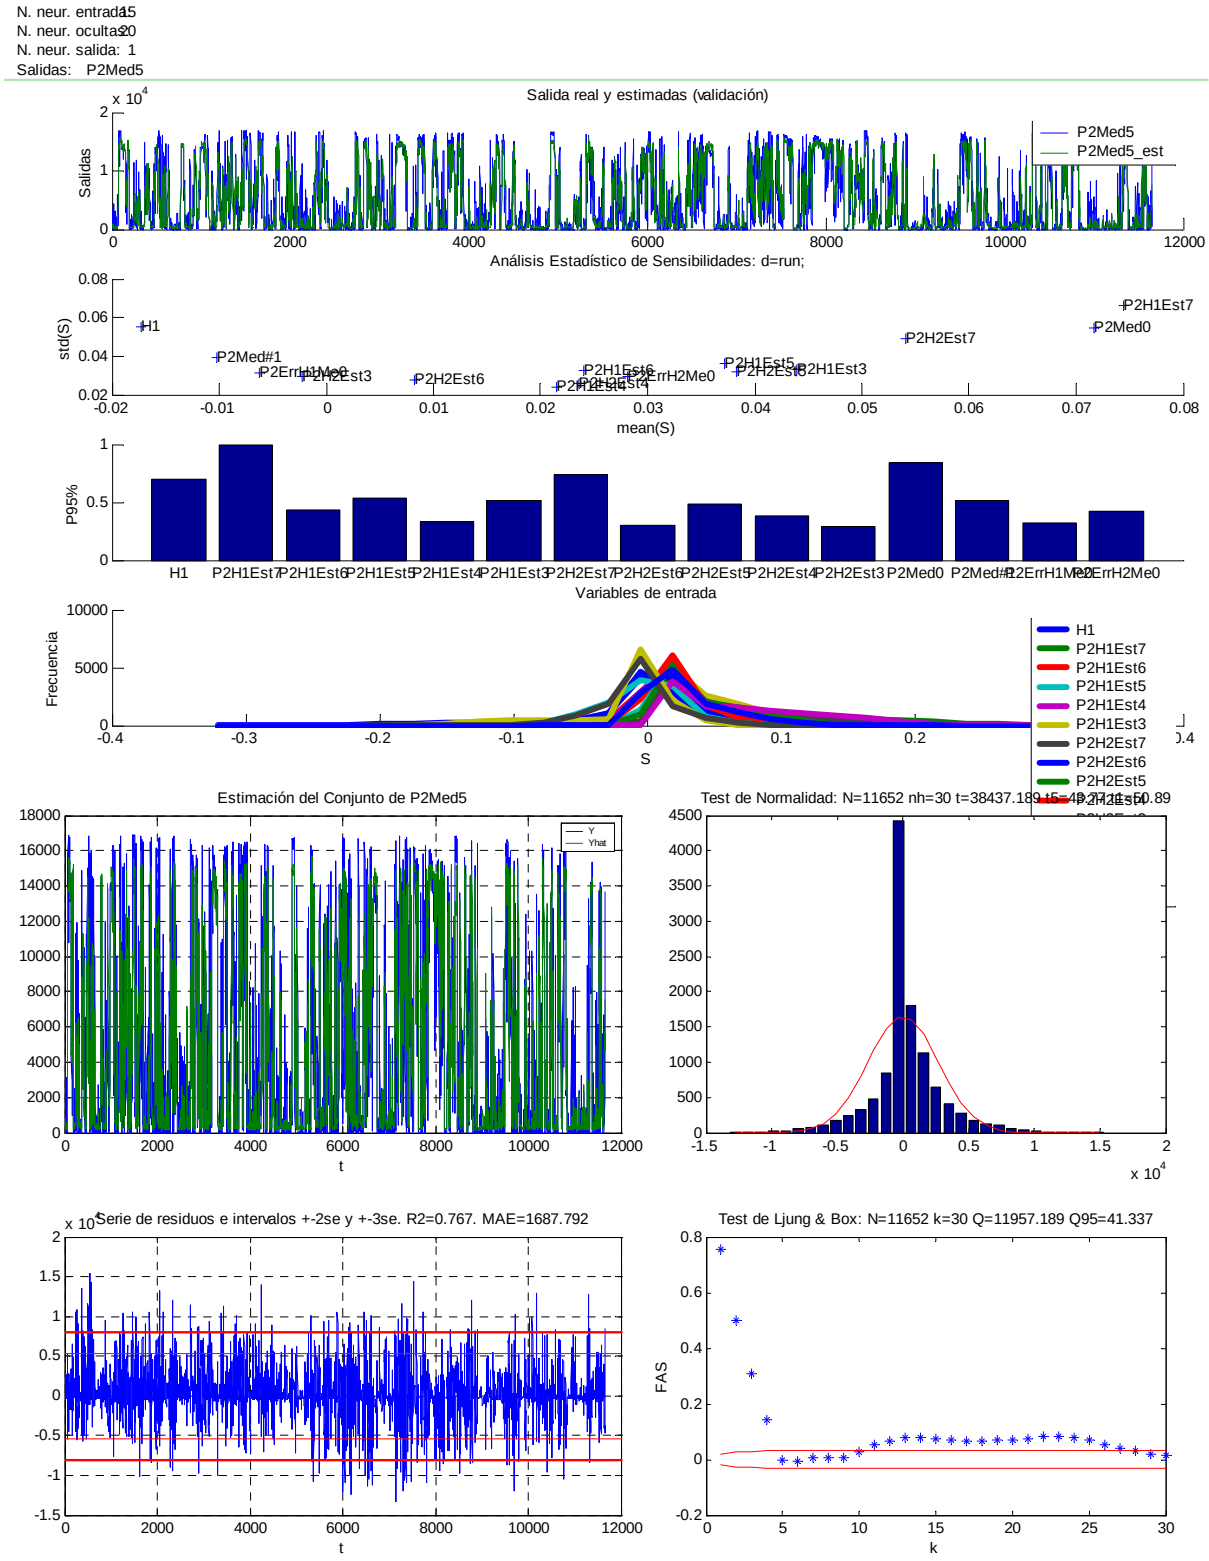


Figura 52: Detalle del modelo de E2 con horizonte de 5 horas

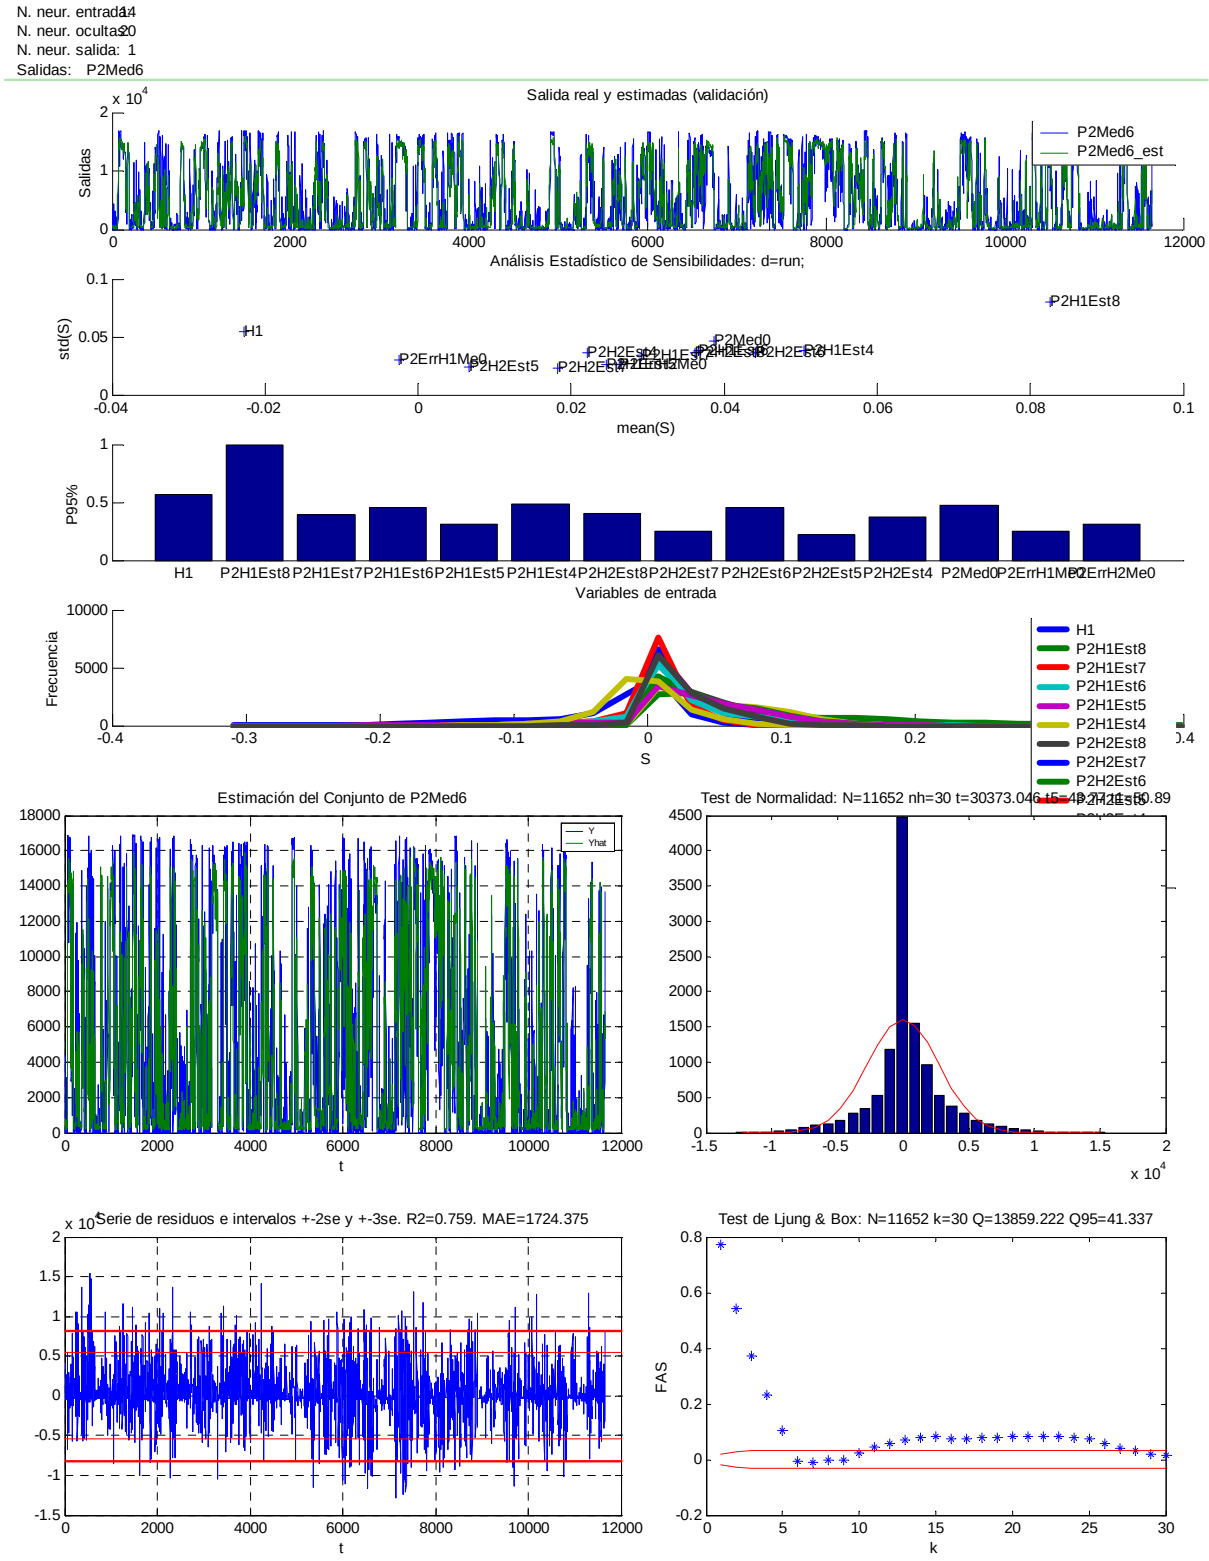


