

APLICACIÓN DEL APRENDIZAJE PROFUNDO PARA LA  
PREDICCIÓN DE CAUDAL FRENTE A ESCENARIOS DE  
INUNDACIÓN DEL RÍO ARGÁ

**Ismael Moreno Lasa**

Trabajo fin de estudios para el

*Grado en Ciencia de Datos*

Universidad Pública de Navarra

Escuela Técnica Superior de Ingeniería Agronómica y Biociencias

Dirigido por *Humberto Bustince Sola*



Junio 2023

## Agradecimientos

La presentación del presente trabajo requiere también de los agradecimientos a Peio Oria, delegado territorial en Navarra de la Agencia Estatal de Meteorología, por su apoyo, consejo profesional y disposición de gran parte de los datos empleados sin los cuales los resultados obtenidos no habrían sido posibles.

Por otro lado, quisiera agradecer a todos los profesores e investigadores de la Universidad Pública de Navarra tanto por su esfuerzo en nuestra formación académica de alumnos del grado en Ciencia de Datos como por todo el apoyo académico y profesional que me han brindado para este proyecto.

Por último, agradezco a mi familia y a mis personas más cercanas por todo el apoyo y motivación que me han dado, y que me ha permitido la conclusión de este trabajo.



Ismael Moreno Lasa

6 de junio de 2023

## Resumen

La modelización del caudal en cuencas hidrográficas de rápido flujo es un problema altamente complejo en el que los modelos hidrológicos comúnmente utilizados a menudo tienen limitaciones. La existencia de una predicción que permita una alerta temprana de inundaciones es vital para minimizar los daños a la propiedad y la infraestructura, y reducir los riesgos potenciales para las personas.

Las técnicas de aprendizaje automático tienen el potencial de superar algunas de las limitaciones de los modelos hidrológicos tradicionales al utilizar conjuntos de datos grandes para aprender las relaciones entre diferentes variables hidrológicas, lo que permite realizar predicciones más precisas del caudal en cuencas de flujo rápido.

El objetivo de este trabajo ha sido aplicar redes neuronales de Memoria a Corto y Largo Plazo (LSTM, por sus siglas en inglés) para la predicción de caudal en la cuenca del río Arga. Las redes LSTM son un tipo de Redes Neuronales Recurrentes (RNN) que son especialmente adecuadas para tareas de predicción en series temporales. Estas redes tienen células de memoria que les permiten recordar patrones en los datos a lo largo de un período de tiempo más largo, lo que las hace efectivas para capturar las dependencias temporales presentes en los datos de caudal. El uso de este tipo de redes permite superar algunas de las limitaciones típicas de los modelos hidrológicos tradicionales.

Al utilizar redes LSTM, mostramos que el modelo es capaz de capturar la compleja dinámica temporal de los datos de caudal y realizar predicciones precisas a corto plazo, incluso para escenarios de alto flujo, con varias horas de anticipación. Los resultados demuestran que el uso de estas redes para la predicción del caudal en la cuenca del río Arga es un enfoque prometedor, especialmente para predicciones a corto plazo, con anticipación de horas.

El uso de enfoques de aprendizaje automático puede desbloquear un nuevo potencial en la predicción y gestión de los recursos hídricos en el área, así como en la evaluación de riesgos y sistemas de alerta temprana para inundaciones.

**Palabras clave** Modelización de caudal · Cuencas hidrográficas · Modelos hidrológicos · Predicción de caudal · Aprendizaje automático · Aprendizaje profundo · Redes neuronales · LSTM · Red neuronal recurrente (RNN) · Series temporales · Alerta temprana

## Abstract

Modeling streamflow in fast-flowing watersheds is a highly complex problem where commonly used hydrological models often have limitations. The existence of a prediction that allows for early warning of floods is vital for minimizing damage to property and infrastructure and reducing potential risks to people.

Machine learning techniques have the potential to overcome some of the limitations of traditional hydrological models by using large datasets to learn the relationships between different hydrological variables, making it possible to make more accurate predictions of streamflow in fast-flow basins.

In this work, Long Short-term Memory (LSTM) neural networks are tested to predict streamflow in the Arga river's basin. LSTM networks are a type of Recurrent Neural Network (RNN) that are particularly well-suited for time-series prediction tasks. These networks have memory cells that allow them to remember patterns in the data over a longer period of time, making them effective at capturing the temporal dependencies present in the streamflow data. The use of this types of networks allows the potential to overcome some of the typical limitations of traditional hydrological models.

By using LSTM networks, we show that the model is able to capture the complex temporal dynamics of the streamflow data and make short-term, hours ahead, accurate predictions even for high flow scenarios. The results demonstrate that the use of LSTM networks for streamflow prediction in the Arga river basin is a promising approach, particularly for short-term predictions.

The usage of machine learning approaches may unlock new potential in the forecasting and management of water resources in the area, as well as in risk assessment and early warning systems for floods.

**Keywords** Flow modeling · Hydrographic basins · Hydrological models · Flood prediction · Machine learning · Deep learning · Neural networks · Long Short-term Memory (LSTM) · Recurrent Neural Network (RNN) · Time series · Early warning



---

# Índice

---

Lista de figuras . . . . .	V
Lista de tablas . . . . .	VII
<b>1. Introducción</b>	<b>1</b>
1.1. Inundaciones en la Cuenca de Pamplona . . . . .	3
1.2. Objetivos . . . . .	4
1.3. Aprendizaje Profundo . . . . .	5
<b>2. Estado del arte</b>	<b>6</b>
2.1. Aproximaciones clásicas . . . . .	6
2.2. Aproximaciones por aprendizaje automático . . . . .	7
<b>3. Metodología</b>	<b>8</b>
3.1. Agregaciones . . . . .	8
3.2. Red recurrente autorregresiva . . . . .	9
3.3. Modelo de regresión . . . . .	13
<b>4. Datos disponibles</b>	<b>14</b>
4.1. Caudales en estaciones de aforo en río . . . . .	14
4.2. Precipitación real en estaciones . . . . .	15
4.3. Malla de temperaturas . . . . .	16
4.4. Índice de precipitaciones acumuladas. . . . .	16
4.5. Mapa de precipitaciones pasadas. . . . .	17
4.6. Mapa de precipitaciones del modelo Harmonie . . . . .	18
4.7. Estimaciones de humedad en suelo . . . . .	18
<b>5. Experimentación y resultados</b>	<b>19</b>
5.1. Construcción de ventanas temporales . . . . .	19
5.2. Análisis de componentes Principales . . . . .	20
5.3. Empleo de predicciones meteorológicas . . . . .	21
5.4. Tratamiento de mapas . . . . .	21
5.5. Parámetros de entrenamiento . . . . .	22
5.6. Resultados . . . . .	24
<b>6. Conclusiones y mejoras futuras</b>	<b>30</b>

<b>Referencias</b>	<b>31</b>
<b>A. Anexo del capítulo 5</b>	<b>34</b>

---

# Índice de figuras

---

1.1. Cuencas de los ríos Ulzama y Arga hasta Pamplona sobre mapa de relieve. <i>Información geográfica propiedad del Gobierno de Navarra.</i> . . . . .	2
1.2. Periodos de retorno de del Sistema Nacional de Cartografía de Zonas Inundables para el área de Pamplona. <i>Información geográfica propiedad del Gobierno de Navarra.</i> . . . . .	3
2.1. Resultados para modelos de ML en predicciones de caudal a corto plazo.	7
3.1. Esquema de una red recurrente. Figura tomada de (Kalita 2022). . . . .	10
3.2. Esquema de una celda LSTM frente a una RNN. Figura tomada de (Donahue et al. 2015). . . . .	10
3.3. Esquema autorregresivo. Figura tomada de (TensorFlowCore 2023). . .	12
3.4. Esquema de la red. . . . .	13
4.1. Caudal en estación de aforo en Arazuri. . . . .	15
4.2. Caudal en estación de aforo tras embalse en Eugi. . . . .	15
4.3. Precipitación horaria en Huarte. . . . .	16
4.4. Índice de precipitación acumulada horario en Huarte. . . . .	17
4.5. Mapa de precipitación para una hora. . . . .	17
4.6. Humedad relativa. <i>Media móvil de 30 días en rojo.</i> . . . . .	18
5.1. Esquema de ventanas temporales. <i>El número de celdas y series de celdas es puramente esquemático.</i> . . . . .	19
5.2. Caudal en Arazuri a las 6 horas frente a componentes principales. . . . .	20
5.3. Caudal en Arazuri a las 6 horas frente a tres componentes principales. .	21
5.4. Resultados gráficos en <i>test</i> para agregación por máximo, <i>offset</i> de 6h. .	26
5.5. Resultados gráficos en <i>test</i> para agregación por mínimo, <i>offset</i> de 6h. . .	27
5.6. Resultados gráficos en <i>test</i> para agregación por media, <i>offset</i> de 6h. . .	28
5.7. Resultados gráficos en <i>test</i> para agregación por OWA, <i>offset</i> de 6h. . . .	29
A.1. Resultados gráficos en <i>test</i> para agregación por máximo, <i>offset</i> de 3h. .	35
A.2. Resultados gráficos en <i>test</i> para agregación por mínimo, <i>offset</i> de 3h. . .	36
A.3. Resultados gráficos en <i>test</i> para agregación por media, <i>offset</i> de 3h. . .	37
A.4. Resultados gráficos en <i>test</i> para agregación por OWA, <i>offset</i> de 3h. . . .	38
A.5. Resultados gráficos en <i>test</i> para agregación por máximo, <i>offset</i> de 9h. .	39

A.6. Resultados gráficos en <i>test</i> para agregación por mínimo, <i>offset</i> de 9h. . .	40
A.7. Resultados gráficos en <i>test</i> para agregación por media, <i>offset</i> de 9h. . .	41
A.8. Resultados gráficos en <i>test</i> para agregación por OWA, <i>offset</i> de 9h. . . .	42
A.9. Resultados gráficos en <i>test</i> para agregación por máximo, <i>offset</i> de 12h. .	43
A.10. Resultados gráficos en <i>test</i> para agregación por mínimo, <i>offset</i> de 12h. .	44
A.11. Resultados gráficos en <i>test</i> para agregación por media, <i>offset</i> de 12h. . .	45
A.12. Resultados gráficos en <i>test</i> para agregación por OWA, <i>offset</i> de 12h. . .	46

---

# Índice de cuadros

---

1.1. Superficie de las regiones de interés de las cuencas. . . . .	2
1.2. Caudales máximo en estaciones en escenarios de inundación relevantes. <i>Caudales en m<sup>3</sup>/s.</i> . . . . .	4
5.2. Resultados en <i>test</i> para función de agregación e intervalo de predicción, <i>offset.</i> . . . . .	24

# Introducción

---

El agua ha sido un elemento vital para el desarrollo de los asentamientos humanos desde tiempos antiguos hasta el presente. No resulta extraño que las áreas cercanas a los ríos se convirtieran en lugares preferidos para el establecimiento de comunidades urbanas y zonas donde se llevaran a cabo actividades productivas relacionadas con el uso del agua: las llanuras aluviales ofrecen un terreno con gran capacidad para la agricultura y la cercanía del cauce del río proporciona tanto el agua como un recurso indispensable para las ciudades e industria así como una infraestructura de transporte y energética (Bescos and Camarasa 1998).

Sin embargo, la proximidad a las vías fluviales también trae consigo ciertos riesgos: las inundaciones son uno de los peligros más destacados asociados a las proximidades de un río. Durante períodos de lluvias intensas o deshielo, los ríos pueden crecer rápidamente y sobrepasar su capacidad de contención y, como resultado, las áreas cercanas a las orillas se vuelven propensas a sufrir anegaciones de agua que pueden causar daños significativos a las zonas residenciales e industriales pudiendo provocar la destrucción de viviendas, infraestructuras y cultivos, lo que implica una pérdida económica considerable para las comunidades afectadas. Todo esto sin considerar el adicional peligro para la seguridad de la población, ya que las aguas desbordadas pueden arrastrar objetos pesados, crear corrientes peligrosas y causar el colapso de estructuras y comprometer la integridad física de las personas, que ante escenarios de rápida evolución, corren el riesgo de sufrir lesiones o incluso de perder sus vidas (Olcina et al. 2008).

La comarca de la ciudad de Pamplona se encuentra atravesada por los ríos Arga y Ulzama, siendo el segundo afluente del primero. Debido a la topología del terreno de la cuenca fluvial anterior a Pamplona, que presenta un terreno montañoso y accidentado, estos ríos presenten un flujo rápido, con pequeños o inexistentes represamientos, lo que implica la posibilidad de cambios repentinos en su caudal (Pejenaute Goñi 2002).

Como se visualiza en la figura 1.1, las cuencas de ambos ríos, Arga y Ulzama, tienen sus puntos más elevados en los pirineos desde donde la corriente fluvial inicia un descenso hasta su confluencia poco después de su entrada en la comarca de Pamplona, en las localidades de Huarte y Villava.

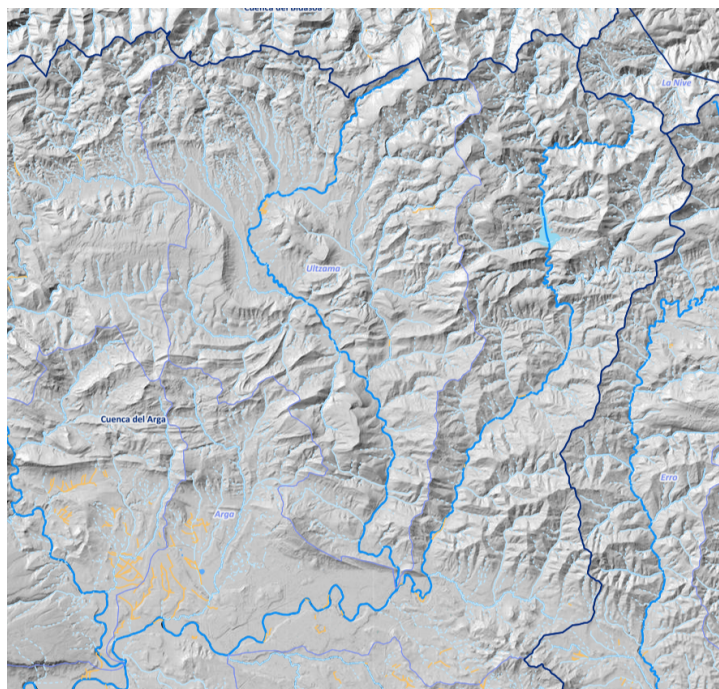


Figura 1.1: Cuencas de los ríos Ulzama y Arga hasta Pamplona sobre mapa de relieve. *Información geográfica propiedad del Gobierno de Navarra.*

EL flujo de agua desde su precipitación o deshielo sigue sin retenciones por ambas cuencas excepto para las zonas más altas de la cuenca del Arga, donde se haya el embalse de Eugi, visible también en la figura 1.1. Dicho embalse cuenta con una capacidad de  $21,40 \text{ hm}^3$  por lo que cuenta con cierta capacidad de retención. Sin embargo, tomando un periodo reciente de fuertes inundaciones, *5/12/2021 al 15/12/2021*, el caudal de salida acumulado del embalse alcanzó los  $28,62 \text{ hm}^3$  y el caudal acumulado a su paso por Huarte de  $49,20 \text{ hm}^3$ . Se vislumbra de esta manera que la capacidad reductora del embalse es limitada tanto por el tamaño de la cuenca anterior a la presa como por su capacidad.

Región	Superficie $\text{km}^2$	Superficie %
Arga hasta Pamplona	435,74	100
Ulzama	262,78	60,31
Arga hasta Huarte	171,089	39,26
Arga hasta Eugi	66,832	15,34
Arga desde Eugi hasta Huarte	104,257	23,93

Cuadro 1.1: Superficie de las regiones de interés de las cuencas.

La superficie cubierta por cada región relevante de las cuencas, siendo estas las cuencas de ambos ríos y sus particiones por el embalse de Eugi se muestra en la tabla 1.1. La contribución en medida de superficie a la descarga del Arga en Pamplona es mayoritaria para el río Ulzama, sin embargo la contribución de las cuencas en caudal real puede

diferir por motivos climatológicos como pueden ser la mayor precipitación anual o la mayor presencia de precipitación sólida.