Figura 53: Detalle del modelo de E2 con horizonte de 6 horas

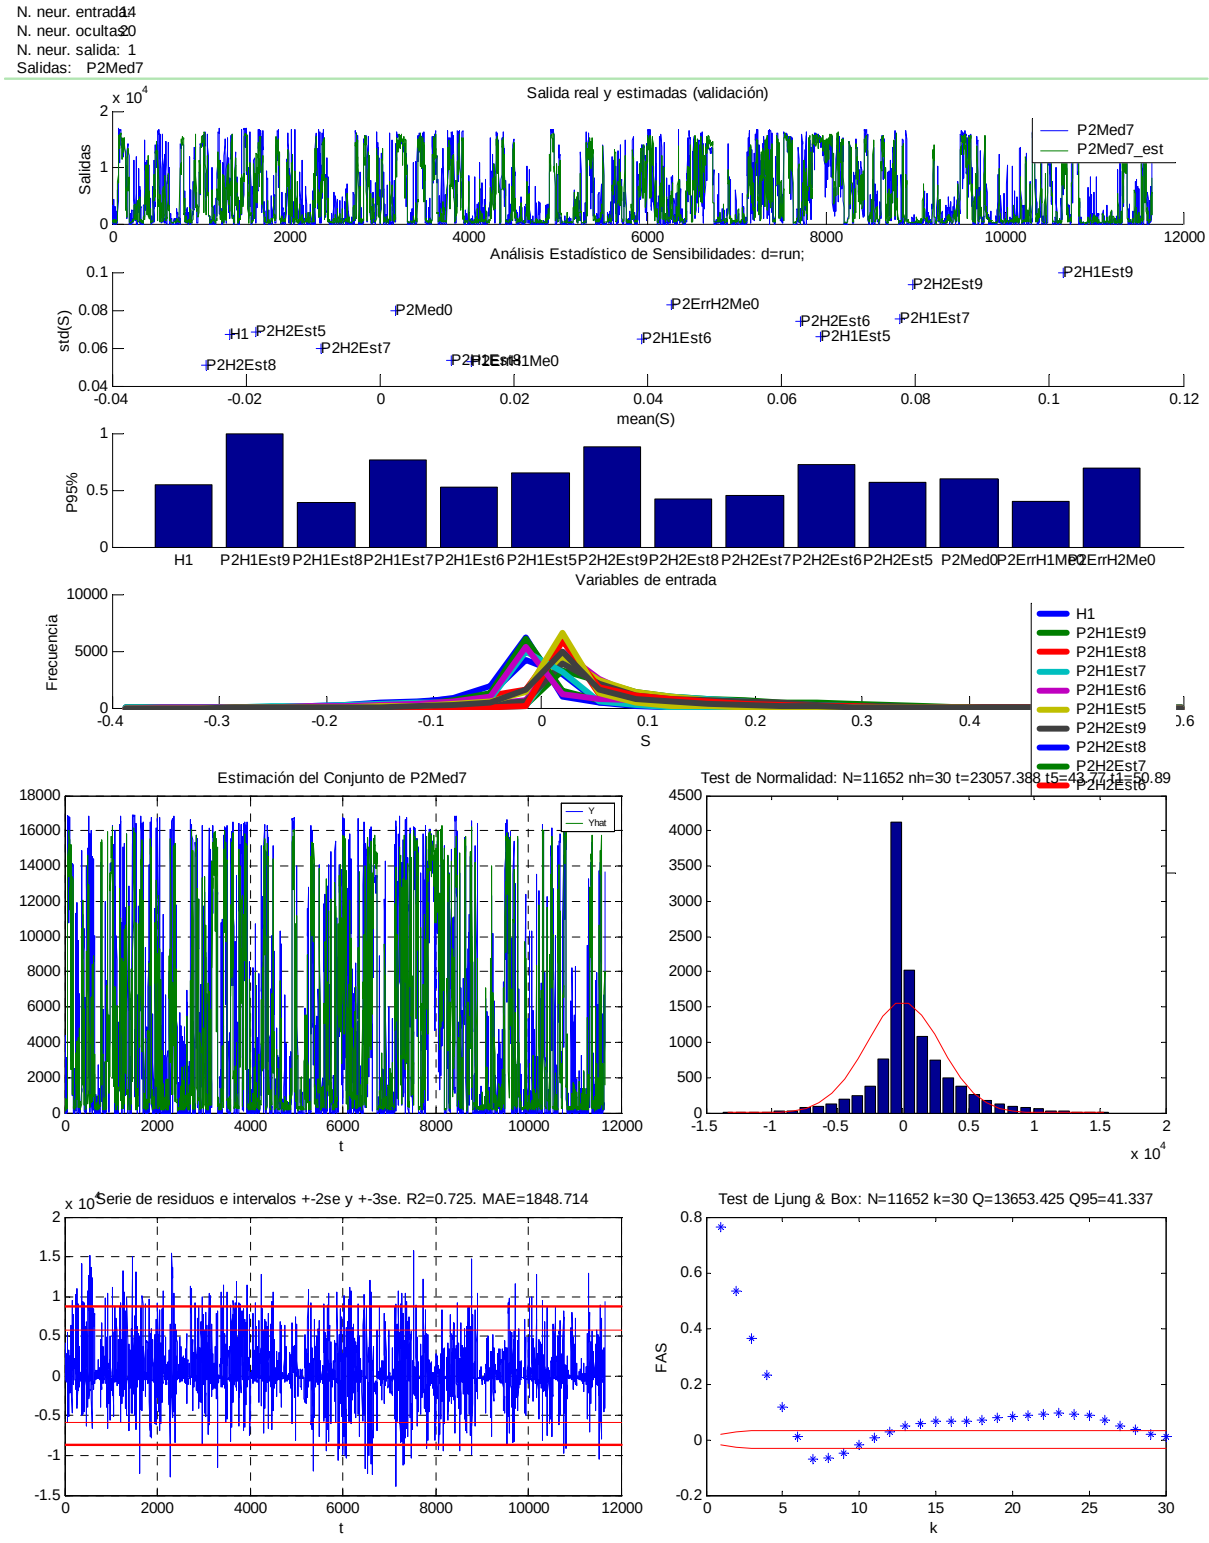


Figura 54: Detalle del modelo de E2 con horizonte de 7 horas

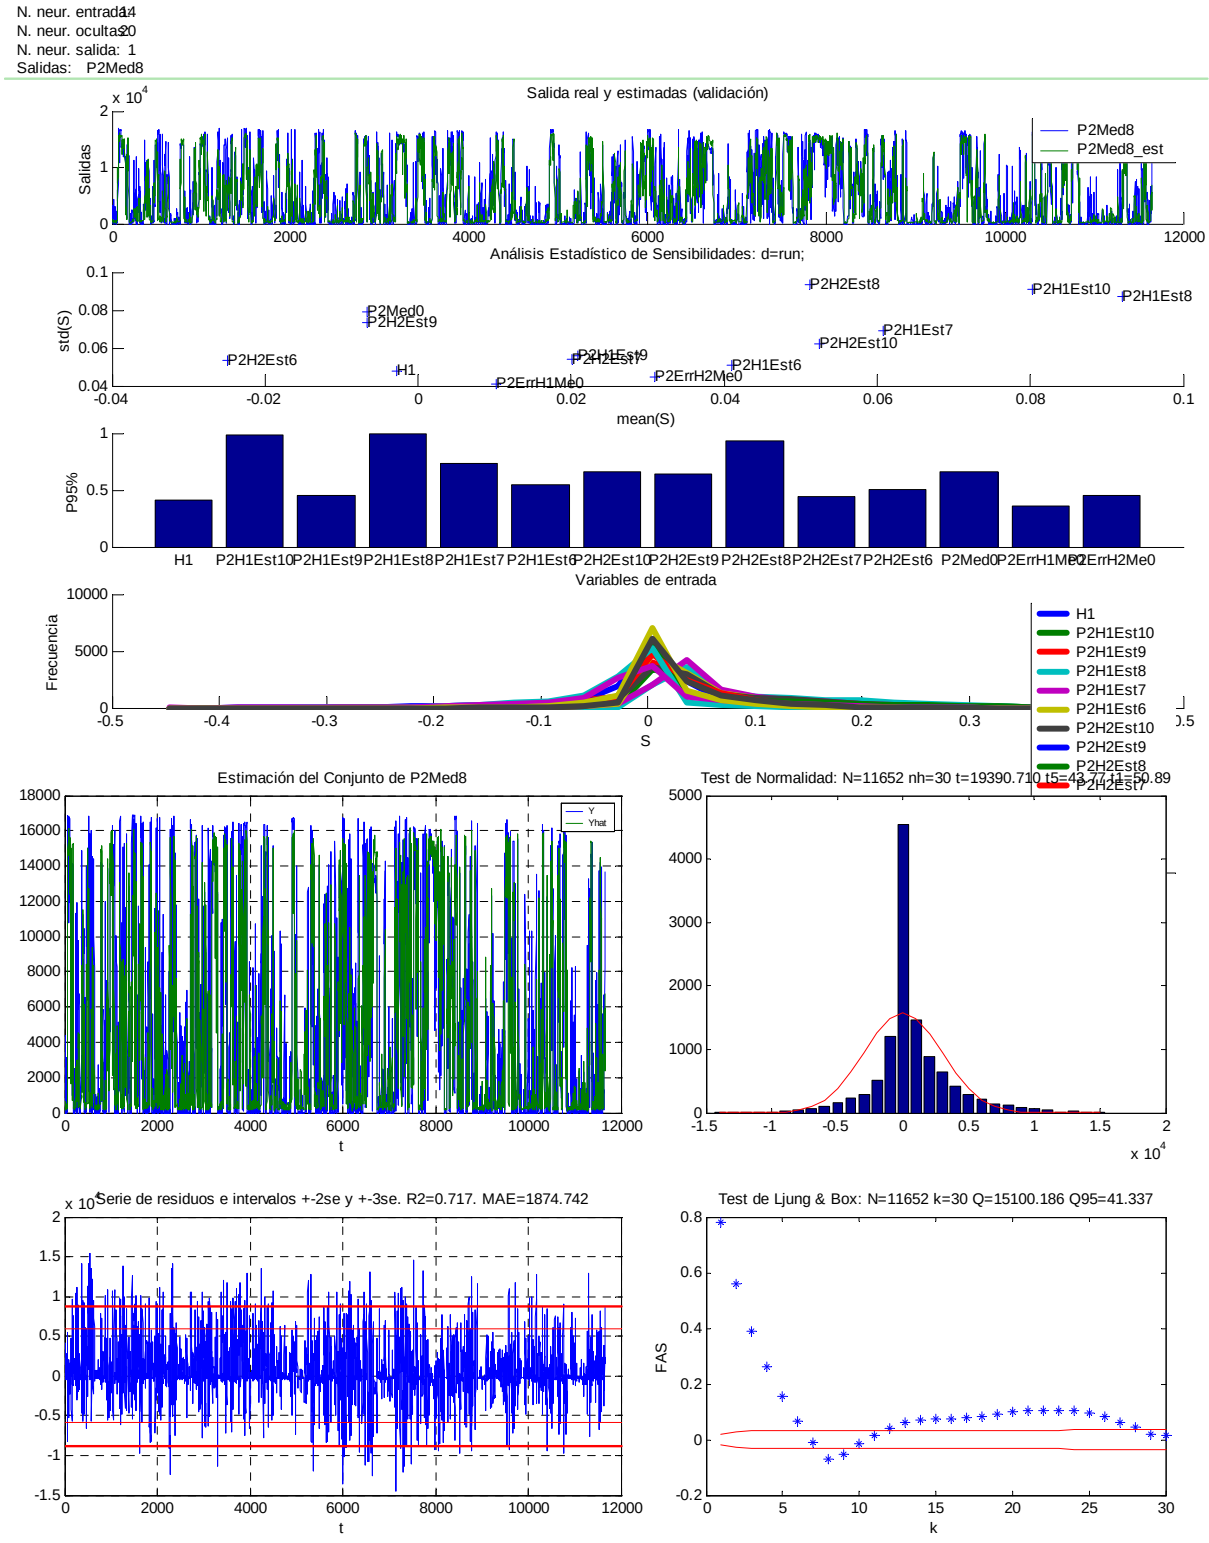


Figura 55: Detalle del modelo de E2 con horizonte de 8 horas