## 1.1. Inundaciones en la Cuenca de Pamplona

En varias ocasiones, la comarca de Pamplona ha sido escenario de inundaciones destructivas debido a lluvias intensas y prolongadas en las cabeceras de estos ríos. Estas inundaciones han tenido un impacto significativo en áreas residenciales e industriales, resultando en daños materiales considerablemente graves y planteando un riesgo potencial para la seguridad de la población (López et al. 2012). Estas situaciones resaltan los peligros asociados a la proximidad a las vías fluviales y la necesidad de implementar medidas adecuadas de prevención y mitigación para reducir los efectos adversos de las inundaciones en estas comunidades.

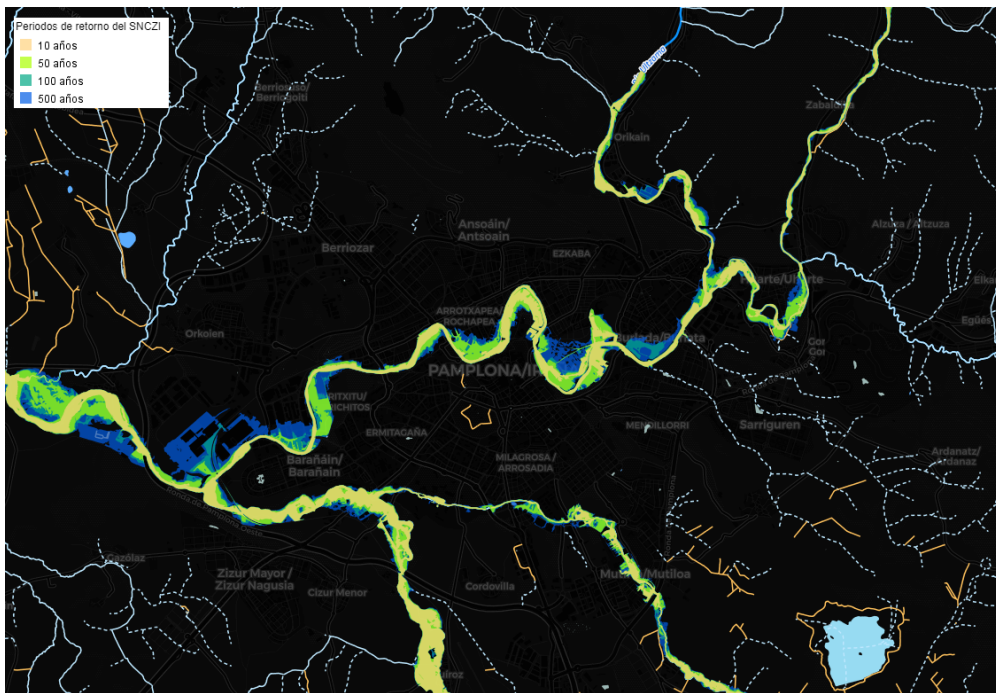


Figura 1.2: Periodos de retorno de del Sistema Nacional de Cartografía de Zonas Inundables para el área de Pamplona. *Información geográfica propiedad del Gobierno de Navarra.*

La figura 1.2 muestra el modelo de periodos de retorno de inundación obtenido por el Sistema Nacional de Cartografía de Zonas Inundables: se visualiza el alcance máximo del cauce fluvial en los periodos de 10, 50, 100 y 500 años.

Resulta vital destacar dos eventos significativos que tuvieron lugar en la cuenca: el 9 de junio de 2013 y el 10 de diciembre de 2021. Durante ambos eventos, se registraron caudales cercanos a los  $500 \text{ m}^3/\text{s}$  en la estación de aforo en Burlada, después de la confluencia de los ríos Arga y Ulzama. Estas cifras ponen de manifiesto la magnitud de



las precipitaciones y el impacto que tuvieron en la región.

Episodio	Olave (Ulzama)	Huarte	Eugi	Burlada	Arazuri
9/6/2013	316.70	175.86	57.62	496.50	660.22
13/12/2019	202.43	136.75	56.82	452.00	543.81
10/12/2021	320.00	188.36	109.08	507.75	671.70

Cuadro 1.2: Caudales máximo en estaciones en escenarios de inundación relevantes. *Caudales en  $m^3/s$ .*

La tabla 1.2 muestra los picos de caudal para las estaciones de relevancia disponibles en el entorno de forma que se consigue una visión de la contribución de cada región a la descarga del río en Pamplona durante los episodios de inundación más relevantes.

En resumen, los episodios de inundación en el área de Pamplona se presentan de manera recurrente y con periodos variables de pocos años, más aún, la capacidad de limitar los efectos dañinos es mínima en cuanto a la vía de la contención de agua por el embalse y de compleja previsión por la vía de prevención o prealerta en las zonas afectadas.

## 1.2. Objetivos

El motivo de este trabajo se centra en el último punto comentado, la predicción y consecuente posible alerta temprana de la descarga de muy altos caudales en el río Arga. Para ello, se plantean los siguientes aspectos de desarrollo.

- La utilización de técnicas de aprendizaje profundo, en contraposición a los modelos hidrológicos tradicionalmente empleados, buscando un mejor rendimiento en la predicción que con modelos de naturaleza «menos determinista».
- La obtención de resultados de mayor calidad en el problema de regresión que implica la predicción de caudal a corto plazo, con un horizonte temporal de horas de antelación.
- Los algoritmos de ajuste automático seleccionados deben ser capaces de capturar las fuertes dependencias espaciales y temporales de los comportamientos diversos presentes en cada una de las series temporales de variables que recopilan datos de precipitación, caudal, temperatura y humedad.

El empleo de técnicas de aprendizaje profundo representa un cambio innovador en la forma en que abordamos la predicción hidrológica. Este enfoque tiene el potencial de permitir mejorar la precisión y la calidad de las predicciones de caudal, lo que es fundamental para la toma de decisiones en diversas áreas, como la gestión de recursos hídricos, la planificación de infraestructuras y la prevención de desastres naturales en situaciones críticas de fuerte afluencia en los ríos.

### 1.3. Aprendizaje Profundo

El aprendizaje profundo, habitualmente referido como *deep learning* en inglés, es una disciplina del aprendizaje automático que ha demostrado un alto potencial en numerosos campos en la última década. Se basa en la construcción y entrenamiento, ajuste automático de parámetros, de redes neuronales artificiales profundas, capaces de aprender y realizar tareas complejas de manera automatizada.

A través de una versión bioinspirada por el funcionamiento del cerebro humano, las redes neuronales profundas han demostrado una capacidad sorprendente para extraer patrones y características de grandes conjuntos de datos, permitiendo realizar predicciones y toma de decisiones precisas. Dichos algoritmos se fundamentan en la composición de múltiples capas de unidades de procesamiento llamadas neuronas o perceptrones. Cada neurona toma una serie de entradas, las procesa y produce una salida por medio de una transformación afín sobre la que se aplica una función, ecuación 1.1. Estas salidas se propagan hacia adelante a través de las capas de la red, siendo los pesos refinados y ajustados mediante un proceso de entrenamiento que busca minimizar el error entre las salidas esperadas y las producidas.

$$X_{out} = f(\theta_0 + \sum_{i=1}^n \theta_i X_i) = f(\theta_0 + \Theta^T \cdot \mathbf{X}) \quad (1.1)$$

Siendo  $\theta_i$  parámetros propios a cada neurona y aprendibles (Gallant et al. 1990), y  $f(\cdot)$  una *función de activación* aplicada a la transformación afín sobre la entrada de cada neurona (Ramachandran et al. 2017).

El entrenamiento de las redes neuronales profundas se realiza mediante algoritmos de aprendizaje, como el descenso de gradiente estocástico, que ajustan los pesos y las conexiones entre las neuronas de manera iterativa. A medida que se procesan más datos de entrenamiento, la red neuronal aprende a reconocer patrones más complejos y a realizar predicciones más precisas.

El éxito del aprendizaje profundo radica en su capacidad para aprender representaciones de características de forma automática, sin necesidad de que los expertos humanos diseñen características específicas para cada tarea.

No obstante, el aprendizaje profundo también presenta desafíos y limitaciones. La cantidad masiva de datos requeridos para entrenar redes neuronales profundas y el tiempo de cálculo necesario pueden ser obstáculos significativos. Además, la interpretación de las decisiones tomadas por estas redes puede resultar complicada, ya que su funcionamiento interno no siempre es transparente.

# Estado del arte

---

La modelización de los sistemas hídricos lleva realizándose desde tiempos antiguos hasta la actualidad, con el objetivo de comprender y poder maximizar el uso de los recursos hídricos y controlar su impacto en el entorno.

Desde las grandes obras hídricas del imperio romano, donde se construyeron acueductos y sistemas de drenaje para abastecer a las ciudades (Magnusson 2003), hasta los avances tecnológicos actuales, la predicción hidrológica ha sido una herramienta crucial en la gestión y planificación del agua.

Sin embargo, las técnicas han diferido y siguen difiriendo tanto por los diferentes avances tecnológicos en materia de monitorización y modelización como por las diferentes propiedades hidrológicas de las regiones, que hacen de la modelización del comportamiento de los ríos problemas de cierta unicidad no existiendo así un estado del arte general para las tareas de predicción de caudal (Pandi et al. 2021).

## 2.1. Aproximaciones clásicas

Los modelos hidrológicos habitualmente empleados por las agencias o instituciones gubernamentales habitualmente emplean modelos estadísticos con gran componente determinista y fuertemente basados en características de la topología del terreno, como pueden ser la pendiente o la retención y absorción de precipitación, con el fin de discretizar y parametrizar el proceso hidrológico al completo (Vinogradov et al. 2011).

Si bien estos modelos pueden dar lugar a buenos resultados de alta interpretabilidad, en ocasiones anómalas como pueden ser los escenarios de descarga excepcional de caudal, o para regiones donde el flujo es rápido y poco retenido, la precisión de estos es limitada (Lespinas et al. 2014).

Ejemplo de estos modelos hidrológicos clásicos es el modelo HEC-HMS (Hydrologic Engineering Center-Hydrologic Modeling System), desarrollado por el Hydrologic Engineering Center HEC del U.S. Army Corps of Engineers, USACE, para la simulación de caudales de ríos en cuencas específicas. Este modelo se basa en la estructuración de la cuenca en subcuencas, que están asociadas a los cauces de la red fluvial. Se utiliza el

método de los Polígonos de Thiessen para evaluar la precipitación en cada subcuenca utilizando datos de estaciones pluviométricas. El modelo se basa en relaciones matemáticas simples que representan los procesos hidrológicos (López et al. 2012).

## 2.2. Aproximaciones por aprendizaje automático

El estado actual de la modelización vía *machine learning* para la predicción de inundaciones es bastante joven y se encuentra en una etapa temprana de avance.

La literatura recoge resultados prometedores empleando variedad de algoritmos: Redes Neuronales Artificiales, *ANNs*, Máquinas de Soporte Vectorial, *SVM*, Sistema de inferencia neuro-*fuzzy* adaptativo, *ANFIS*, Redes Neuronales Wavelet, *WNNs*, o Árboles de Decisión, *DTs*. El artículo (Mosavi et al. 2018) realiza un estudio comparativo de distintos métodos para la predicción en eventos de inundación. Donde, así mismo, se identifica como posible estrategia habitual la hibridación, o no, de modelos clásicos con la introducción en los mismos de algoritmos de aprendizaje automático.




Figura 2.1: Resultados para modelos de ML en predicciones de caudal a corto plazo.

La gráfica 2.1 obtenida de (Mosavi et al. 2018) muestra resultados de múltiples desarrollos para modelos no hibridados, con una mecánica puramente propia de algoritmos de ajuste automático.

---

# Metodología

---

En este trabajo se emplea un modelo de aprendizaje profundo para la predicción horaria en corto plazo del caudal del río Arga para una estación de medida de referencia. En concreto, el modelo, consiste en una red neuronal que incorpora fases de agregación de datos, extracción de características mediante una subred recurrente Long Short-Term Memory autorregresiva y un regresor perceptrón multicapa.

La metodología dispuesta trata de manejar el carácter espacial de la información por medio de una serie de agregaciones de puntos según su disposición espacial e inferir el comportamiento temporal de los datos gracias a la red recurrente.

## 3.1. Agregaciones

La posibilidad de realizar agregaciones sobre los datos de entrada resulta vital en múltiples aspectos, estos van desde la reducción de dimensionalidad del problema de regresión, y su asociado tamaño de red neuronal, hasta la reducción de dependencia del modelo por valores de ciertas variables que pueden estar sometidas a errores o anomalías.

El modelo contará con datos de entrada en forma de malla, o mapa, tridimensional donde dos dimensiones tienen un carácter espacial y la tercera temporal. Así mismo, existen múltiples versiones de estas mallas de valores que componen en conjunto un ensemble de conjuntos de valores posibles en cada disposición temporal. Es decir, para cada instante de tiempo se dispone de múltiples mallas bidimensionales, y, todo ello en serie compone varias series de mallas bidimensionales.

De acuerdo a los enunciados anteriores, se seleccionan mecanismos de agregación a aplicar sobre las dos dimensiones espaciales y sobre el ensemble de mallas.

Se emplean las siguientes agregaciones.

- **Función máximo:** selecciona el valor máximo de la serie.

$$x_{agg} = \text{máx}(x_1, x_2, \dots, x_n)$$

- **Función mínimo:** selecciona el valor mínimo de la serie.

$$x_{agg} = \text{mín}(x_1, x_2, \dots, x_n)$$

- **Función media aritmética:** selecciona calcula el valor promedio de la serie .

$$x_{agg} = \frac{1}{n} \sum_{i=1}^n x_i$$

- **Función OWA** (Ordered Weighted Averaging): generalización de las funciones de agregación (Yager 1993). Utiliza pesos para ponderar los elementos y luego los ordena antes de calcular la media ponderada. Se define de la siguiente manera:

$$x_{agg} = \text{OWA}(x_1, x_2, \dots, x_n; w_1, w_2, \dots, w_n) = \sum_{i=1}^n w_i x_{(i)}$$

donde  $x_{(i)}$  representa el  $i$ -ésimo elemento más grande después de ordenar los  $x$  de manera descendente, y  $w_i$  es el peso asociado al  $i$ -ésimo elemento.

Las funciones presentadas se emplean en las primeras capas de la red para condensar la entrada de datos, se realiza un estudio del rendimiento del modelo con las diferentes funciones.

## 3.2. Red recurrente autorregresiva

Las redes recurrentes son un tipo de arquitectura de redes neuronales artificiales diseñadas para procesar y analizar secuencias de datos. A diferencia de las redes neuronales convencionales, las redes recurrentes tienen conexiones internas que les permiten mantener y utilizar información anterior mientras procesan nuevas entradas.

### 3.2.1. Redes recurrentes

La característica principal de las redes recurrentes es su capacidad para manejar datos secuenciales, donde la posición y la relación entre los elementos son fundamentales. La estructura básica de una red recurrente consta de unidades de procesamiento llamadas «celdas», que están interconectadas formando una especie de bucle, como se muestra en la figura 3.1. Cada celda toma una entrada y produce una salida, al mismo tiempo que mantiene una «memoria» interna que puede influir en su comportamiento futuro. Esta memoria recurrente es lo que permite que la red capture información relevante de los datos anteriores y la utilice para tomar decisiones en el contexto actual.




Figura 3.1: Esquema de una red recurrente. Figura tomada de (Kalita 2022).

### 3.2.2. Celdas LSTM

Las redes LSTM (Long Short-Term Memory) son una variante especializada de las redes recurrentes que se utilizan para abordar el problema del desvanecimiento de dependencias a largo plazo. Fueron diseñadas para superar este desafío al incorporar unidades de memoria llamadas «celdas de memoria» en su arquitectura. Estas celdas de memoria permiten a las redes LSTM almacenar y acceder a la información durante largos períodos de tiempo.

La estructura interna de una unidad LSTM consta de tres componentes principales: la celda de memoria, las puertas de entrada y las puertas de salida. La puerta de entrada determina qué información nueva se va a agregar a la celda de memoria, mientras que la puerta de salida controla la cantidad de información que se transmite a la salida de la unidad LSTM. Además, las LSTM tienen una puerta *forget*, de olvido, que decide qué información antigua se va a descartar de la celda de memoria, todo ello se muestra en la figura 3.2. Ambas puertas están compuestas por capas de neuronas con funciones de activación, y su función es regular el flujo de información dentro de la unidad LSTM. La definición de la celda se toma de Sak et al. (2014).

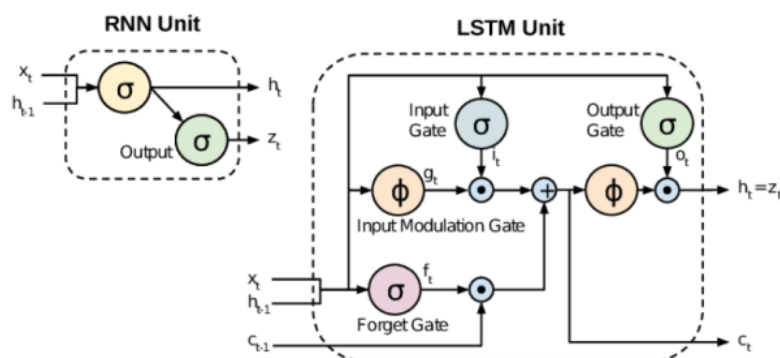


Figura 3.2: Esquema de una celda LSTM frente a una RNN. Figura tomada de (Donahue et al. 2015).

- **Puerta de entrada:**

La puerta de entrada determina cuánta de la información entrante debe ser almacenada en la celda de memoria. Toma la entrada actual  $x_t$  y el estado oculto anterior  $h_{t-1}$  como entradas y produce una salida  $i_t$  entre 0 y 1, que representa la activación de la puerta de entrada. La activación de la puerta de entrada se calcula de la siguiente manera:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i)$$

donde  $W_{xi}$ ,  $W_{hi}$  y  $b_i$  son la matriz de pesos y el vector de sesgos asociados con la puerta de entrada.

- **Puerta de olvido, o *forget gate*:**

La puerta de olvido determina cuánta de la información almacenada en la celda de memoria debe ser descartada. Toma la entrada actual  $x_t$  y el estado oculto anterior  $h_{t-1}$  como entradas y produce una salida  $f_t$  entre 0 y 1, que representa la activación de la puerta de olvido. La activación de la puerta de olvido se calcula de la siguiente manera:

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f)$$

donde  $W_{xf}$ ,  $W_{hf}$  y  $b_f$  son la matriz de pesos y el vector de sesgos asociados con la puerta de olvido.

- **Celda de memoria:**

La celda de memoria almacena la información de pasos de tiempo anteriores. Toma la entrada actual  $x_t$ , el estado oculto anterior  $h_{t-1}$  y la activación de la puerta de entrada  $i_t$  como entradas, y produce un nuevo estado de celda  $C_t$ . El estado de la celda se calcula de la siguiente manera:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c)$$

donde  $\odot$  representa la multiplicación elemento por elemento,  $W_{xc}$ ,  $W_{hc}$  y  $b_c$  son la matriz de pesos y el vector de sesgos asociados con la celda de memoria.

- **Puerta de salida:**

La puerta de salida determina la cantidad de información que se debe emitir desde la celda LSTM. Toma la entrada actual  $x_t$ , el estado oculto anterior  $h_{t-1}$  y la activación de la puerta de entrada  $i_t$  como entradas, y produce una salida  $o_t$  entre 0 y 1, que representa la activación de la puerta de salida. La activación de la puerta de salida se calcula de la siguiente manera:



$$o_t = \sigma(W_{x_o}x_t + W_{h_o}h_{t-1} + b_o)$$

donde  $W_{x_o}$ ,  $W_{h_o}$  y  $b_o$  son la matriz de pesos y el vector de sesgos asociados con la puerta de salida.

- **Estado oculto, o *hidden state*:**

El estado oculto  $h_t$  es la salida de la celda LSTM en el paso de tiempo  $t$ . Se calcula aplicando la activación de la puerta de salida  $o_t$  al estado de la celda  $C_t$ :

$$h_t = o_t \odot \tanh(C_t)$$

### 3.2.3. Modelo multipaso autorregresivo

Una red recurrente autorregresiva es una variante especializada de las redes recurrentes, como las RNN y las LSTM, con estructura de modelo multipaso, que realiza iteraciones para la construcción de la predicción. A diferencia de las redes recurrentes tradicionales, donde se utilizan tanto entradas anteriores como la entrada actual para predecir la siguiente salida, las redes recurrentes autorregresivas solo se basan en sus salidas anteriores para generar predicciones secuenciales. La figura 3.3 muestra el mecanismo autorregresivo de la red.

En una red recurrente autorregresiva, la salida generada en cada paso de tiempo se utiliza como entrada para el siguiente paso. Esto significa que la red aprende a modelar las dependencias entre los elementos de una secuencia y utiliza esa información para generar elementos futuros de manera iterativa. Una ventaja clave de este proceso es la capacidad para generar secuencias coherentes y realistas.

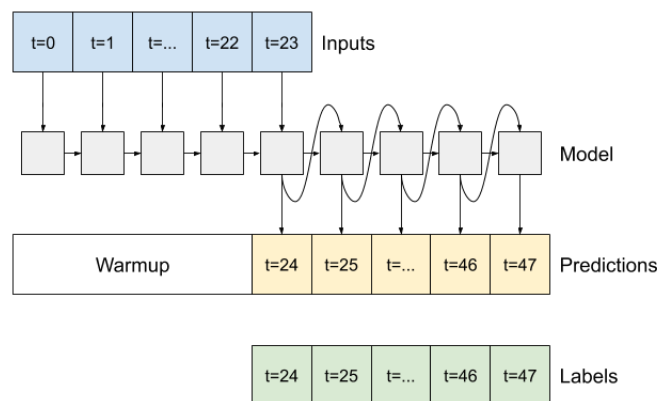


Figura 3.3: Esquema autorregresivo. Figura tomada de (TensorFlowCore 2023).

El número de iteraciones *hacia adelante* de la red autorregresiva es parametrizable e implica la existencia de un periodo de calentamiento, o *warmup* en la figura 3.3, para la

inicialización de los estados internos de las celdas, durante el cual no se realiza predicción o salida de nuevos valores.

### 3.3. Modelo de regresión

La red neuronal incorpora en serie capas de agregación, variables de entre las funciones descritas en la sección 3.1 según la configuración elegida; una capa que incorpora una red autorregresiva del mismo número de pasos como horas de antelación se fije para la predicción del modelo y un regresor perceptrón multicapa con una salida de la dimensión correspondiente a las horas de antelación fijadas. Además, se incorpora una conexión residual sobre la autorregresiva.

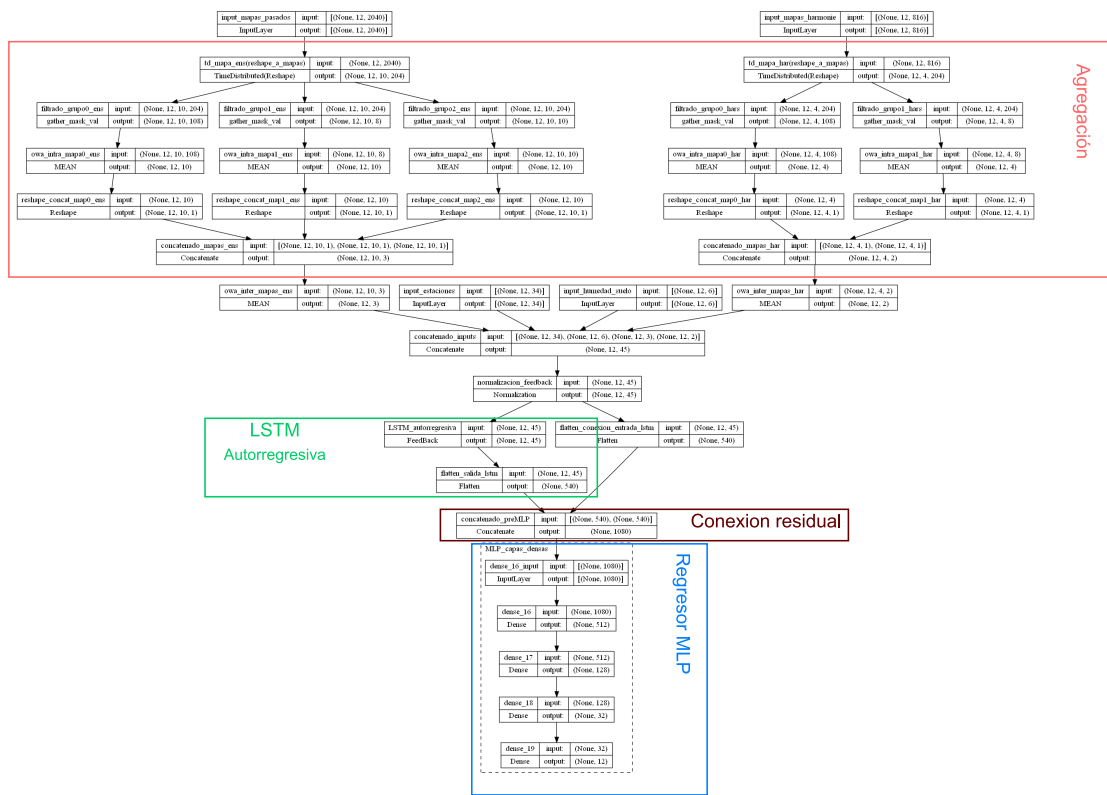


Figura 3.4: Esquema de la red.

La figura 3.4 representa la estructura de red al completo, se han excluido múltiples capas paralelas en el tercer nivel desde arriba para simplificar el grafo y indican en la estructura las capas anteriormente descritas. Algunos de los valores del esquema son parametrizables, sean por ejemplo el tamaño de salida de la última capa.

Otros aspectos de la configuración del modelo no presentes en el gráfico ni en la descripción del modelo son, así mismo, parametrizables. Sus valores se han sido evolucionados de manera experimental y los resultados se mostraran en la sección de experimentación.

---

# Datos disponibles

---

La problemática planteada inspira fácilmente a la recolección y estudio de datos tanto de precipitación como de caudal en las estaciones de medida existentes en las cuencas de los ríos Arga y Ulzama. Estos conjuntos de datos son fácilmente accesibles y se dispone de un buen histórico de ellos. Adicionalmente, se aportan valores de temperatura sobre las cuencas.

Durante el desarrollo experimental, se introduce en el estudio la inclusión de ciertas variables aparentemente menos ligadas a la descarga de los ríos. Se recaban datos sobre humedad del terreno y predicciones de precipitación por modelos meteorológicos. Con esto, se ha de comentar que no todos los conjuntos de datos fueron considerados desde el inicio, múltiples de ellos han sido obtenidos, transformados o generados para su adhesión a la modelización tras la observación de resultados preliminares sin su inclusión.

## 4.1. Caudales en estaciones de aforo en río

Se toman las series históricas de mediciones de aforo en río en las siguientes estaciones.

- **Olave** Final de la cuenca del Ulzama.
- **Eugi** Tras la salida del Embalse.
- **Huarte** Final de la subcuenca del Arga previa a la confluencia con el Ulzama.
- **Burlada** Arga tras su confluencia con el Ulzama.
- **Pamplona** Arga en Pamplona
- **Arazuri** Arga tras Pamplona

La inclusión de las tres últimas estaciones esta principalmente destinada a la predicción de las mismas.

Dichas variables son estimaciones de caudal realizadas por la Confederación Hidrográfica del Ebro, valores quinceminutales estrictamente positivos medidos en  $m^3/s$ . Con el fin de equiparar la frecuencia de las variables se realiza una agregación por promedio para




Figura 4.1: Caudal en estación de aforo en Arazuri.




Figura 4.2: Caudal en estación de aforo tras embalse en Eugi.

obtener una serie temporal con periodo horario. Se muestran en las figuras 4.1 y 4.2 el aspecto de estas series.

De la segunda gráfica se puede observar cierto comportamiento artificial ya que el aforador se sitúa tras el embalse de Eugi y el desembalse en general no sigue un flujo natural.

## 4.2. Precipitación real en estaciones

Se dispone de datos de precipitación en las estaciones de pluviometría situadas en

- Beruete
- Huarte
- Lantz
- Olave
- Oskotz
- Eltzaburu
- Pamplona
- Eugi

El tratamiento seguido para la transformación de la frecuencia de las series es semejante al de los caudales, en este caso los valores, *mm* quinceminutales, se agregan.

En la figura 4.3 se observa que estas series tienen un comportamiento más parecido al de impulsos en una señal con picos en las horas en las que se presentan precipitaciones y ceros en la gran mayoría de observaciones de la serie.




Figura 4.3: Precipitación horaria en Huarte.

### 4.3. Malla de temperaturas

Se dispone de una estimación de temperaturas para un mallado de 12 puntos sobre la cuenca de los ríos Arga y Ulzama con una separación de en torno a  $8km$  longitudinalmente y  $11km$  en latitud. La intuición detrás de la incorporación de estas variables es la de ofrecer al modelo información sobre la forma de precipitación y la presencia de nieve en cabeceras de los ríos Arga y Ulzama.

Se intuye que la presencia de nieve tiene efectos tanto de moderación en el caudal de los ríos como de un posible fuerte incremento ante una rápida fusión, ejemplo de ello puede ser el escenario del 10 de diciembre de 2021.

### 4.4. Índice de precipitaciones acumuladas.

Con el fin de ofrecer al modelo información sobre precipitaciones pasadas que abarque una ventana temporal larga, de semanas, se decide generar un conjunto de variables desde las series de pluviometría. Se emplea la fórmula extraída de Rasheed et al. (2022),

$$IPA = \sum_{j=0}^i P_{t-j} k^j$$

donde  $i$  es el número total de días antecedentes,  $j$  el índice de desfase,  $P_t$  la precipitación acumulada en la hora  $t$  y  $k$  un parámetro para la construcción de la variable.

En Rasheed et al. (2022) se sugiere que el parámetro  $k$  se encuentre en el intervalo  $[0,85, 0,9]$ , dicho parámetro es susceptible a ser modificado y se podría plantear un proceso de validación para su selección. En este caso se ha tomado  $k = 0,98$  y se ha fijado un máximo para  $i$  de 30 días. Se puede observar el aspecto del índice en figura 4.4.




Figura 4.4: Índice de precipitación acumulada horario en Huarte.

## 4.5. Mapa de precipitaciones pasadas.

Aunque se dispone de una monitorización de precipitaciones bastante intensa sobre la cuenca del Arga con el conjunto de estaciones de pluviometría tomado, la resolución espacial obtenida para las precipitaciones no es tan elevada. Por ello, se plantea la inclusión en el modelo de un conjunto de datos que consiste en mapas de precipitación. Se trata de un ensemble de mapas, mallados de mayor resolución compuestos por 204 ( $17 \times 12$ ) puntos sobre la cuenca como el de la figura 4.5, cada uno de ellos generado por distintos algoritmos o distintas configuraciones de un mismo algoritmo de inferencia de pluviometrias.




Figura 4.5: Mapa de precipitación para una hora.

Este conjunto de datos constituye uno de las mallas tridimensionales en ensemble comentadas en la sección 3.1. La existencia de 10 variantes la hace un ensemble y la disposición espacial de los 204 puntos más su frecuencia horaria le da carácter espacio temporal.

## 4.6. Mapa de precipitaciones del modelo Harmonie

Con la observación de resultados de modelos preliminares, se concluye en la necesidad de adherir información sobre la lluvia futura, por ello, se toma un mapa de precipitaciones, equivalente en forma y características a los anteriores, generado por el modelo meteorológico de predicción HARMONIE-AROME (Díez Muyo 2018).

Se trata de un único mapa de precipitaciones por hora, para el trabajo se seleccionan mapas generados en pasadas, predicciones, del modelo que garantizan con margen la disponibilidad de los mapas al momento de realizar la predicción.

## 4.7. Estimaciones de humedad en suelo

Con un fin similar al de la construcción en inclusión del índice de precipitaciones acumuladas se dispone un conjunto de datos, mallados con 6 puntos sobre la cuenca, de humedad del suelo estimada por satélite. Los datos son generados por el *Copernicus Climate Change Service* (Lopez 2018).

Se dispone de estimaciones de humedad relativa, en % de saturación del terreno, o estimaciones de humedad absoluta, en  $m^3$  de agua por  $m^3$  de material de suelo. Se emplea la humedad relativa por el menor número de valores faltantes y presumible mayor calidad de las estimaciones. Para el tratamiento de valores faltantes se evalúan múltiples técnicas resultando de elección la imputación lineal. Diversas técnicas como Random Forest iterativo resultan en una no convergencia.