6.3 Detalle de los modelos de la agregación de los parques 1 y 2

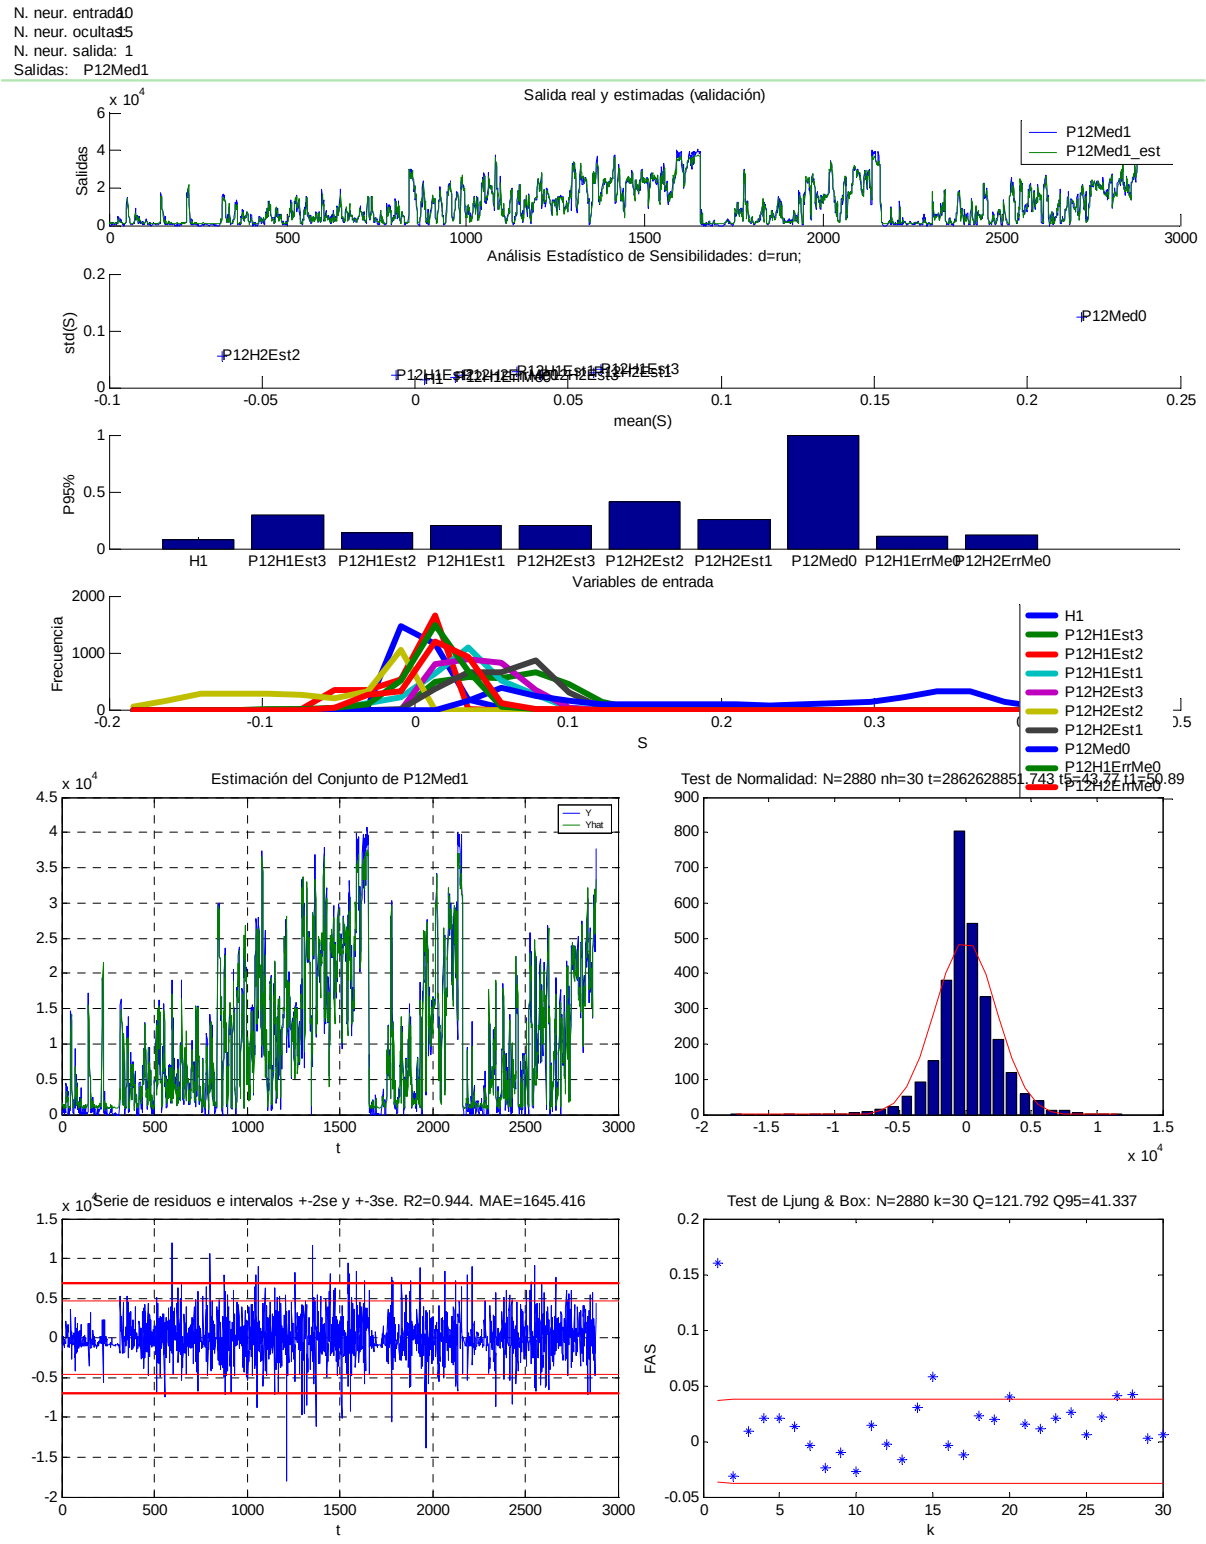


Figura 56: Detalle del modelo de E12 con horizonte de 1 hora