Figura 4.6: Humedad relativa. *Media móvil de 30 días en rojo.*

Se puede observar el claro comportamiento estacional de la serie en la figura 4.6.

# Experimentación y resultados

## 5.1. Construcción de ventanas temporales

El empleo de redes neuronales para la modelización de series temporales requiere de la definición de ventanas temporales sobre las que el modelo realizará el ajuste, para ello, se han desarrollado una transformación sobre todas las series de datos, previamente ajustadas en frecuencia, obteniendo ventanas temporales de longitud parametrizable. Dicha longitud es estudiada y depende parcialmente del numero de horas máximo sobre el que se desea realizar una predicción.




Figura 5.1: Esquema de ventanas temporales. *El número de celdas y series de celdas es puramente esquemático.*

El tamaño de ventana finalmente elegido se ha limitado a las 6 horas pasadas, se realiza una pequeña validación con tamaños variables que van desde las pocas horas a la semana que consiste en entrenamientos con conjuntos de datos reducidos y evaluación de su rendimiento. El tamaño de ventana de horas futuras corresponde con el número de horas de antelación con el que se desea predecir. Es decir, el tamaño de ventana completo



corresponde con la suma de horas pasadas, se ha seleccionado 6, más el número de horas de antelación fijado.

La construcción de dichas ventanas se optimiza para la máxima optimización de los datos, las ventanas con valores faltantes para cualquiera de las variables en las horas anteriores son descartadas, así como, las ventanas con valores faltantes en la variable a predecir en las horas futuras son descartadas.

En cuanto a los mapas de precipitaciones predecidas por el modelo HARMONIE, estos son desplazados temporalmente para la construcción de las ventanas. Al tratarse de datos predichos por un modelo meteorológico externo, la disponibilidad de los mismos es previa a su posicionamiento temporal, por ello consta de sentido su inclusión en el modelo. De esta forma, los mapas de HARMONIE correspondientes a las horas a predecir pasan como entrada al modelo de esas mismas ventanas. El grafo 5.1 muestra el esquema de la construcción de las ventanas.

## 5.2. Análisis de componentes Principales

Cada ventana generada contiene la totalidad de variabilidad presente en los datos que el modelo tendrá disponible para su ajuste, por ello se puede plantear el empleo de técnicas de análisis de esta variabilidad sobre el conjunto de ventanas temporales donde cada desplazamiento temporal seleccionado de cada una de las series es ahora una variable.

Se realiza un Análisis de Componentes Principales sobre el conjunto de ventanas generadas. Se emplea el método de PCA descrito en (Halko et al. 2011; Martinsson et al. 2011).

De los cientos de variables generadas la práctica totalidad de la varianza se condensa en pocas decenas de variables. Sin embargo no se vislumbra a simple vista de la figura 5.2 una simple relación entre las componentes principales y el caudal medido.




Figura 5.2: Caudal en Arazuri a las 6 horas frente a componentes principales.

En la figura 5.3 se observan claramente remanentes de dependencia temporal siendo fácilmente identificables los escenarios de caudales elevados como curvas en el espacio

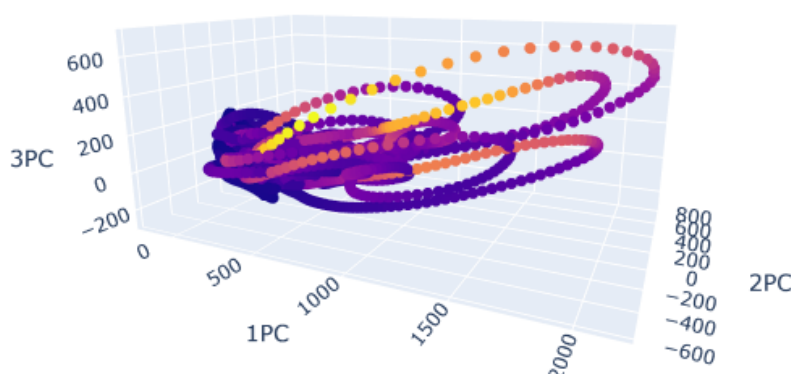


Figura 5.3: Caudal en Arazuri a las 6 horas frente a tres componentes principales.

de las tres primeras componentes principales. Esto es indicador tanto de que los datos sí recogen información que permite identificar dichos escenarios (no tanto de que expliquen el caudal con precisión), así como de la unicidad de cada uno de esos escenarios al ser claramente identificables y no agregarse en los puntos en una misma estructura.

### 5.3. Empleo de predicciones meteorológicas

Tras la primera experimentación se comprueba que el modelo descrito es capaz de inferir el comportamiento del caudal para horas próximas. Sin embargo, ante la cuestión de generalización de la predicción para intervalos más allá de las horas inmediatas siguientes el modelo resultaba incapaz de mantener el rendimiento. Dicho rendimiento se evalúa sobre escenarios de caudal variable.

Con estos resultados en mente, se especula la necesidad de alimentar el modelo con información sobre la magnitud de precipitaciones futuras. Estos datos corresponden con los presentados en la sección 4.6 para el modelo HARMONIE.

### 5.4. Tratamiento de mapas

Los mapas o mallas de valores introducidos en las secciones 4.5 y 4.6, compuestos por 204 valores con frecuencia horaria, requieren de un tratamiento espacial que se hibride con la red neuronal.

Se decide realizar un agregación de los 204 puntos para cada instante temporal y otra agregación sobre las diferentes versiones de los mapas en cada instante, ya sea por los componentes del ensemble para 4.5 o para las distintas pasadas del modelo meteorológico HARMONIE para 4.6.

La primera de las agregaciones se realiza sobre un conjunto de 8 máscaras sobre los 204 puntos, obteniendo 8 valores como resultado de la agregación. Estas máscaras agrupan los puntos de acuerdo a su distancia por el cauce fluvial hasta la estación de medida de caudal sobre la que se realiza la predicción. En concreto las máscaras corresponden a las siguientes distancias.

- **0** → Punto fuera de la cuenca.
- **1** → Punto a entre 0 y 5 *km* de la estación.
- **2** → Punto a entre 5 y 10 *km* de la estación.
- **3** → Punto a entre 10 y 15 *km* de la estación.
- **4** → Punto a entre 15 y 20 *km* de la estación.
- **5** → Punto a entre 20 y 25 *km* de la estación.
- **6** → Punto a entre 25 y 30 *km* de la estación.
- **7** → Punto a entre 30 y 35 *km* de la estación.
- **8** → Punto en la subcuenca anterior al embalse de Eugi.

La segunda de las agregaciones cumple únicamente una función de reducción de valores de entrada para el modelo.

Ambas agregaciones se realizan de acuerdo a lo presentado en la sección 3.1, las distintas funciones de agregación son evaluadas en el desarrollo experimental.

## 5.5. Parámetros de entrenamiento

La implementación del modelo se realiza sobre Tensorflow (Abadi et al. 2016) y Keras (Chollet et al. 2015). Se emplea un equipo con tarjeta gráfica *NVIDIA GeForce RTX 3060*.

Se emplea el error cuadrático medio, *MSE*, como función de coste, definido como por 5.1.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5.1)$$

Donde:

- *MSE* es el error cuadrático medio.
- *n* es el número de valores de caudal predichos.
- $y_i$  es el valor real de caudal en ventana *i*.
- $\hat{y}_i$  es el valor predicho de caudal en ventana *i*.

El optimizador empleado es Adam, descrito en (Kingma and Ba 2014), un algoritmo de optimización ampliamente utilizado en el campo del aprendizaje profundo. Es una combinación del optimizador de descenso de gradiente estocástico (SGD) con momentum (Ruder 2016) y el método de estimación adaptativa de momentos (RMSprop) (Hinton et al. 2012). Adam adapta automáticamente la tasa de aprendizaje para cada parámetro individual y mantiene un promedio de los momentos de primer y segundo orden de los gradientes para realizar ajustes más precisos durante el entrenamiento lo que le permite converger rápidamente y ser eficiente en términos de memoria y ser potencialmente eficaz en problemas con grandes conjuntos de datos y redes pesadas.

Como parámetros de estructura del modelo se emplean 64 celdas LSTM en la red recurrente autorregresiva con funciones de activación  $\tanh(x)$ , definida como  $\frac{e^x - e^{-x}}{e^x + e^{-x}}$ , en la capa de salida y sigmoide:  $\sigma(x)$ , definida como  $\frac{1}{1 + e^{-x}}$ , en las capas recurrentes. La inicialización de los pesos se realiza mediante el método *Glorot Xavier Uniform* (Glorot and Bengio 2010), excepto para los *bias* donde se emplea inicialización por ceros.

Por otra parte el modelo cuenta con un regresor final con 5 capas dimensiones  $\{512, 128, 32, 12\}$ , correspondiéndose el último valor con el número de horas de predicción fijado. Se emplea la activación  $\text{ReLU}(x)$ , definida como  $\max(0, x)$ , y la misma inicialización de pesos que las celdas recurrentes.

En cuanto a la agregación por OWA, definida en la sección 3.1, los pesos  $w_i$ , se fijan como parámetros aprendibles del modelo.

El entrenamiento se realiza sobre una partición del conjunto de entrenamiento, en concreto se toma una fracción, del 50%, de las ventanas temporales siendo seleccionadas para conjunto de entrenamiento las primeras cronológicamente. De esta manera, los datos de los dos conjuntos de ventanas adicionales, validación y *test* (ambos con un 25% de las ventanas) contienen valores no presentes en el conjunto de entrenamiento.

## 5.6. Resultados

A continuación se presentan los resultados para las cuatro funciones de agregación descritas por medio de dos métricas evaluadas sobre el conjunto de *test*. Las métricas empleadas son el, ya introducido como función de *loss* para el entrenamiento, *MSE* y el coeficiente de determinación,  $R^2$ , definido como  $1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$ .

<i>offset</i>	MSE	$R^2$
1	28.406460	0.979961
2	35.475504	0.974973
3	51.713039	0.963517
4	73.639662	0.948044
5	82.194151	0.942000
6	103.953867	0.926633
7	136.979903	0.903307
8	163.199052	0.884781
9	215.346804	0.847943
10	301.403373	0.787154
11	316.578686	0.776417
12	327.949101	0.768367

(a) Agregación por máximo.

<i>offset</i>	MSE	$R^2$
1	25.789849	0.981807
2	30.173172	0.978714
3	44.297314	0.968749
4	63.927526	0.954897
5	111.527892	0.921300
6	113.339479	0.920009
7	157.704482	0.888678
8	178.464673	0.874003
9	198.433677	0.859886
10	233.838563	0.834867
11	287.872613	0.796690
12	298.761090	0.788983

(b) Agregación por mínimo.

<i>offset</i>	MSE	$R^2$
1	28.338175	0.980009
2	25.075739	0.982310
3	33.796185	0.976157
4	51.279738	0.963820
5	60.389045	0.957386
6	92.494895	0.934720
7	118.105703	0.916630
8	130.031123	0.908197
9	162.881575	0.884989
10	204.255480	0.855759
11	233.576854	0.835037
12	259.633118	0.816619

(a) Agregación por media.

<i>offset</i>	MSE	$R^2$
1	24.215704	0.982917
2	29.973583	0.978855
3	36.122513	0.974516
4	49.454947	0.965108
5	61.297012	0.956746
6	75.981940	0.946375
7	99.029580	0.930096
8	115.039621	0.918781
9	146.311070	0.896689
10	175.113143	0.876338
11	201.593532	0.857625
12	216.085148	0.847378

(b) Agregación por OWA.

Cuadro 5.2: Resultados en *test* para función de agregación e intervalo de predicción, *offset*.

El conjunto de tablas 5.2 contiene los resultados de las métricas indicadas. El rendimiento del modelo resulta óptimo para el intervalo de predicción de hasta 6 horas, 8 en el caso del modelo que emplea agregaciones por OWA con pesos entrenables.

En cualquier caso, la interpretación de los resultados dispuestos en las tablas debe realizarse con cautela ya que el rendimiento general de la predicción puede no ser consistente con el rendimiento en escenarios de elevado caudal. Por esto, se realiza un análisis gráfico de una selección de escenarios del conjunto de *test*.

Los resultados de ajuste del modelo sobre el conjunto de *train* presentan un sobreajuste muy significativo. Con respecto a esto, se comenta que las modificaciones sobre el modelo, como la reducción de su tamaño o el uso de capas que supongan un cuello de botella, no consigue reducir ese sobreaprendizaje sin dañar los resultados en *test*.

Las figuras 5.4, 5.5, 5.6 y 5.7, presentan los resultados de predicción 6 horas vista para las cuatro funciones de agregación. Se incluyen en el anexo de este mismo documento las gráficas para los valores de *offset* de 3, 9 y 12 horas.

Tanto los valores de las métricas detalladas como la interpretación gráfica de los resultados indican un rendimiento superior para el modelo que emplea las agregaciones OWA con pesos entrenables. Si bien, las diferencias entre las funciones de agregación no resultan muy significativas.