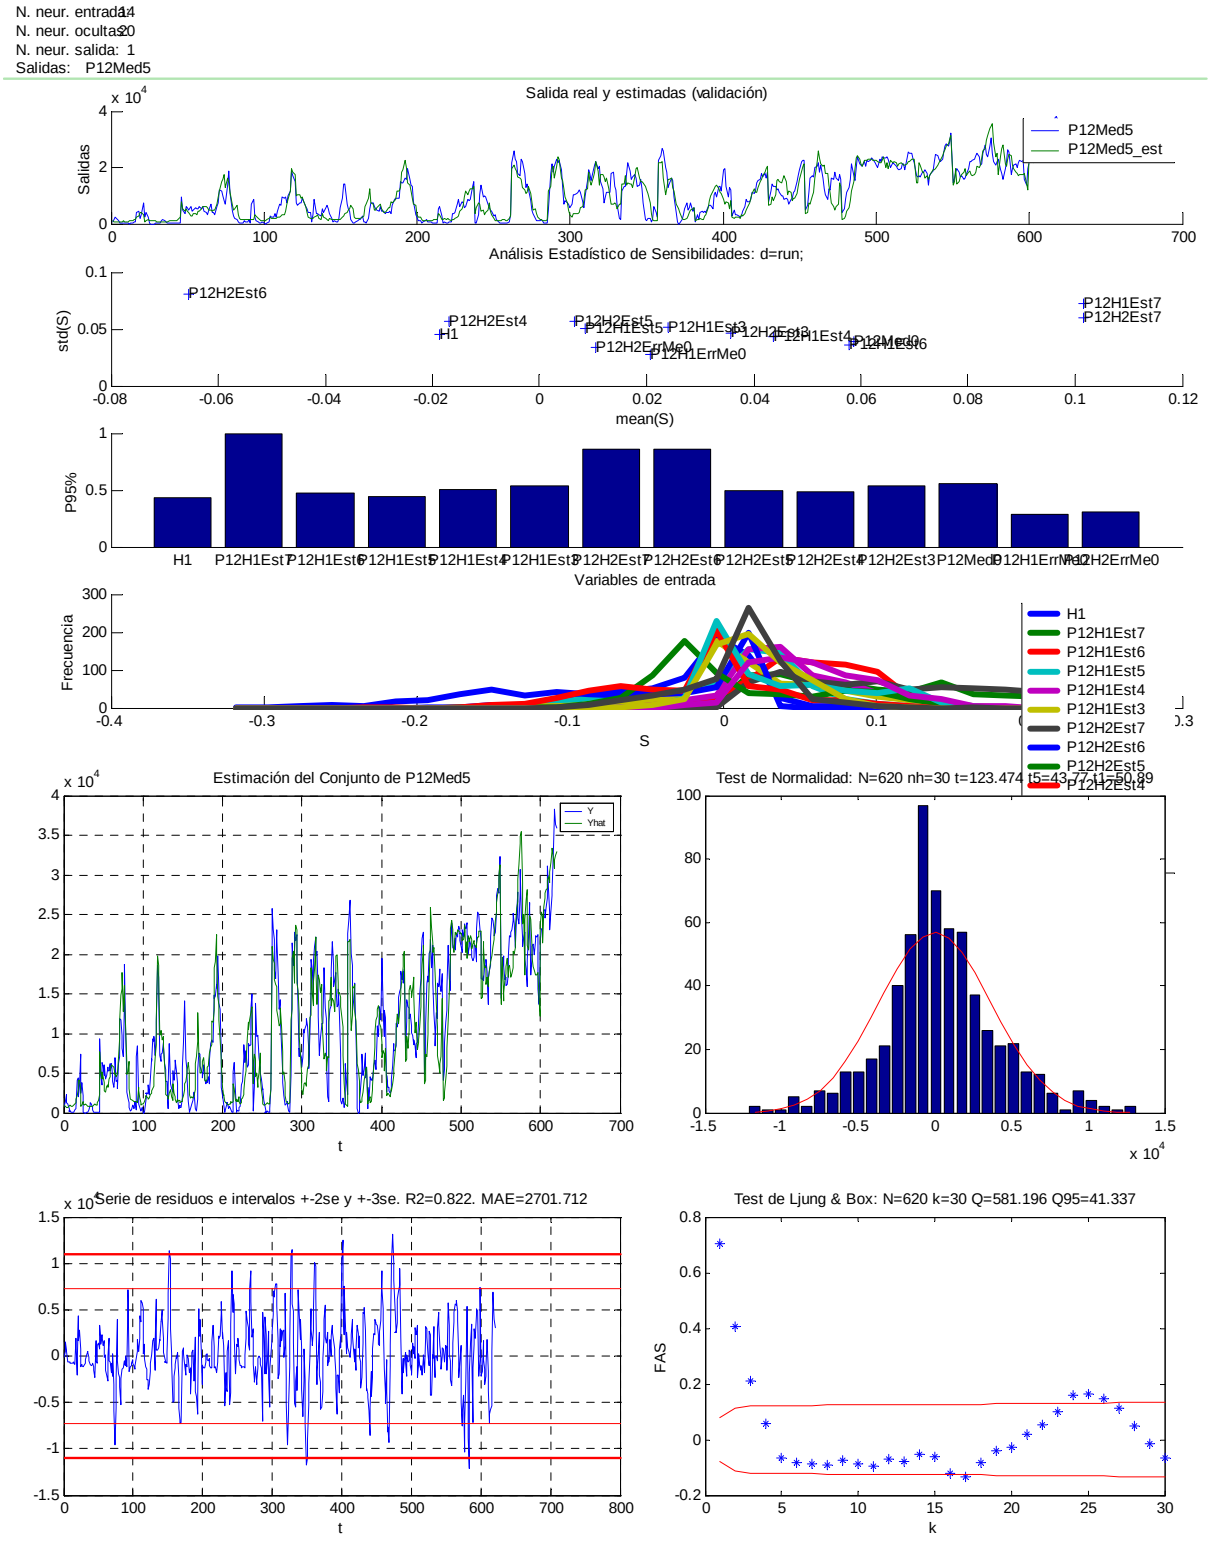


Figura 57: Detalle del modelo de E12 con horizonte de 5 horas (conjunto de validación)