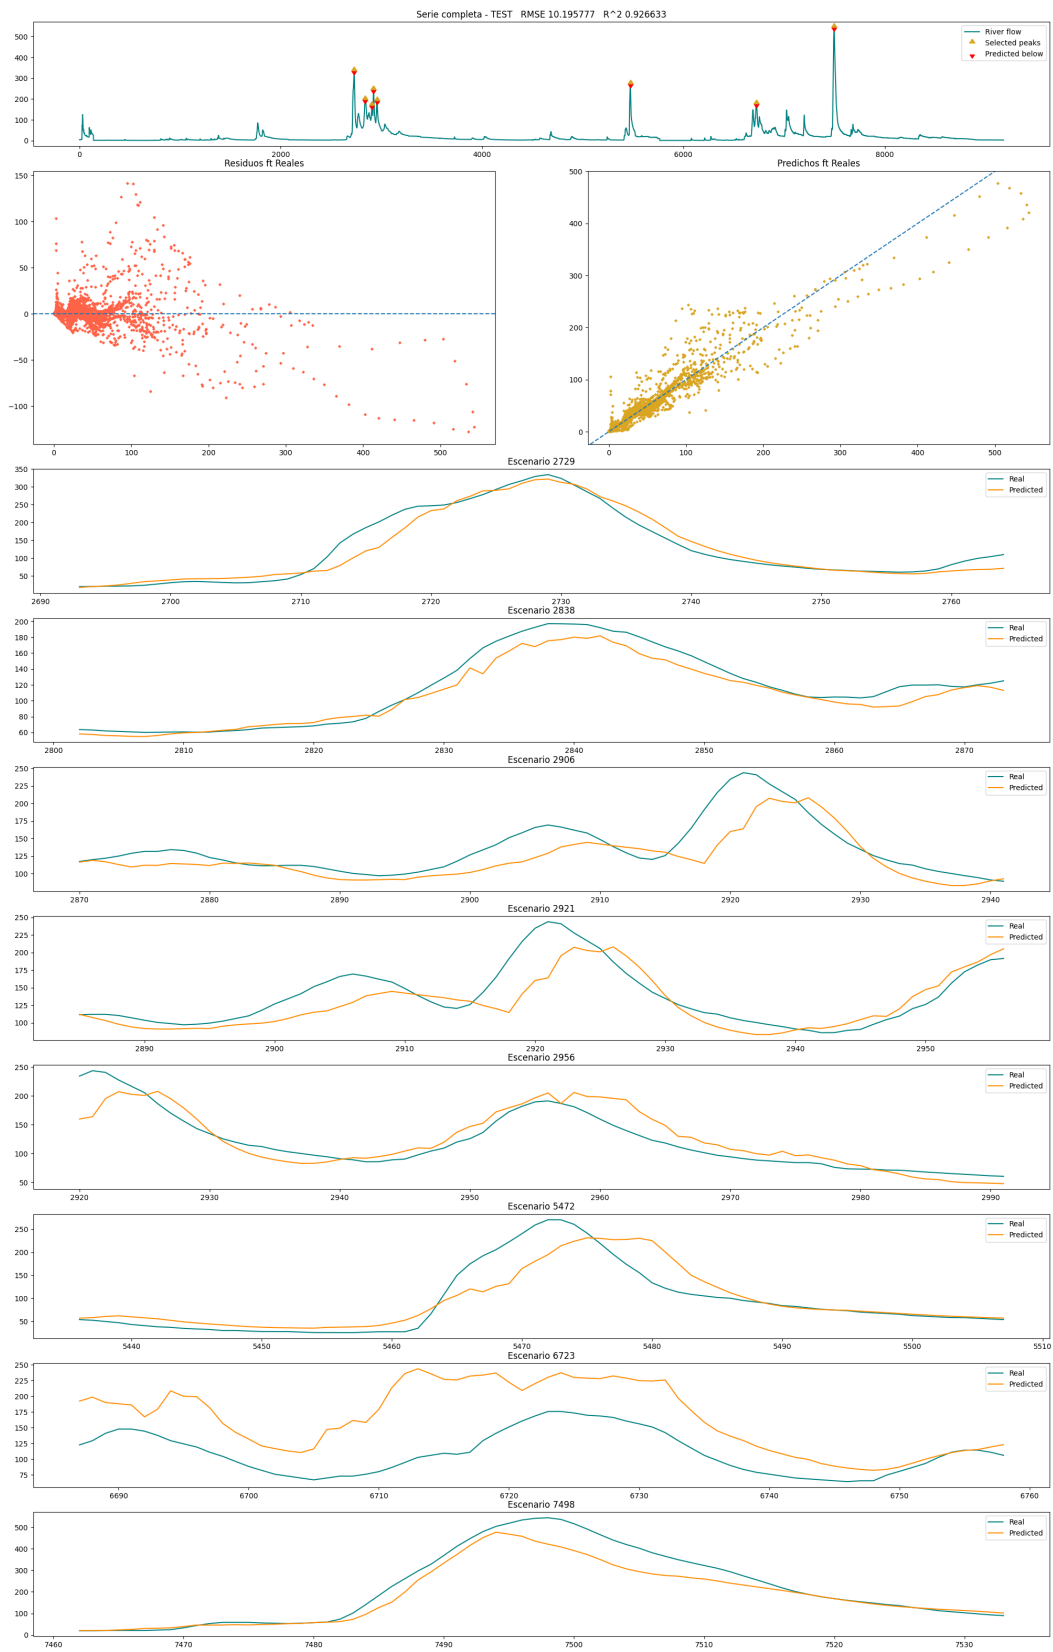
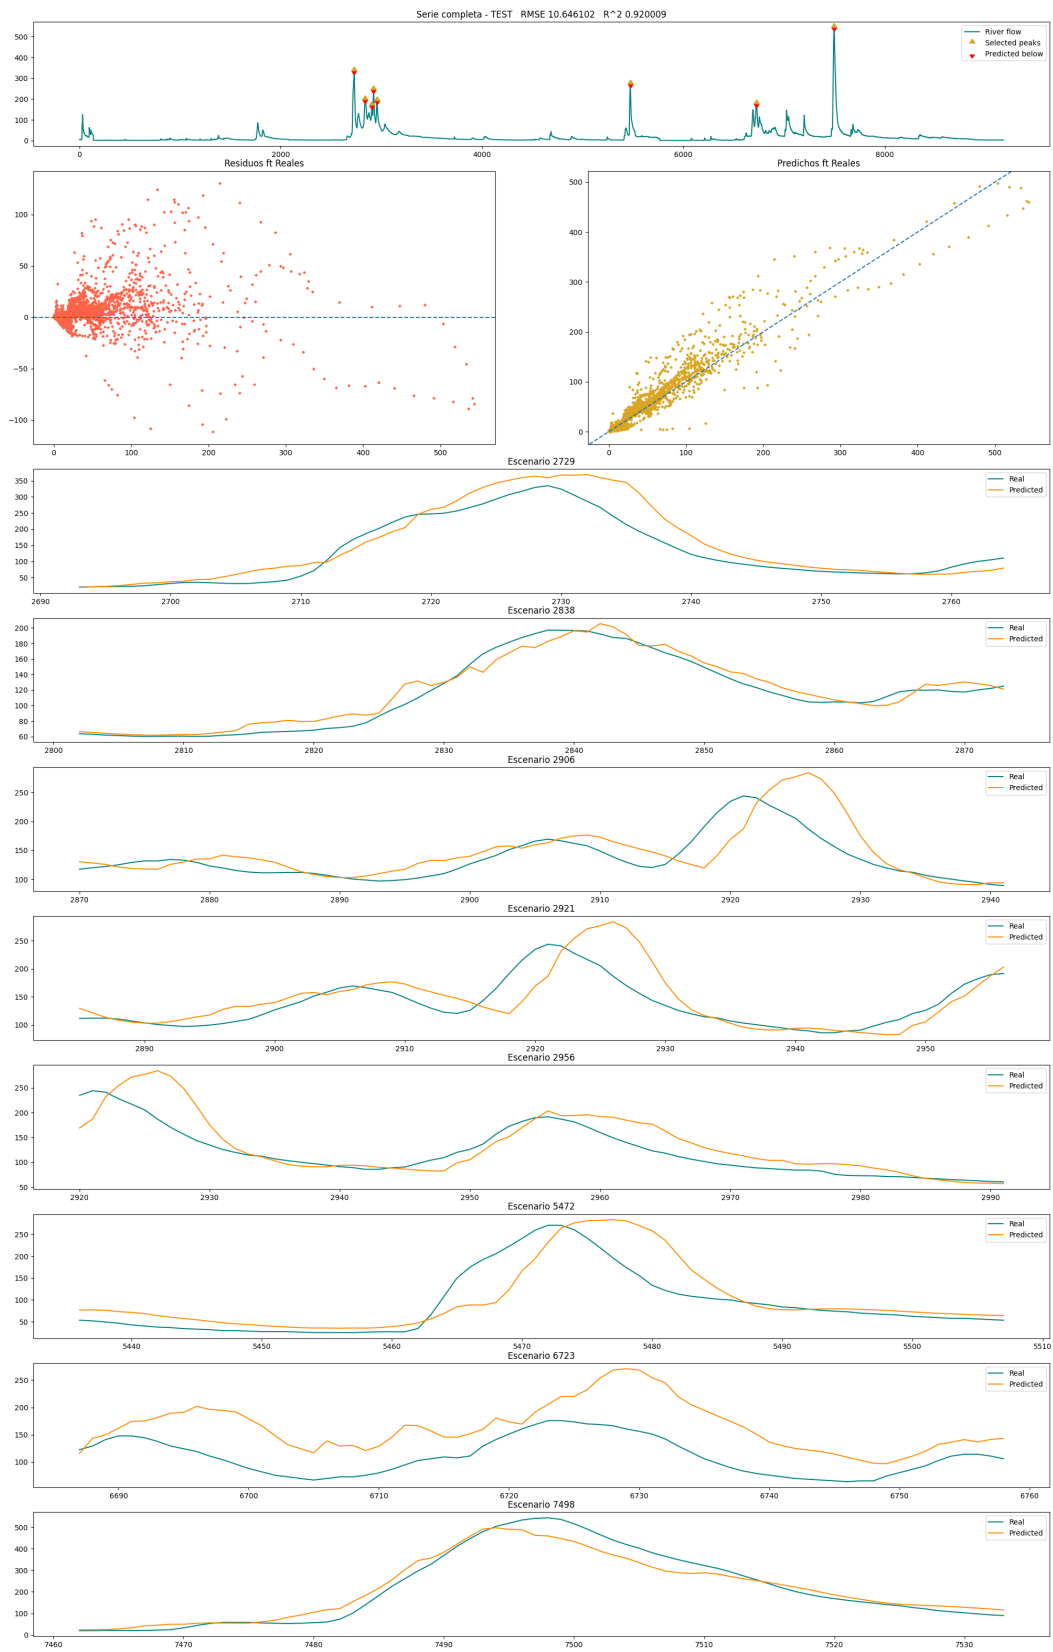
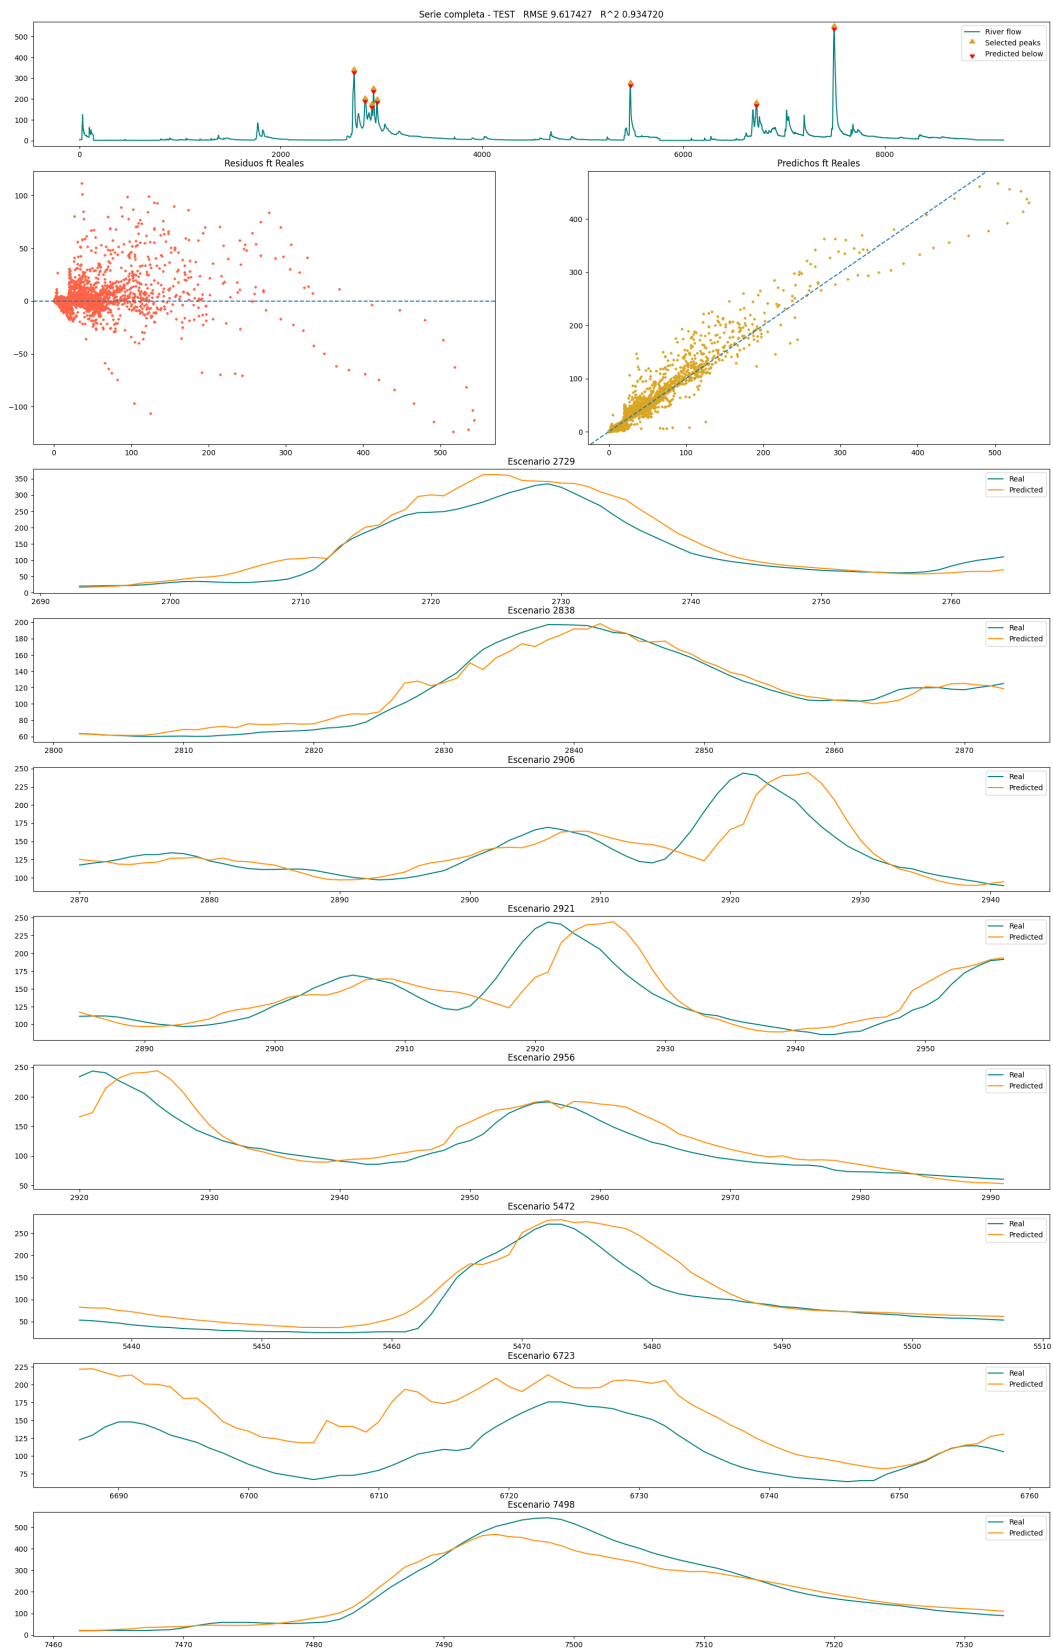


Figura 5.4: Resultados gráficos en *test* para agregación por máximo, *offset* de 6h.

Figura 5.5: Resultados gráficos en *test* para agregación por mínimo, *offset* de 6h.



Figura 5.6: Resultados gráficos en *test* para agregación por media, *offset* de 6h.