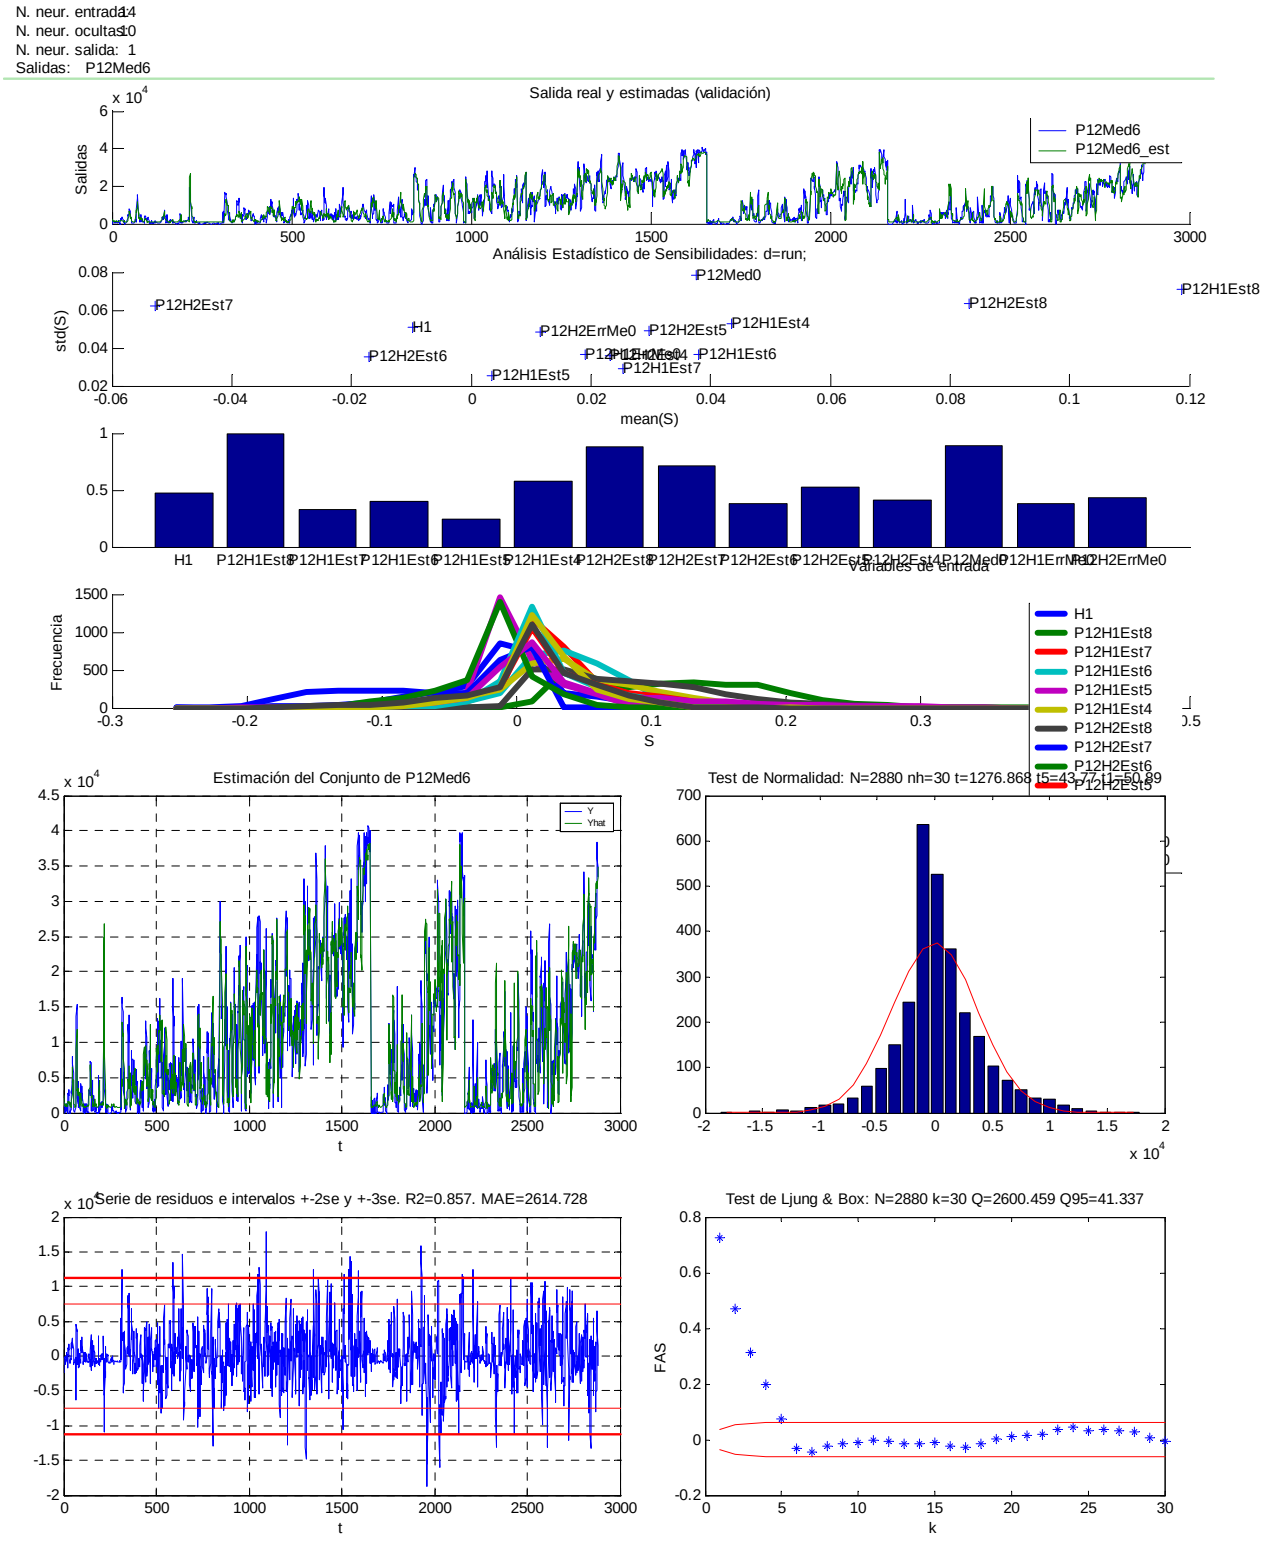


Figura 58: Detalle del modelo de E12 con horizonte de 6 horas

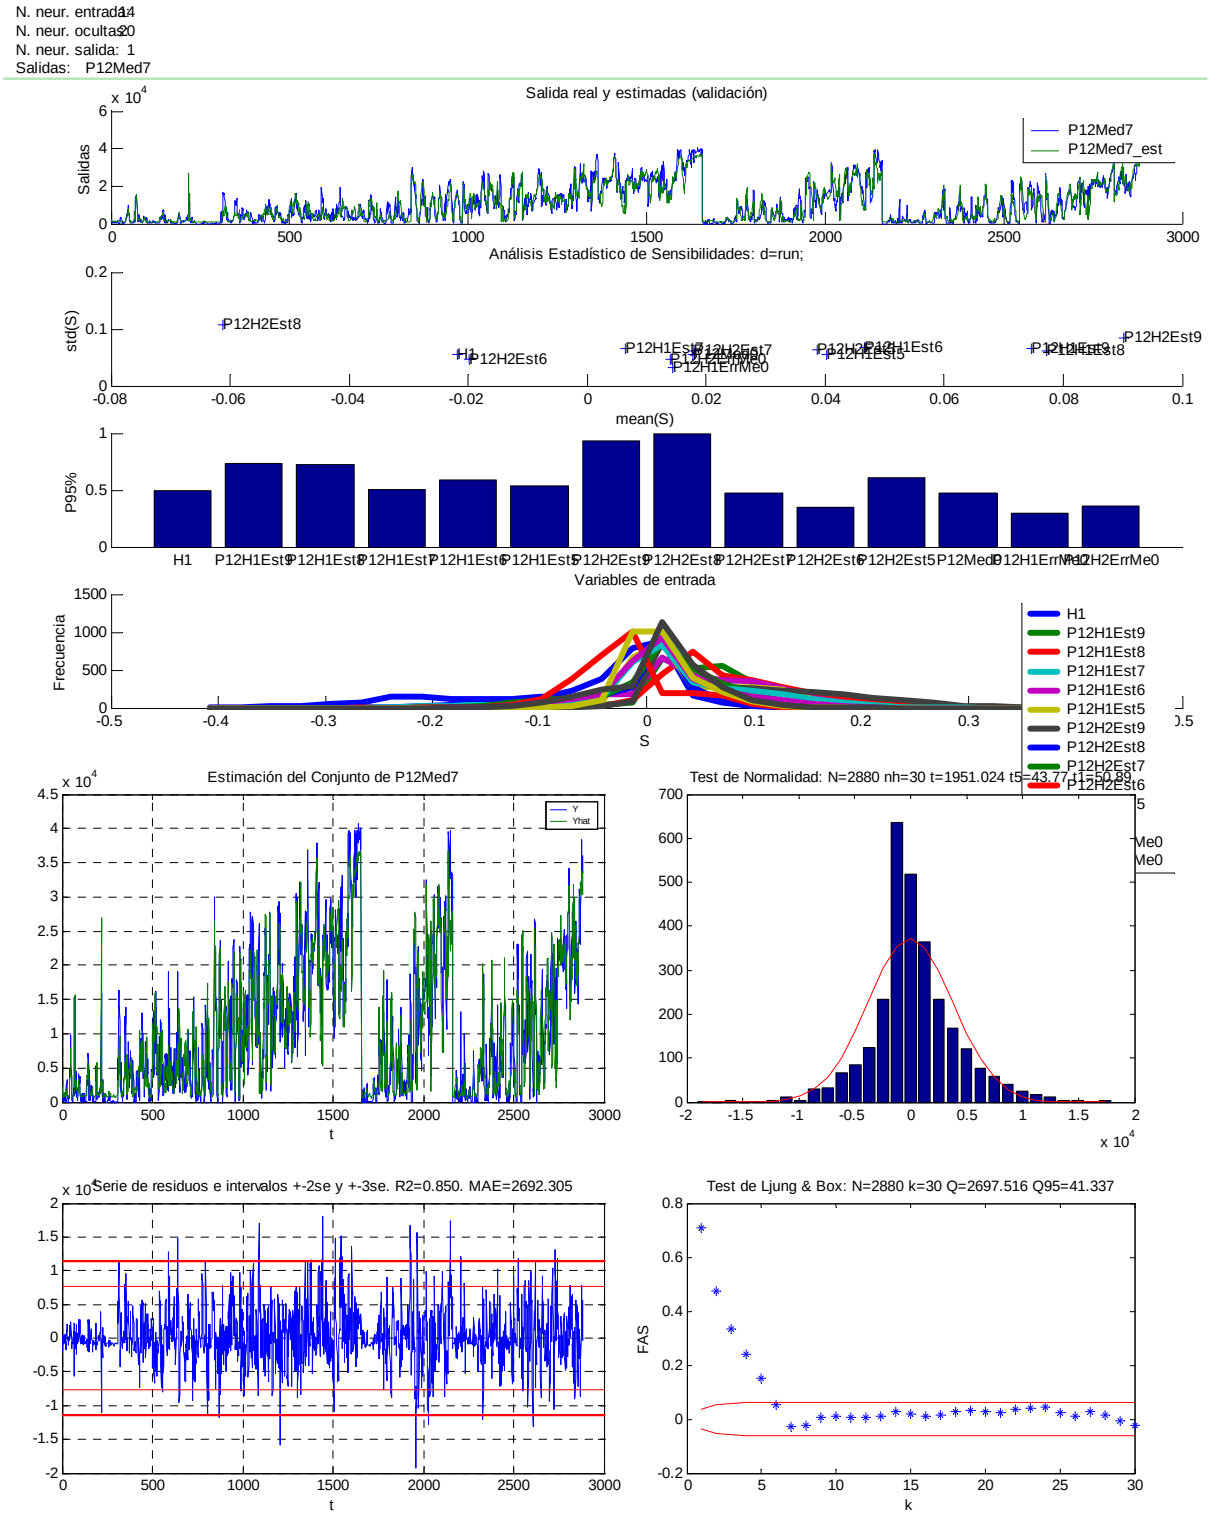


Figura 59: Detalle del modelo de E12 con horizonte de 7 horas