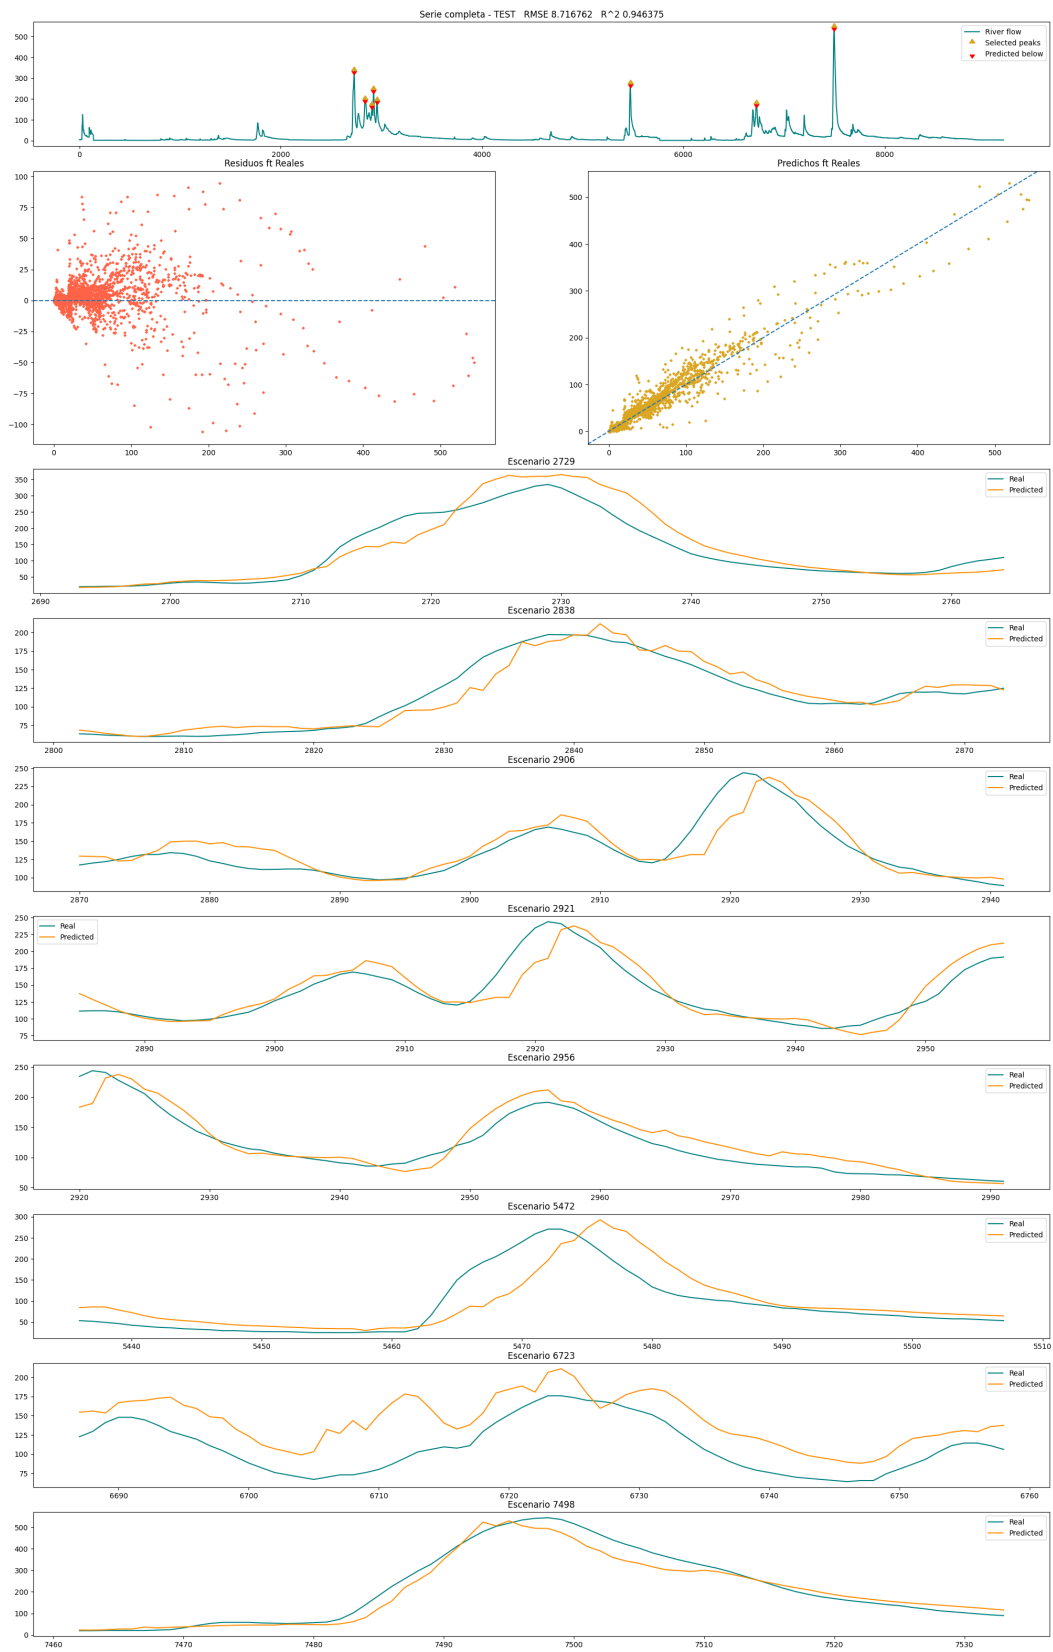


Figura 5.7: Resultados gráficos en *test* para agregación por OWA, *offset* de 6h.

---

## Conclusiones y mejoras futuras

---

Una de las ideas trascendentales para la elaboración de este proyecto es la de presentar la potencial utilidad de los algoritmos de aprendizaje profundo, ya sea por hibridación con otros modelos o por su reemplazo, sobre campos en los que la modelización clásica se encuentra fuertemente extendida. El documento presenta el planteamiento, desarrollo, experimentación y resultados de una red neuronal construida *ad hoc* para la predicción de caudal de río.

Los resultados obtenidos son, a vista de expertos, prometedores en cuanto a la mejora de predicción para los escenarios de caudal elevado, los que dada la principal problemática: las inundaciones y su carácter destructivo, resultan de verdadero interés. Se prueba de esta forma la viabilidad en el desarrollo de un modelo de alerta temprana para estos escenarios de riesgo por medio de las técnicas detalladas en el documento.

Si bien, los resultados pueden parecer ideales, al menos para los intervalos de no excesivas horas de antelación, la garantía de generalización del modelo para escenarios futuros no se puede dar por absoluta. Los escenarios de inundación, tal como se muestra en el desarrollo experimental, cuentan con características únicas, que en ocasiones desafortunadas, podrían lastrar severamente el rendimiento del modelo llevándolo a la infraestimación o sobreestimación de la magnitud de inundaciones futuras.

Por otra parte, las propiedades del problema planteado tienen una fuerte dependencia con las características de localidad para la región de Pamplona. Esto es, la generalización del modelo sobre otras cuencas fluviales no está, ni mucho menos, garantizada. Este modelo hace uso una variedad considerable de datos asociados a la cuenca de los ríos que transcurren por Pamplona, la disponibilidad y naturaleza de los mismos, así como su precisión o dimensiones, pueden ser drásticamente diferentes para otras localizaciones provocando efectos insospechados en el rendimiento del modelo aquí empleado.

Por último, se presentan múltiples vías para el futuro desarrollo que van desde el desarrollo de nuevas arquitecturas, como (Vaswani et al. 2017), o al mayor nivel de hibridación del modelo de aprendizaje profundo con sistemas de control existentes.

---

# Bibliografía

---

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ..., and Ghemawat, S. (2016). Tensorflow: Large-scale machine learning on heterogeneous systems. Software available from tensorflow.org.
- Bescos, A. and Camarasa, A. M. (1998). Caracterización hidrológica del río arga (navarra): el agua como recurso y como riesgo. *Estudios Geográficos*, 59(232):389–422.
- Chollet, F. et al. (2015). Keras. GitHub repository.
- Díez Muyo, M. V. (2018). Harmonie-arome, modelo operativo de escala convectiva de aemet.
- Donahue, J., Anne Hendricks, L., Guadarrama, S., Rohrbach, M., Venugopalan, S., Saenko, K., and Darrell, T. (2015). Long-term recurrent convolutional networks for visual recognition and description. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2625–2634.
- Gallant, S. I. et al. (1990). Perceptron-based learning algorithms. *IEEE Transactions on neural networks*, 1(2):179–191.
- Glorot, X. and Bengio, Y. (2010). Understanding the difficulty of training deep feed-forward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pages 249–256. JMLR Workshop and Conference Proceedings.
- Halko, N., Martinsson, P.-G., and Tropp, J. A. (2011). Finding structure with randomness: Probabilistic algorithms for constructing approximate matrix decompositions. *SIAM review*, 53(2):217–288.
- Hinton, G., Srivastava, N., and Swersky, K. (2012). Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. *Cited on*, 14(8):2.
- Kalita, D. (2022). A brief overview of recurrent neural networks (rnn). *Analytics Vidhya*. Retrieved July, 10:2022.
- Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Lespinas, F., Ludwig, W., and Heussner, S. (2014). Hydrological and climatic uncer-

- tainties associated with modeling the impact of climate change on water resources of small mediterranean coastal rivers. *Journal of Hydrology*, 511:403–422.
- Lopez, A. (2018). Soil moisture gridded data from 1978 to present.
- López, J. J., González, M., Scaini, A., Goñi, M., Valdenebro, J. V., and Gimena, F. N. (2012). Caracterización del modelo hec-hms en la cuenca de río arga en pamplona y su aplicación a cinco avenidas significativas. *Obras y proyectos*, (12):15–30.
- Magnusson, R. J. (2003). *Water technology in the Middle Ages: cities, monasteries, and waterworks after the Roman Empire*. JHU press.
- Martinsson, P.-G., Rokhlin, V., and Tygert, M. (2011). A randomized algorithm for the decomposition of matrices. *Applied and Computational Harmonic Analysis*, 30(1):47–68.
- Mosavi, A., Ozturk, P., and Chau, K.-w. (2018). Flood prediction using machine learning models: Literature review. *Water*, 10(11):1536.
- Olcina, J. et al. (2008). Prevención de riesgos: cambio climático, sequías e inundaciones.
- Pandi, D., Kothandaraman, S., and Kuppusamy, M. (2021). Hydrological models: a review. *International Journal of Hydrology Science and Technology*, 12(3):223–242.
- Pejenaute Goñi, J. M. (2002). *Navarra. : geografía*. Gobierno de Navarra, Departamento de Educación y Cultura.
- Ramachandran, P., Zoph, B., and Le, Q. V. (2017). Searching for activation functions. *arXiv preprint arXiv:1710.05941*.
- Rasheed, Z., Aravamudan, A., Gorji Sefidmazgi, A., Anagnostopoulos, G. C., and Nikolopoulos, E. I. (2022). Advancing flood warning procedures in ungauged basins with machine learning. *Journal of Hydrology*, 609:127736.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Sak, H., Senior, A., and Beaufays, F. (2014). Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition. *arXiv preprint arXiv:1402.1128*.
- TensorFlowCore (2023). Time series forecasting — TensorFlow Core — tensorflow.org. [https://www.tensorflow.org/tutorials/structured\\_data/time\\_series#advanced\\_autoregressive\\_model](https://www.tensorflow.org/tutorials/structured_data/time_series#advanced_autoregressive_model). [Accessed 04-Jun-2023].
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.

---

Vinogradov, Y. B., Semenova, O., and Vinogradova, T. (2011). An approach to the scaling problem in hydrological modelling: the deterministic modelling hydrological system. *Hydrological processes*, 25(7):1055–1073.

Yager, R. R. (1993). Families of owa operators. *Fuzzy sets and systems*, 59(2):125–148.

## Anexo del capítulo 5

---

Se incluyen gráficos de predicción sobre *test* para los *offset* de 3, 9 y 12 horas en escenarios de elevado caudal.

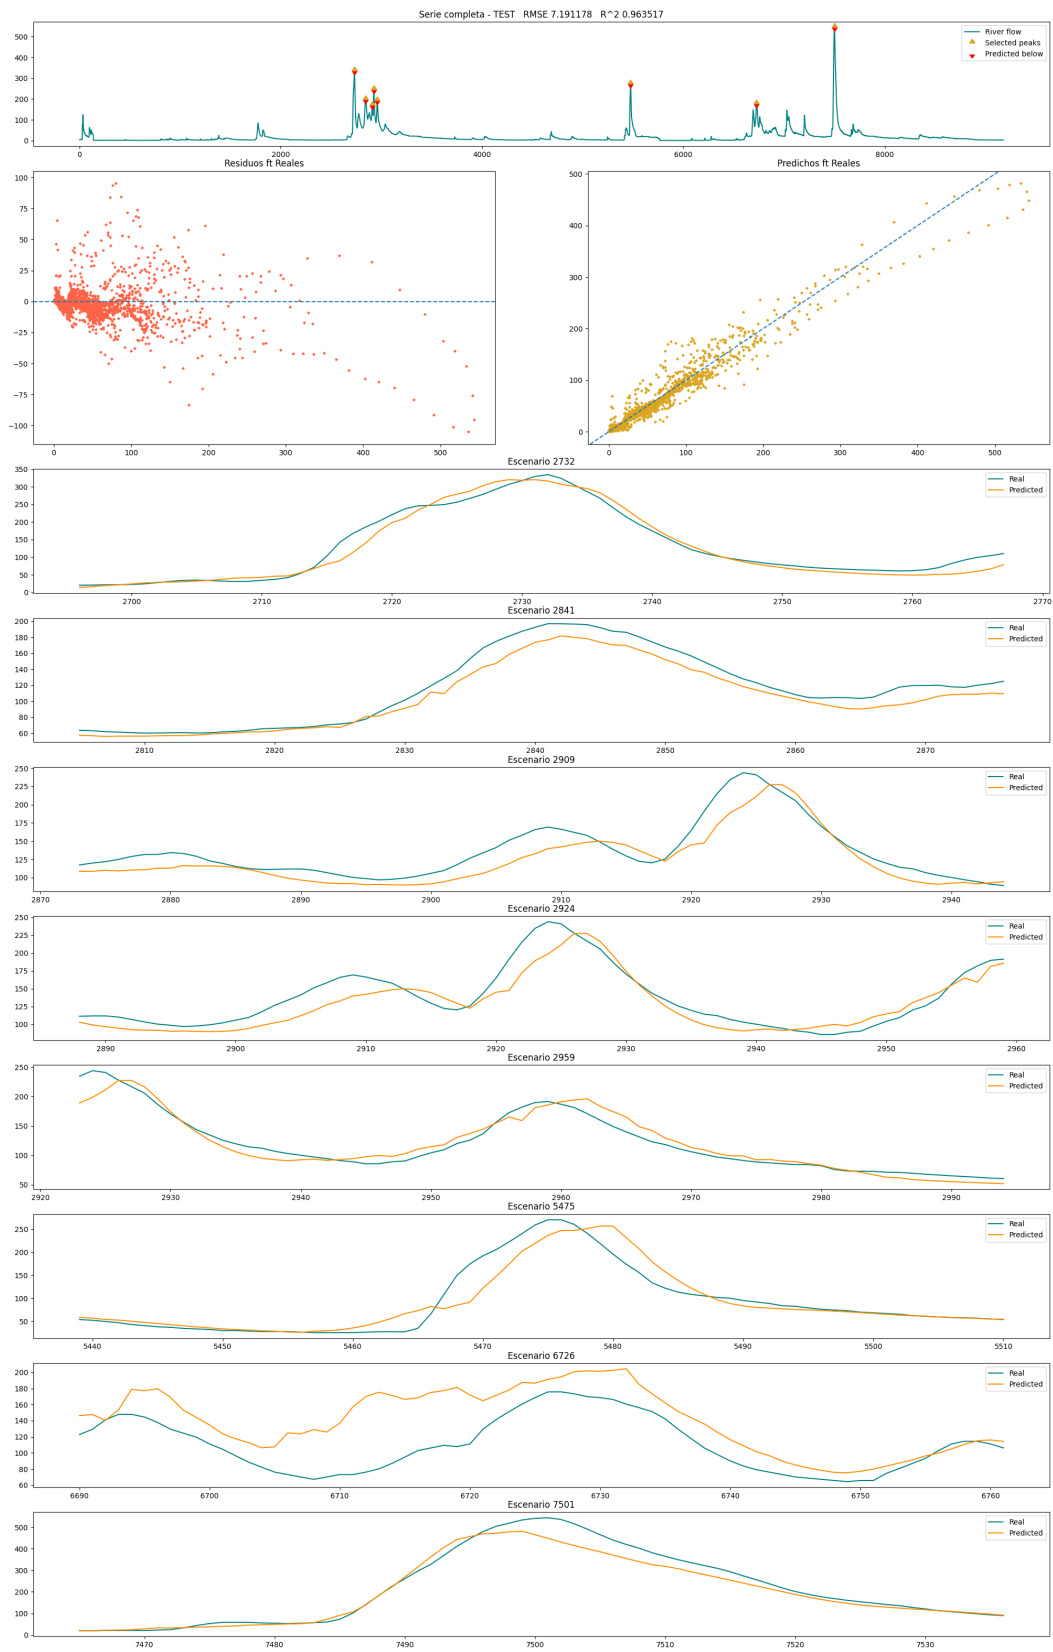


Figura A.1: Resultados gráficos en *test* para agregación por máximo, *offset* de 3h.



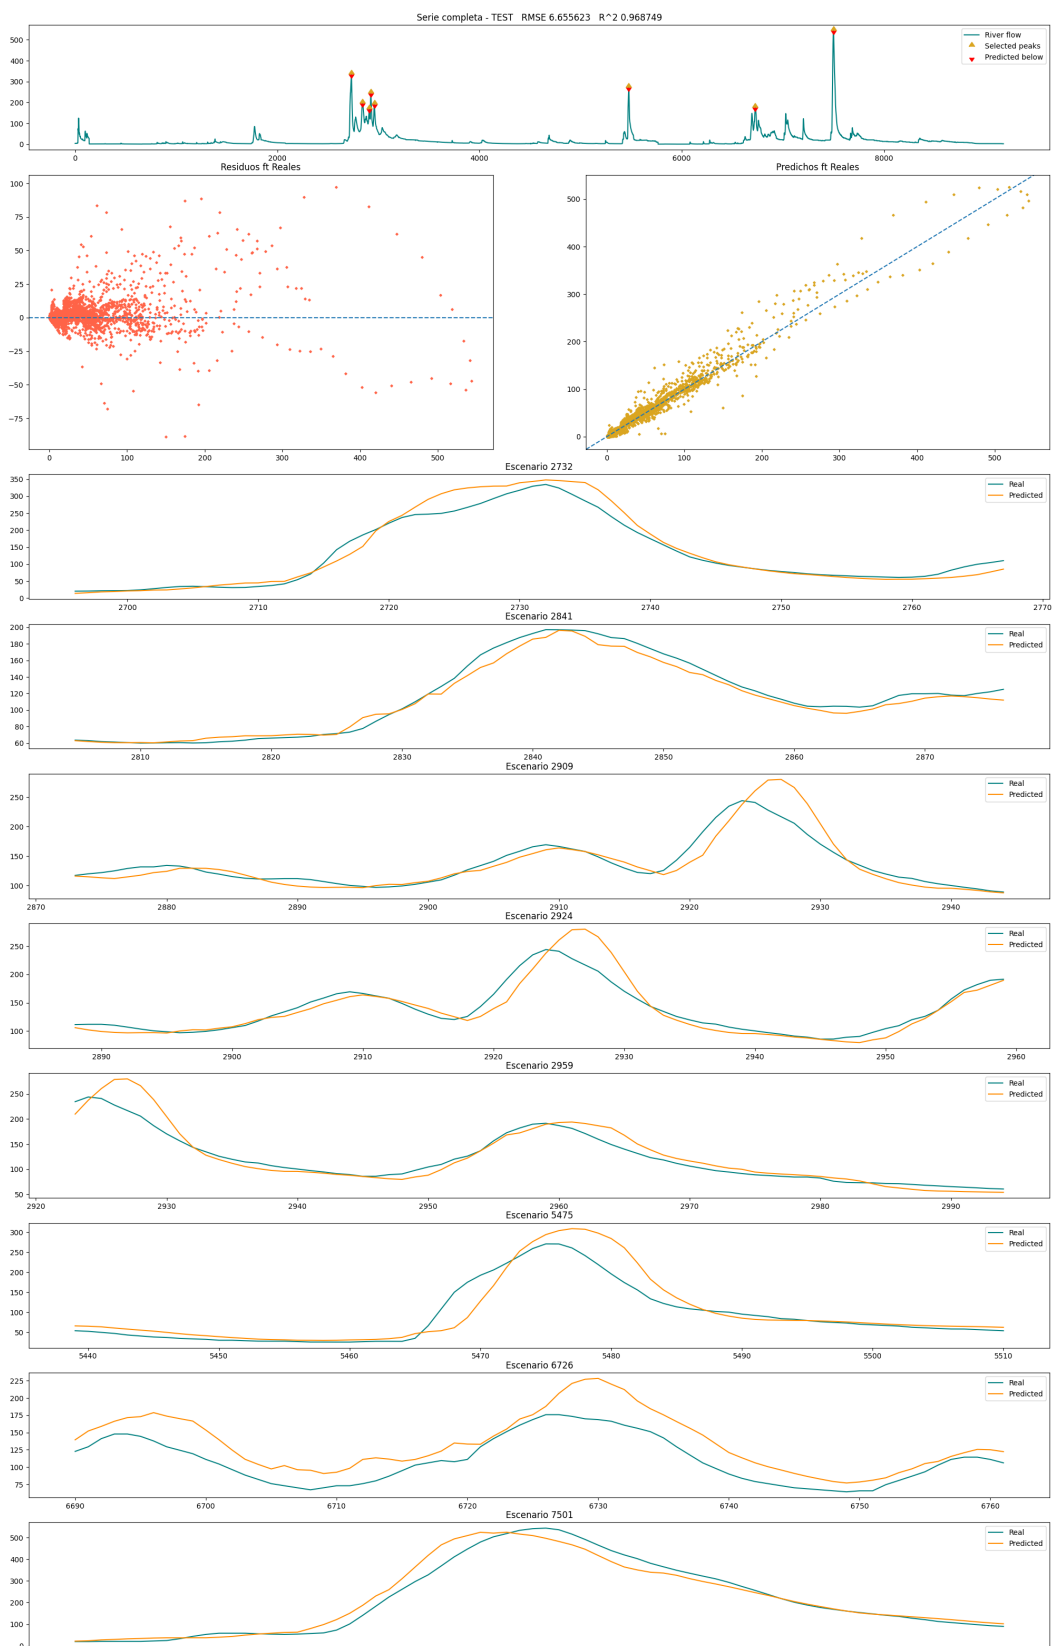


Figura A.2: Resultados gráficos en *test* para agregación por mínimo, *offset* de 3h.

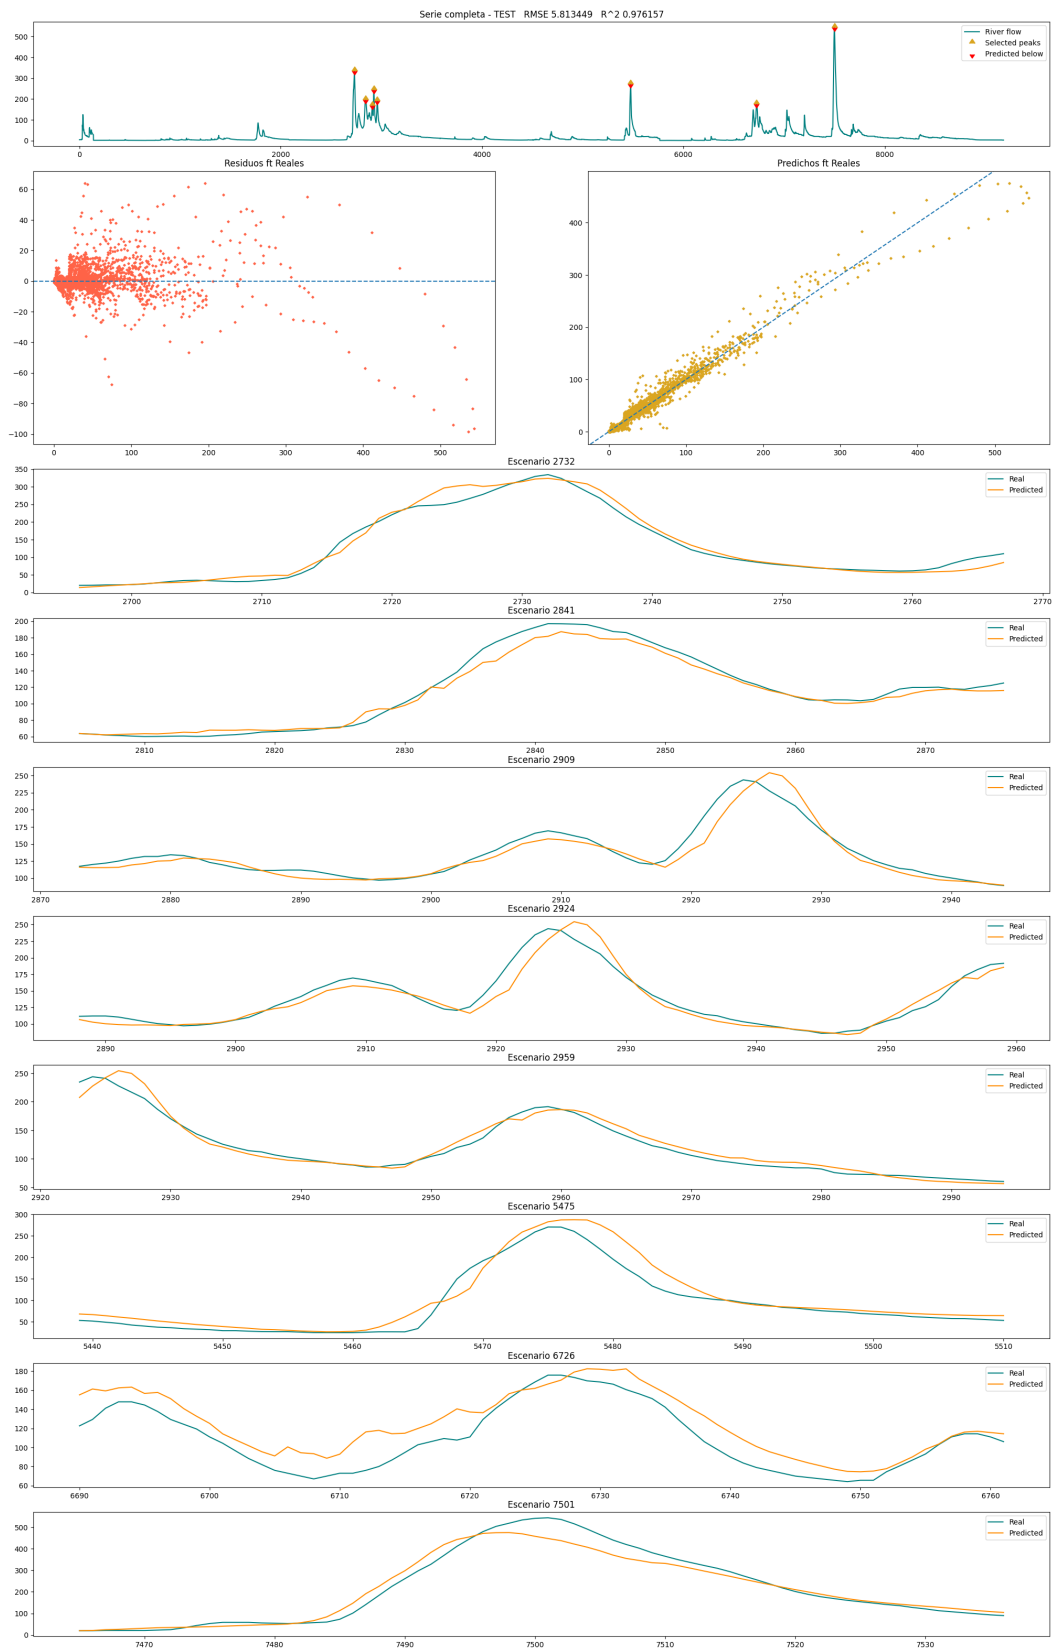


Figura A.3: Resultados gráficos en *test* para agregación por media, *offset* de 3h.




Figura A.4: Resultados gráficos en *test* para agregación por OWA, *offset* de 3h.




Figura A.5: Resultados gráficos en *test* para agregación por máximo, *offset* de 9h.

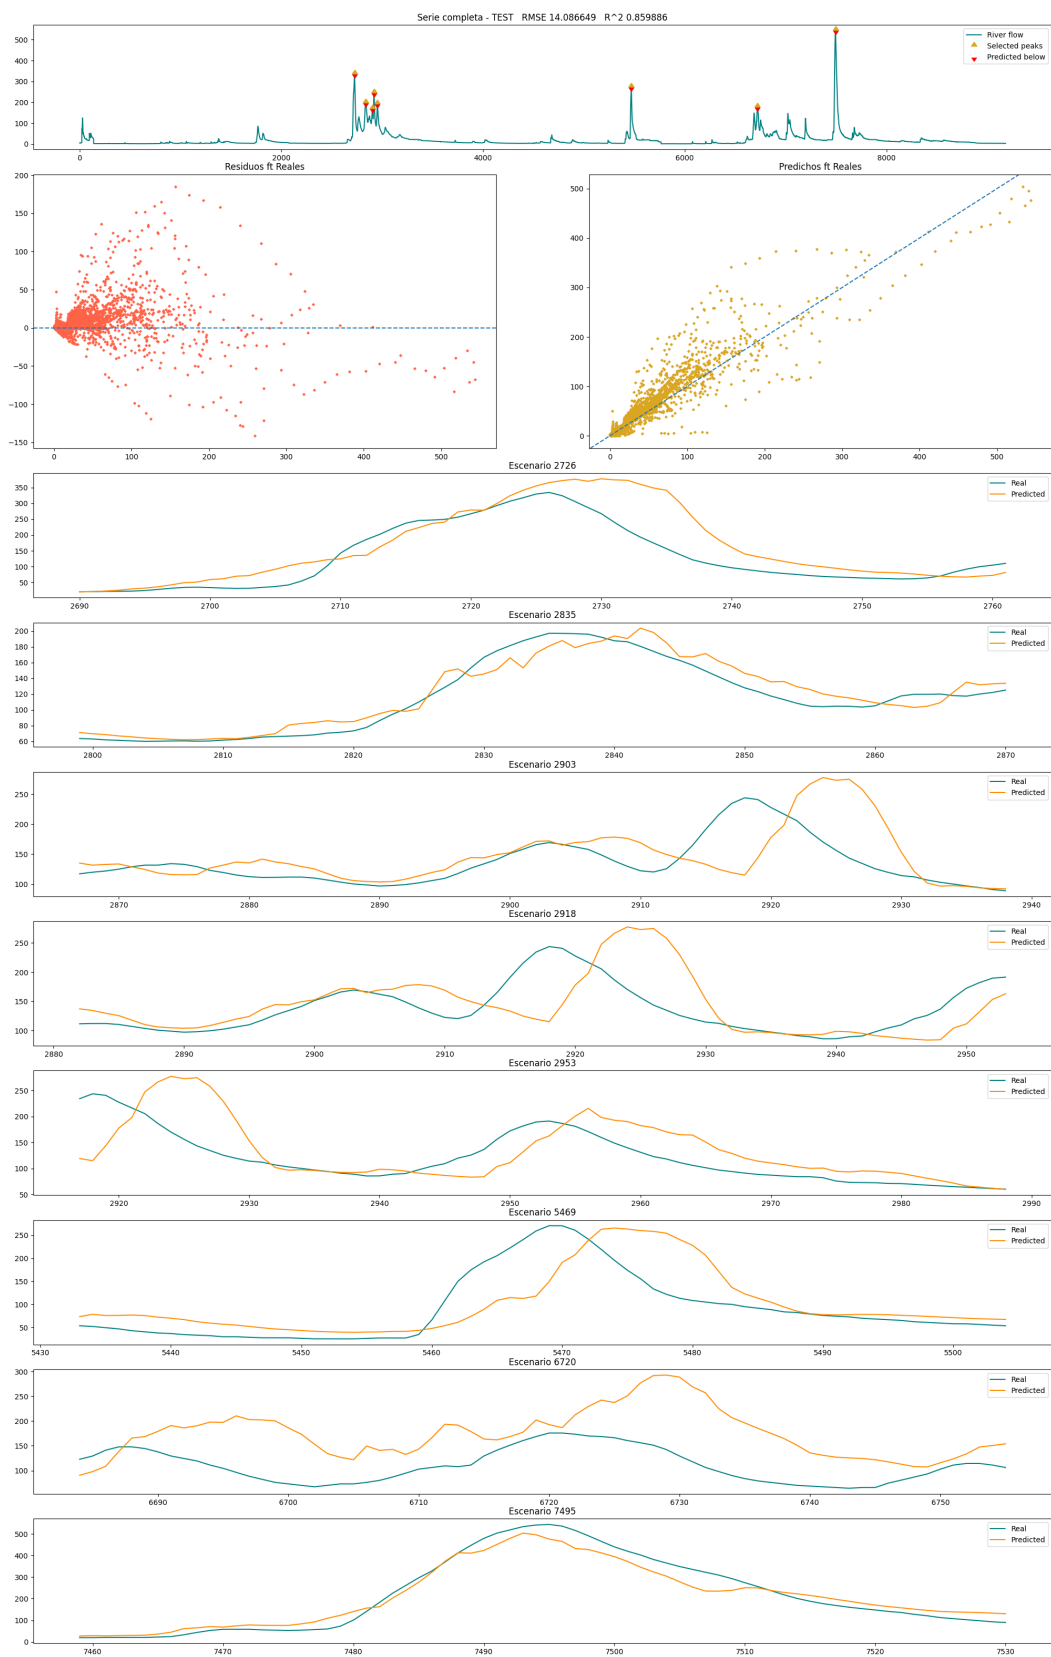


Figura A.6: Resultados gráficos en *test* para agregación por mínimo, *offset* de 9h.