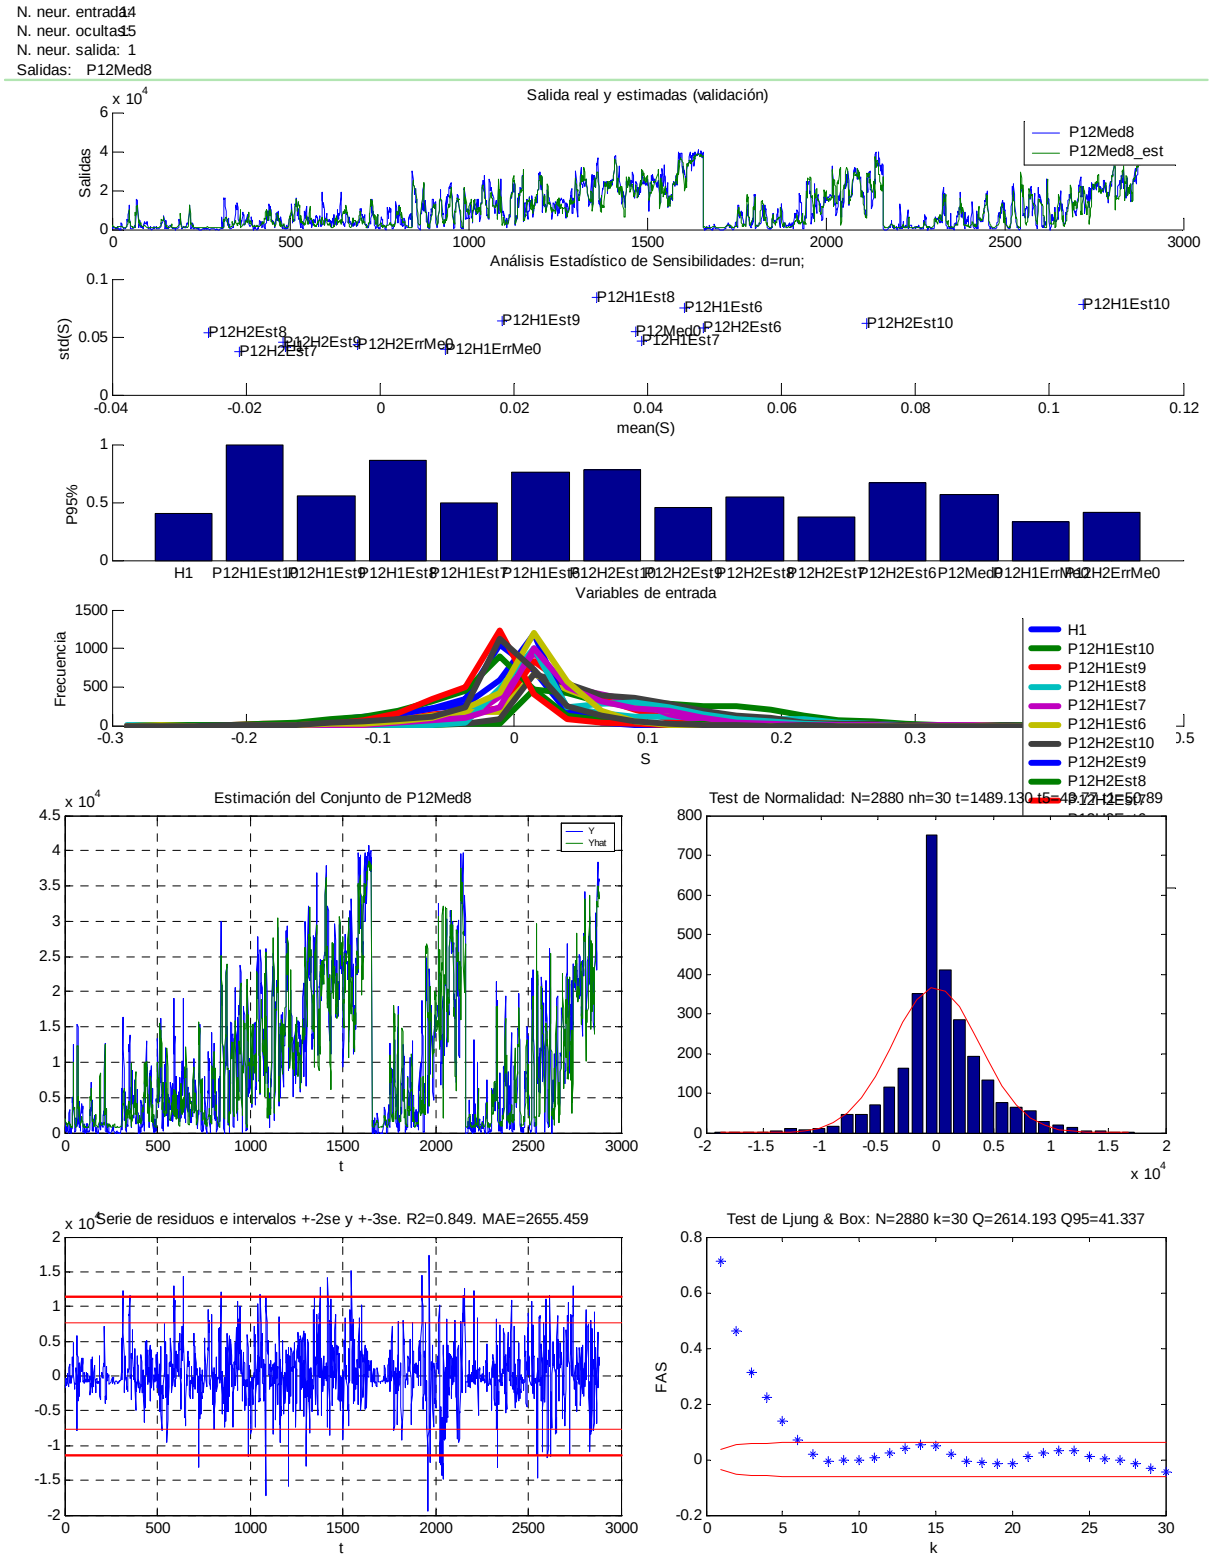


Figura 60: Detalle del modelo de E12 con horizonte de 8 horas