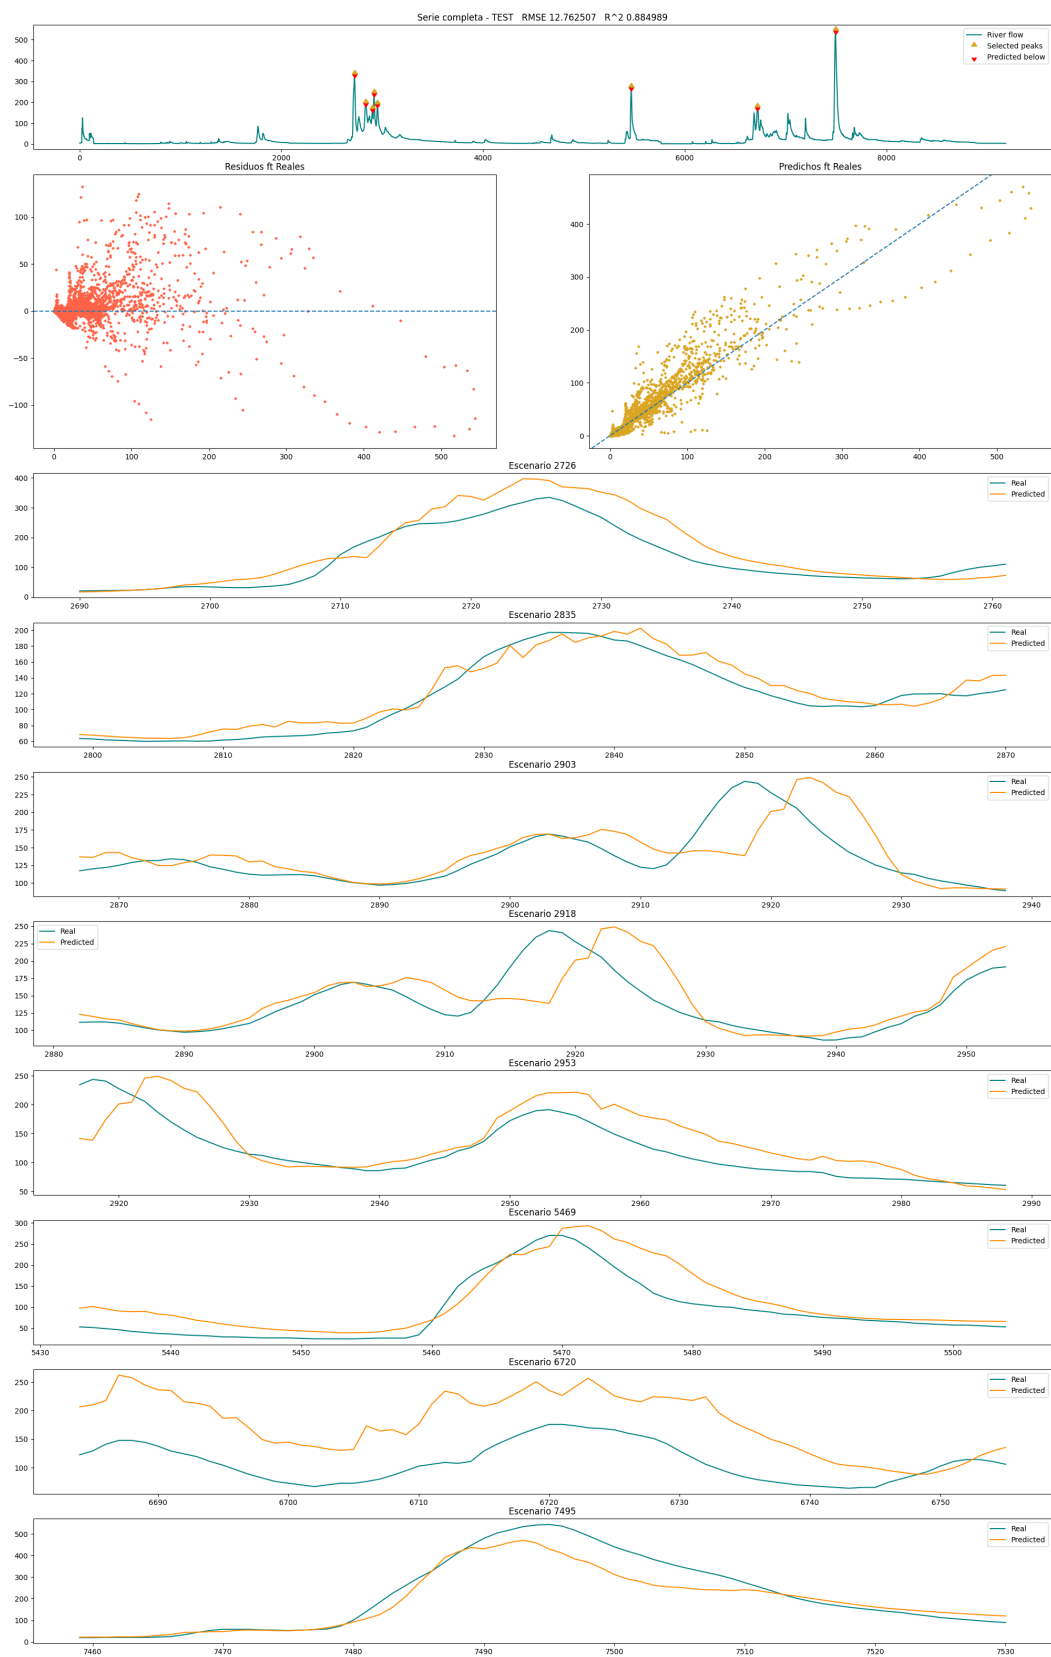


Figura A.7: Resultados gráficos en *test* para agregación por media, *offset* de 9h.

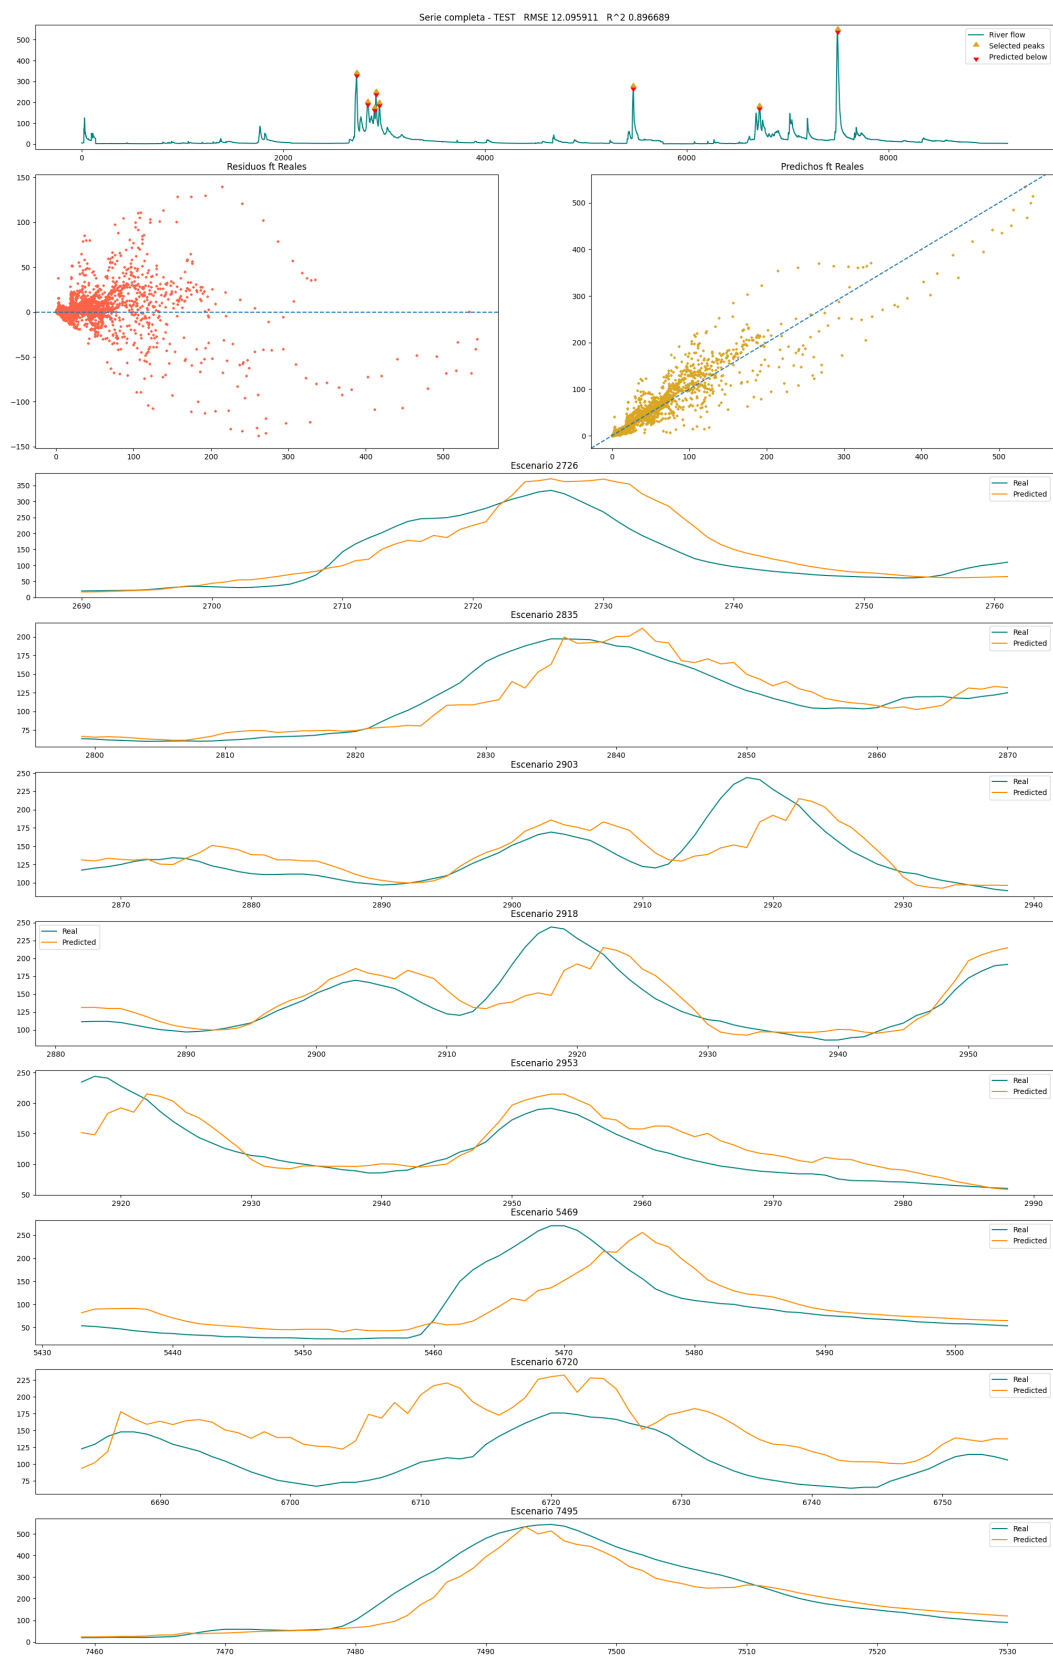


Figura A.8: Resultados gráficos en *test* para agregación por OWA, *offset* de 9h.




Figura A.9: Resultados gráficos en *test* para agregación por máximo, *offset* de 12h.






Figura A.10: Resultados gráficos en *test* para agregación por mínimo, *offset* de 12h.




Figura A.11: Resultados gráficos en *test* para agregación por media, *offset* de 12h.

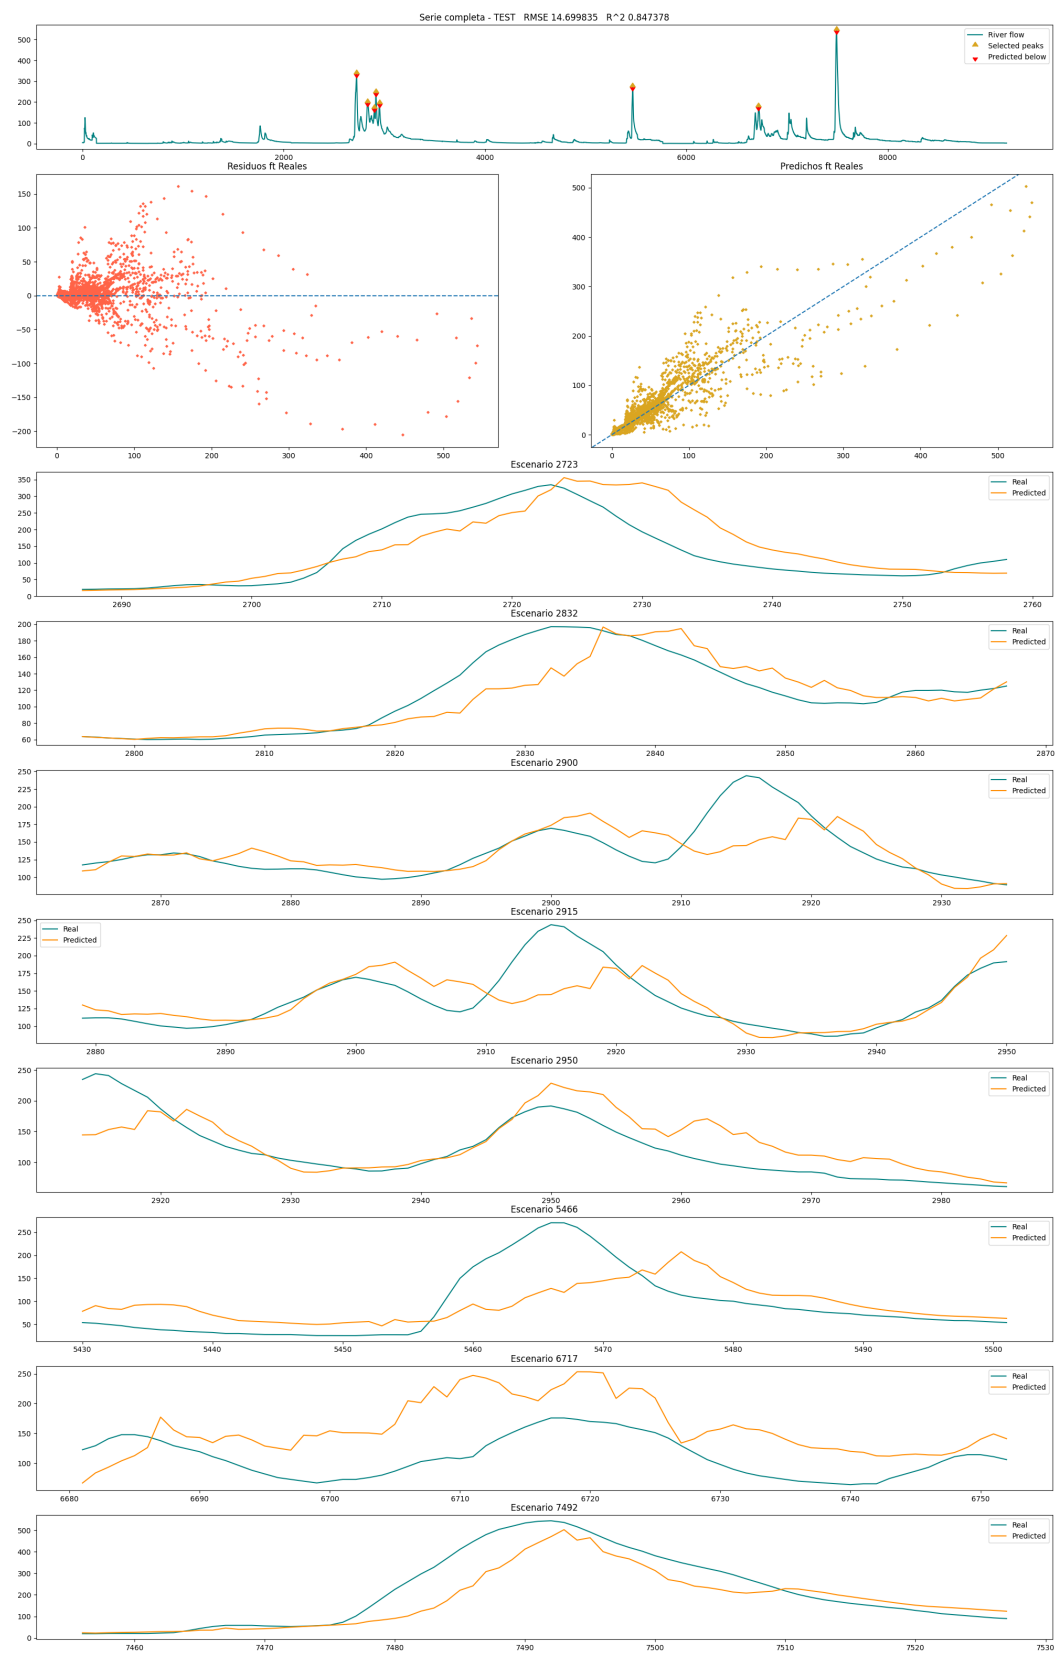


Figura A.12: Resultados gráficos en *test* para agregación por OWA, *offset* de 12h.